Entrepreneurship Journal for Finance and Business (EJFB)
2026, VOL. 07, NO. special, 135-149, E-ISSN: 2709-4251, **P-ISSN:** 2708-8790
DOI: https://doi.org/10.56967/ejfb20261021

Measuring and predicting financial sustainability using machine learning models: An applied study in Iraqi industrial companies

Mohammed A. Alsendi[1*], Ashti A. AL-Mizori [2] ،Rafiaa I. AL-Hamdani[3], Khalid A. khider [4]
[1,2,3,4] Financial and Banking, Administration and Economic college, university of Mosul, Mosul, Iraq
Mohammed.Abdulrahman@uomosul.edu.iq , Ashti_abdulsattar@uomosul.edu.iq
Rafea_ibrahem@uomosul.edu.iq , Khalid.khider@uomosul.edu.iq

Article information:
Published: 5–11– 2026

Corresponding author:
Mohammed A.Alsendi
Mohammed.Abdulrahman@uomosul.edu.iq

This work is licensed under a Creative Commons Attribution 4.0 International License.

Abstract:

This study aimed to evaluate the financial sustainability of Iraqi industrial companies using machine learning models and to compare their performance with traditional statistical models. Five key financial variables were analyzed: Working Capital Ratio (WCR), Current Ratio (CR), Return on Equity (ROE), Return on Assets (ROA), and Asset Turnover (AT). A Financial Sustainability Index (FSI) was constructed to classify companies. The results showed that WCR and CR were the most influential variables in explaining financial sustainability, while AT had the least impact. All variables demonstrated statistically significant relationships with the FSI. Moreover, machine learning models—particularly XGBoost and Random Forest—outperformed the traditional logistic regression model in predictive accuracy, with variations in variable importance rankings across models. The findings highlight the importance of focusing on working capital management and liquidity improvement to enhance financial sustainability, as well as the use of machine learning tools in financial forecasting to support more accurate strategic decision-making. This study contributes by providing a modern analytical framework to support the financial sustainability of industrial companies, with the potential for future application in other sectors. Specifically, machine learning models improved predictive accuracy by approximately 9.4% over the traditional logistic regression model, while SHAP-based analysis confirmed that WCR and CR carry the greatest weight in predicting financial sustainability. Accordingly, the study recommends that industrial companies prioritize working capital and liquidity management, that financial analysts and investors adopt machine learning models such as XGBoost and Random Forest in financial sustainability forecasting, that more comprehensive sustainability indices combining financial and operational performance be developed, and that decision-makers invest in training on machine learning tools and SHAP interpretation to support more reliable, evidence-based financial decisions.

Keywords: Financial Sustainability, Machine Learning, Financial Forecasting, Financial Performance, Iraqi Industrial Companies.

Conclusions:

1. Importance of Financial Variables: The results showed that working capital ratio (WCR) and current ratio (CR) were the most influential variables affecting the financial sustainability of industrial

companies, while asset turnover (AT) had the least influence. The SHAP values also confirmed the impact of each variable at the company level, helping to explain the importance of variables in complex models.

2. Impact of Variables on Financial Sustainability: All five financial variables (ROA, ROE, CR, AT, and WCR) showed a positive and statistically significant relationship with the financial sustainability index. This confirms their important role in strengthening companies' ability to maintain financial continuity and achieve sustainable performance.

3. Superiority of Machine Learning Models over Traditional Models: The XGBoost, Random Forest, and Artificial Neural Network (ANN) models outperformed logistic regression in terms of accuracy, precise prediction of financial sustainability, and their ability to handle nonlinear relationships and complex interactions among financial variables. The test of the second hypothesis (H2) confirmed this superiority, with a 9.4% improvement in prediction accuracy.

4. Differences in Variable Importance Across Models: The test of the third hypothesis (H3) showed that the ranking and importance of financial variables vary depending on the model used. This highlights the need to select the most influential variables when developing modern financial models to achieve better predictive accuracy and stability.

قياس الاستدامة المالية والتنبؤ بها باستخدام نماذج تعلم الآلة: دراسة تطبيقية في الشركات الصناعية العراقية

محمد عبدالرحمن محمد السندي[1*] ، آشتي عبدالستار عبدالغني المزوري[2] ، رافعة ابراهيم الحمداني[3] ، خالد عبدالله خضر الطائي[4]
[1,2,3,4] قسم العلوم المالية والمصرفية، كلية الادارة والاقتصاد، جامعة الموصل، الموصل، العراق
Mohammed.Abdulrahman@uomosul.edu.iq , Ashti_abdulsattar@uomosul.edu.iq
Rafea_ibrahem@uomosul.edu.iq , Khalid.khider@uomosul.edu.iq

معلومات البحث:
تاريخ النشر: 2026 –11– 5

المؤلف المراسل:
محمد عبدالرحمن محمد السندي
Mohammed.Abdulrahman@uomosul.edu.iq

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

المستخلص:
هدفت هذه الدراسة إلى تقييم الاستدامة المالية للشركات الصناعية العراقية باستخدام نماذج تعلم الآلة ومقارنتها بالنماذج الإحصائية التقليدية. تم تحليل خمسة متغيرات مالية رئيسية هي: رأس المال العامل (WCR)، نسبة التداول(CR) ، العائد على حقوق الملكية (ROE) ، العائد على الموجودات (ROA) ، ومعدل دوران الموجودات (AT)، وتم بناء مؤشر استدامة مالية (FSI) لتصنيف الشركات. أظهرت النتائج أن WCRو CR هما الأكثر تأثيرا على الاستدامة المالية، بينما كان ATالأقل تأثيراً. كما أظهرت جميع المتغيرات ارتباطاً دالاً إحصائياً مع FSI. وقد تفوقت نماذج تعلم الآلة، وخصوصا XGBoost و Random Forest، على الانحدار اللوجستي التقليدي في دقة التنبؤ، مع اختلاف ترتيب أهمية المتغيرات عبر النماذج. تشير النتائج إلى ضرورة تركيز الشركات على إدارة رأس المال العامل وتحسين السيولة لتعزيز استدامتها المالية، واستخدام أدوات تعلم الآلة في التنبؤ المالي لتعزيز دقة القرارات الاستراتيجية. تسهم هذه الدراسة في تقديم إطار تحليلي حديث لدعم استدامة الشركات الصناعية مالياً، مع إمكانية تعميمه على قطاعات أخرى مستقبلا. وعلى وجه التحديد، حققت نماذج تعلم الآلة تحسناً في دقة التنبؤ بنسبة بلغت نحو 9.4% مقارنة بنموذج الانحدار اللوجستي التقليدي، كما أكد تحليل قيم SHAP أن رأس المال العامل (WCR) ونسبة التداول (CR) هما الأكثر تأثيراً في التنبؤ بالاستدامة المالية. وبناءً على ذلك، توصي الدراسة الشركات الصناعية بإعطاء الأولوية لإدارة رأس المال العامل والسيولة، وتبني المحللين الماليين والمستثمرين نماذج تعلم الآلة مثل XGBoost والغابة العشوائية في التنبؤ بالاستدامة المالية، وتطوير مؤشرات استدامة أكثر شمولية تجمع بين الأداء المالي والتشغيلي، فضلاً عن استثمار صناع القرار في تدريب فرقهم على أدوات تعلم الآلة وتفسير قيم SHAP لدعم اتخاذ قرارات مالية أكثر موثوقية استناداً إلى أدلة دقيقة.

الكلمات المفتاحية: الاستدامة المالية، تعلم الاله، التنبؤ المالي، الاداء المالي، الشركات الصناعية العراقية.

المقدمة:

أصبحت الاستدامة المالية من المفاهيم المحورية في تقييم أداء الشركات، لاسيما في ظل التقلبات الاقتصادية المتزايدة، واشتداد المنافسة، وتنامي المخاطر المالية في الأسواق الناشئة. إذ لم يعد تحقيق الأرباح على المدى القصير معيارا كافيا للحكم على نجاح الشركات، بل أصبح الحفاظ على القدرة المالية والاستمرارية التشغيلية على المدى الطويل هدفا استراتيجيا تسعى إليه الشركات والمستثمرون وصانعو السياسات على حد سواء. وتعد الشركات الصناعية من أكثر القطاعات تأثرا بهذه التحديات نظرا لاعتمادها الكبير على التمويل، وتقلب تكاليف الإنتاج، وحساسية أدائها للتغيرات الاقتصادية والمالية.

تقليديا، اعتمدت دراسات الاستدامة المالية على الأساليب الإحصائية والنماذج الخطية في تحليل المؤشرات المالية والتنبؤ بالمخاطر المستقبلية، إلا أن هذه الأساليب غالبا ما تعاني من محدودية قدرتها على التقاط العلاقات غير الخطية والتفاعلات المعقدة بين المتغيرات المالية، خصوصا في البيئات الاقتصادية غير المستقرة. ومع التطور السريع في تقنيات الذكاء الاصطناعي، برزت تقنيات تعلم الآلة كأدوات تحليلية متقدمة قادرة على معالجة كميات كبيرة من البيانات، واكتشاف الأنماط الخفية، وتحقيق مستويات أعلى من الدقة في التحليل والتنبؤ مقارنة بالأساليب التقليدية.

في هذا السياق، يكتسب توظيف تقنيات تعلم الآلة في تحليل الاستدامة المالية أهمية خاصة في سوق العراق للأوراق المالية، الذي يعد من الأسواق الناشئة التي لم تحظَ باهتمام بحثي كاف في هذا المجال، على الرغم من دوره المتزايد في دعم النشاط الاقتصادي

وتمويل الشركات. كما أن محدودية الدراسات التطبيقية التي تجمع بين الاستدامة المالية وتعلم الآلة في البيئة العراقية تشكل فجوة بحثية تستدعي المعالجة.

انطلاقا من ذلك، يهدف هذا البحث إلى توظيف تقنيات تعلم الآلة في تحليل وقياس الاستدامة المالية للشركات الصناعية المدرجة في سوق العراق للأوراق المالية، مع مقارنة أدائها بالنماذج الإحصائية التقليدية، وتحديد أهم المؤشرات المالية المؤثرة في الاستدامة. ويسعى البحث إلى تقديم إطار تحليلي حديث يمكن أن يسهم في دعم قرارات المستثمرين، وتعزيز كفاءة التقييم المالي، وتوفير أدوات تنبؤية أكثر دقة لصناع القرار في السوق المالي العراقي.

1. مشكلة البحث:

في ظل التقلبات الاقتصادية والمالية المتزايدة، تواجه الشركات الصناعية تحديات كبيرة في الحفاظ على استدامتها المالية على المدى الطويل. ورغم أهمية الاستدامة المالية في تقييم الأداء المؤسسي، ما تزال غالبية الدراسات تعتمد على النماذج الإحصائية التقليدية التي تفترض علاقات خطية بين المتغيرات المالية، الأمر الذي يحد من قدرتها على تفسير العلاقات المعقدة والديناميكية في البيئات الاقتصادية غير المستقرة. وفي السياق العراقي، تبرز ندرة الدراسات التطبيقية التي توظف تقنيات تعلم الآلة في تحليل الاستدامة المالية للشركات الصناعية المدرجة في سوق العراق للأوراق المالية. ومن هنا تتحدد مشكلة البحث في التساؤل الآتي: **ما مدى كفاءة نماذج تعلم الآلة (Random Forest ، XGBoost، والشبكات العصبية الاصطناعية ANN) في تحليل وقياس الاستدامة المالية للشركات الصناعية المدرجة في سوق العراق للأوراق المالية مقارنة بالنماذج الإحصائية التقليدية؟**

2. أهمية البحث:

2-1 الأهمية العلمية

أ- إدخال نماذج تعلم الآلة المتقدمة (Random Forest، XGBoost، ANN) في تحليل الاستدامة المالية.

ب- توسيع الإطار النظري لتطبيقات الذكاء الاصطناعي في المالية، لاسيما في الأسواق الناشئة.

ت- تقديم مقارنة علمية منهجية بين النماذج الذكية والنماذج الإحصائية التقليدية.

2-2 الأهمية التطبيقية

أ- تحسين دقة التنبؤ بالاستدامة المالية للشركات الصناعية.

ب- دعم المستثمرين والمؤسسات المالية في اتخاذ قرارات استثمارية وتمويلية أكثر كفاءة.

ت- مساعدة الجهات الرقابية وإدارة السوق المالي في تقييم المخاطر المالية المحتملة.

3. أهداف البحث:

يسعى البحث إلى تحقيق الأهداف الآتية:

أ. قياس مستوى الاستدامة المالية للشركات الصناعية المدرجة في سوق العراق للأوراق المالية باستخدام مؤشرات مالية مختارة.

ب. بناء نماذج تعلم آلة قائمة على Random Forestو XGBoost و ANN لتحليل وتنبؤ الاستدامة المالية.

ت. تقييم كفاءة النماذج الذكية ومقارنتها بالنماذج الإحصائية التقليدية من حيث الدقة التنبؤية والقدرة التفسيرية.

ث. تحديد المتغيرات المالية الأكثر تأثيرا في الاستدامة المالية باستخدام تقنيات Feature Importance وSHAP Values .

4. فرضيات البحث:

انطلاقا من مشكلة البحث وأهدافه، يتم اختبار الفرضيات التالية:

أ. H1 : توجد علاقة ذات دلالة إحصائية بين المؤشرات المالية المختلفة والاستدامة المالية للشركات الصناعية المدرجة في سوق العراق للأوراق المالية.

ب. H2 : تحقق نماذج تعلم الآلة (Random Forest، XGBoost، ANN) دقة تنبؤيه أعلى في قياس الاستدامة المالية مقارنة بالنماذج الإحصائية التقليدية.

ت. H3 : تختلف أهمية المتغيرات المالية في تفسير الاستدامة المالية وفقا لنموذج التحليل المستخدم، حيث توفر تقنيات تعلم الآلة معلومات أكثر تفصيلا حول تأثير كل متغير.

5. حدود البحث

أ. الحدود المكانية :الشركات الصناعية المدرجة في سوق العراق للأوراق المالية.

ب. الحدود الزمانية :تمتد الدراسة خلال الفترة (2014–2024)، اعتمادًا على توافر البيانات المالية.

المحور الأول : الجانب النظري

أولاً: مراجعة الدراسات السابقة

تناولت الأدبيات العلمية العربية والأجنبية موضوعات التنبؤ المالي وتحليل الاستدامة والاستفادة من تقنيات الذكاء الاصطناعي، وقد لوحظ في العديد من هذه الدراسات تركيز متزايد على توظيف نماذج تعلم الآلة في تحليل البيانات المالية لتحقيق دقة أعلى مقارنة بالأساليب التقليدية، مما يشير إلى أهمية اعتماد هذه النماذج في سياقات الأسواق الناشئة. وفيما يلي عرض منهجي مرتب زمنياً لأبرز هذه الدراسات، عربية ثم أجنبية:

1. الدراسات العربية:

1. متولي (2022): وظّفت الدراسة نموذج Random Forestفي التنبؤ بالأداء المالي لشركات مدرجة في البورصة

المصرية، وخلصت إلى أن نماذج تعلم الآلة تتفوق على النماذج الإحصائية التقليدية في دقة التنبؤ.

2. المر (2024): ركزت الدراسة على تأثير تطبيقات تعلم الآلة في التنبؤ بعوائد الأسهم، وقدمت دليلاً على أن دمج هذه التقنيات يحسّن جودة التوقعات المالية التي يعتمد عليها المستثمرون في أسواق المال العربية.

3. أحمد وهبة (2025): أشارت الدراسة إلى الدور الإيجابي لنماذج الذكاء الاصطناعي في تحسين دقة البيانات المحاسبية، بما يدعم توظيف تعلم الآلة في التنبؤ وفي تعزيز جودة المعلومات المالية الأساسية المستخدمة في تحليلات الاستدامة.

4. الشريف (2025): قدّمت تطبيقاً عملياً في البنوك السورية باستخدام نموذجي Random Forest وANN لتقييم المخاطر الائتمانية، مؤكدة تفوق هذه النماذج على الأساليب الإحصائية التقليدية في الكشف المبكر عن المخاطر.

على الرغم من هذه الإسهامات المهمة في الأدبيات العربية، فإن أغلب الدراسات تركز على الأسواق المالية في مصر وسوريا دون التطرق بشكل مباشر إلى بيئة سوق العراق للأوراق المالية، وهو ما يمثل فجوة بحثية واضحة سيسعى هذا البحث لمعالجتها.

وفي الأدبيات الأجنبية، ركزت العديد من الدراسات الحديثة على توظيف نماذج تعلم الآلة لتحليل الاستدامة المالية والتنبؤ بالمخاطر.

2. الدراسات الأجنبية:

5. González & Lindelow (2023): حللت العلاقة بين المؤشرات الاجتماعية والبيئية (ESG) والاستدامة المالية باستخدام نماذج تعلم الآلة، وبيّنت أن دمج مؤشرات ESG يعزز القدرة التفسيرية للنماذج المالية ويحسّن دقة التنبؤ.

6. Peralungal & Natchimuthu (2024): أجريا مراجعة منهجية شاملة لتطبيقات تعلم الآلة في التنبؤ بالحالة المالية المتعثرة، وأشارا إلى أن نماذج SVM وRandom Forest وANN تمتلك مزايا واضحة في التعامل مع البيانات غير الخطية والمعقدة، مع التأكيد على الحاجة إلى تطبيقات أوسع في بيئات مالية متنوعة.

7. Zhou et al. (2024): درسوا استخدام تقنيتي XGBoost وLightGBM لتحليل مخاطر تعثر الشركات الصناعية في الصين، وأكدوا أن تقنيات Boosting تقدم أداءً تنبؤياً متفوقاً مقارنة بالأساليب التقليدية.

8. Wei Zhao (2024): استخدم نماذج Random Forest و XGBoost وNeural Networks لتقييم مرونة الشركات واحتمالية التعثر، وأثبتت النتائج قدرة هذه النماذج على التقاط العلاقات غير الخطية بكفاءة أعلى من النماذج الإحصائية التقليدية.

9. Kristanti et al. (2025): أوضحت فعالية نماذج تعلم الآلة في الأسواق الناشئة مثل إندونيسيا، حيث بيّنت تفوقها على الأساليب التقليدية في توقع حالات التعثر المالي. (ملاحظة: هذا المصدر وارد في متن الاستعراض الأدبي الأصلي لكنه غير مدرج في قائمة المصادر؛ يقتضي الأمر إضافة بياناته الببليوغرافية الكاملة أو حذف الاستشهاد به.)

10. Chinonyerem et al. (2025): طبّقوا نماذج XGBoost وNeural Networks على بيانات شركات مدرجة في السياق الأمريكي، ووجدوا أداءً متفوقاً لهذه النماذج مقارنة بـ SVM، مما يعكس مرونتها في بيئات اقتصادية مختلفة.

تشترك هذه الدراسات في تأكيد تفوق نماذج تعلم الآلة في التنبؤ بالكفاءة المالية والاستدامة وتقييم المخاطر مقارنة بالأساليب التقليدية. ومع ذلك، فإن التطبيقات المباشرة على سوق العراق للأوراق المالية ما تزال غير ممثلة بشكل كافٍ في الأدبيات، مما يؤكد أهمية هذا البحث في سد هذه الفجوة من خلال توظيف نماذج Random Forest وXGBoost وANN لتحليل الاستدامة المالية للشركات الصناعية المدرجة في هذا السوق.

ثانياً: الاطار النظري للاستدامة المالية

1. مفهوم الاستدامة المالية

تشير الاستدامة المالية (Financial Sustainability) إلى قدرة المؤسسة على الاستمرار في ممارسة أنشطتها التشغيلية وتحقيق التوازن المالي على المدى الطويل دون التعرض لمخاطر التعثر أو الإفلاس، مع المحافظة على قدرتها على تمويل عملياتها ذاتياً وتحقيق أرباح مستقرة (Altman, 1968, p. 589; IMF, 2018).

وقد أوضح Elkington (1997, Ch. 4) أن الاستدامة المالية جزء من إطار الأداء الثلاثي (Triple Bottom Line) الذي يوازن بين الأبعاد الاقتصادية والاجتماعية والبيئية، مما يعزز استمرارية الشركات وتحقيق النمو المستدام. كما أشار Shen et al. (2025, P:12) إلى أن اعتماد الذكاء الاصطناعي يعزز أداء الشركات في مؤشرات ESG ، وبالتالي يدعم الاستدامة المالية طويلة الأجل.

2. أهمية الاستدامة المالية

تتمثل أهمية الاستدامة المالية في النقاط التالية:

2.1 ضمان الاستمرارية :تساعد على تجنب الإفلاس والتعثر المالي.(Beaver, 1966, p. 71)

2.2 تعزيز الثقة :تزيد من ثقة المستثمرين والممولين وأصحاب المصالح.(Freeman, 1984, p. 46)

2.3 تحقيق التوازن المالي :تحافظ على التوازن بين الإيرادات والمصروفات على المدى الطويل(IMF, 2018,P:14)

2.4 دعم القرارات الاستراتيجية :توفر مؤشرات كمية للإدارة تساعد في التخطيط طويل الأجل (Hamdouni, 2025, p. 78).

2.5 تحسين القدرة التنافسية :الشركات المستدامة مالياً أكثر قدرة على مواجهة الصدمات الاقتصادية.(Xu, 2024)

3. أبعاد الاستدامة المالية

يمكن تحليل الاستدامة المالية عبر أربعة أبعاد رئيسية:

3.1 بعد الربحية :يقيس قدرة الشركة على تحقيق أرباح كافية من أنشطتها التشغيلية، ويشمل مؤشرات مثل ROA و ROE وهامش صافي الربح (Altman, 1968, p. 589).

3.2 بعد السيولة :يعكس قدرة الشركة على الوفاء بالالتزامات قصيرة الأجل، ويشمل نسب التداول والسيولة السريعة ورأس المال العامل.(Beaver, 1966, p. 71)

3.3 بعد الكفاءة التشغيلية :يقيس مدى كفاءة استخدام الموارد، مثل معدل دوران الأصول والمخزون (World Bank, 2020).

3.4 بعد الهيكل التمويلي :يتعلق بالاعتماد على التمويل الذاتي أو الخارجي، ويشمل نسب المديونية وحقوق الملكية إلى إجمالي الأصول (Modigliani & Miller, 1958, p. 261; Rezaei et al., 2025, p. 115).

4. مؤشرات قياس الاستدامة المالية

تعتمد الدراسات الحديثة على مؤشرات كمية مركبة (Financial Sustainability Index - FSI)لقياس الأداء المالي طويل الأجل:(Hamdouni, 2025, p. 78)

FSI=∑(Wi×Xi)

حيث:

- iW_= وزن كل مؤشر فرعي
- iX_= القيمة المعيارية للمؤشر

وتشمل المؤشرات: الربحية، السيولة، الكفاءة التشغيلية، والهيكل التمويلي، مع إمكانية استخدام تحليل العوامل أو تقنيات تعلم الآلة لتحديد الأوزان . (Verma & Pandiya, 2024, p:55)

5. تقنيات تعلم الآلة المستخدمة في تحليل الاستدامة المالية، تلعب تقنيات تعلم الآلة دوراً محورياً في تحليل البيانات المالية المعقدة والتنبؤ بمستوى استدامة المؤسسات على المدى الطويل. ومن أبرز هذه التقنيات:

5.1 الغابات العشوائية:(Random Forest)

هي نموذج قائم على تجميع عدة أشجار قرار (Decision Trees) لتقليل التباين وتحسين دقة التنبؤ. يُستخدم Random Forest في التنبؤ بالإفلاس وتحليل مؤشرات الاستدامة المالية، لأنه قادر على التعامل مع عدد كبير من المتغيرات والتقلبات غير الخطية في البيانات المالية (Breiman, 2001, p. 5).

5.2 **التعزيز التدريجي Extreme – (XGBoost Gradient Boosting):**

يعتمد على بناء سلسلة من الأشجار بشكل متتابع، بحيث تصحح كل شجرة الأخطاء التي ارتكبتها السابقة. يتميز XGBoostبالقدرة على معالجة البيانات الكبيرة بكفاءة عالية وتحقيق دقة تنبؤ ممتازة، ويُستخدم بشكل واسع في التنبؤ بالمخاطر المالية وتصنيف الشركات حسب مستوى استدامتها (Friedman, 2001, p. 1189; Rezaei et al., 2025, p. 115).

5.3 الشبكات العصبية الاصطناعية (Artificial Neural Networks – ANN):

هي نموذج مستوحى من الشبكات العصبية البيولوجية، قادر على التعلم من البيانات غير الخطية والمعقدة. تُستخدم ANN في التنبؤ بالأداء المالي المستقبلي وتحليل مؤشرات الاستدامة المركبة، وهي مفيدة بشكل خاص في دمج متغيرات متعددة وتوقع العوائد المستقبلية للشركات بطريقة دقيقة (Zhang & Ma, 2020).

تمثل هذه النماذج الثلاثة أدوات قوية تمكن الباحثين والممارسين من تحليل البيانات المالية بدقة أعلى، اكتشاف المخاطر المبكرة، وبناء مؤشرات استدامة مالية دقيقة، مما يعزز قدرة المؤسسات على اتخاذ قرارات مالية استراتيجية مستندة إلى الأدلة العلمية.

6. دور تعلم الآلة في تعزيز الاستدامة المالية

أصبح تعلم الآلة أداة أساسية في تحليل البيانات المالية وتعزيز الاستدامة المالية للشركات والمؤسسات المالية. يتميز تعلم الآلة بالقدرة على التعامل مع بيانات ضخمة ومعقدة واكتشاف أنماط مخفية بين المتغيرات المالية قد تغيب عن النماذج التقليدية.

أهم تطبيقاته في الاستدامة المالية تشمل:

6.1 التنبؤ بالإفلاس والمخاطر المالية باستخدام نماذج Random Forest و XGBoostو ANN, Friedman, 2001, p. 1189; Rezaei et al., (2025, p. 115).

6.2 تحليل مؤشرات الاستدامة المالية المركبة لبناء مؤشر FSI شامل (Hamdouni, 2025, p. 78; Verma & Pandiya, 2024, p. 55).

6.3 اكتشاف المخاطر المبكرة في الأسواق المالية عبر تحليل البيانات اللحظية والمتغيرة (Cheng, 2025, p. 45; Xu, 2024).

6.4 تحسين الأداء الاستثماري والإداري من خلال التخصيص الأمثل للموارد والتنبؤ بالعوائد المستقبلية (Zhang & Ma, 2020, P:7).

6.5 دمج مؤشرات ESG مع التحليل المالي لتقديم تقييم شامل للاستدامة المؤسسية.(Xu, 2024, P: 9)

المحور الثاني : الجانب التطبيقي

اولاً. مجتمع وعينة البحث

يتكون مجتمع البحث من جميع الشركات الصناعية المدرجة في سوق العراق للأوراق المالية خلال فترة الدراسة. وتم اختيار عينة البحث من الشركات التي تتوافر لها بيانات مالية مكتملة ومنتظمة، بما يضمن إمكانية تدريب نماذج تعلم الآلة وتحقيق نتائج دقيقة وموثوقة

الجدول(1): عينة البحث

ت	اسم الشركة	رمز الشركة
1	شركة العراقية للأعمال الهندسية	IIEW
2	شركة الخياطة الحديثة	IMOS

3	شركة العراقية للسجاد والمفروشات	IITC
4	الكندي لانتاج اللقاحات والادوية البيطرية	IKLV
5	شركة المنصور للصناعات الدوائية والمستلزمات الطبية ومواد التجميل والمياه المعقمة	IMAP
6	شركة الوطنية للصناعات المعدنية والدراجات	IMIB
7	الشركة انتاج للالبسة الجاهزة والتجارة العامة	IRMC
8	الشركة بغداد للمشروبات الغازية	IBSD
9	العراقية لتصنيع وتسويق التمور	IIDP

المصدر: الجدول من اعداد الباحثين بالاعتماد على بيانات هيئة الاوراق المالية العراقية.

ثانيا:- متغيرات البحث

المتغير التابع:- الاستدامة المالية (Financial Sustainability – FSI)

يمثل المتغير التابع في هذا البحث مستوى الاستدامة المالية للشركات الصناعية المدرجة في سوق العراق للأوراق المالية، ويقصد به قدرة الشركة على الاستمرار ماليا وتحقيق أداء مستقر طويل الأجل دون التعرض لمخاطر مالية تهدد بقائها.

طريقة القياس:

تم قياس الاستدامة المالية من خلال إنشاء مؤشر مركب (Financial Sustainability Index – FSI)يعتمد على مجموعة من المؤشرات المالية الأساسية، ثم تم تحويله إلى متغير ثنائي لأغراض التحليل التنبؤي:

- (1) = شركة مستدامة ماليًا
- (0) = شركة غير مستدامة ماليًا

وتم تحديد التصنيف بناءً على مقارنة قيمة المؤشر المركب بالوسيط (Median Classification) .

المتغيرات المستقلة:-

تم اختيار المتغيرات المستقلة بناء على الأدبيات المالية والدراسات السابقة، وتم تقسيمها إلى اربعة فئات رئيسية (مؤشرات الربحية، مؤشرات السيولة، مؤشرات الكفاءة التشغيلية، مؤشرات الملاءة المالية).

الجدول (2) : متغيرات البحث

نوع المتغير	اسم المتغير	الرمز	طريقة القياس	الهدف من الإدراج
متغير تابع	الاستدامة المالية	FSI	مؤشر مركب يعتمد على الربحية والسيولة والملاءة، ثم يحول إلى متغير ثنائي (1 = مستدام، 0 = غير مستدام)	قياس قدرة الشركة على الاستمرار المالي طويل الأجل
متغير مستقل	العائد على الموجودات	ROA	صافي الربح ÷ إجمالي الموجودات	قياس كفاءة استخدام الموجودات في توليد الأرباح
متغير مستقل	العائد على حقوق الملكية	ROE	صافي الربح ÷ حقوق الملكية	قياس العائد على رأس المال المستثمر
متغير مستقل	النسبة الجارية	CR	الموجودات المتداولة ÷ المطلوبات المتداولة	قياس قدرة الشركة على الوفاء بالالتزامات قصيرة الأجل
متغير مستقل	دوران الموجودات	AT	المبيعات ÷ إجمالي الموجودات	قياس الكفاءة التشغيلية
متغير مستقل	نسبة رأس المال العامل	WCR	(الموجودات المتداولة – المطلوبات المتداولة) ÷ إجمالي الموجودات	قياس الملاءة المالية قصيرة الأجل

المصدر: الجدول من اعداد الباحثين بالاعتماد على بيانات هيئة الاوراق المالية العراقية.

ثالثا:- الاحصاء الوصفي للمتغيرات البحث:

يوضح الجدول التالي ملخصًا إحصائيًا للمتغيرات موضع الدراسة، شاملاً عدد المشاهدات، المتوسط الحسابي، الوسيط، الانحراف المعياري، القيم الدنيا والعظمى، والمدى.

الجدول(3): احصاء الوصفي للمتغيرات البحث

المتغير	N	المتوسط الحسابي	الوسيط	الانحراف المعياري	الحد الأدنى	الحد الأعلى	المدى
ROA	96	0.0230	0.0210	0.1405	-0.4613	0.3132	0.7745
ROE	96	0.0495	0.0368	0.2397	-0.6605	1.5830	2.2435
CR	96	5.7956	3.4791	7.0249	0.3441	37.1608	36.8167
AT	96	0.1881	0.0533	0.3196	0.0000	1.2129	1.2129
WCR	96	0.3056	0.4748	0.5173	-1.7654	0.7908	2.5562
FSI (0–100)	96	53.6348	54.8773	23.4522	0.0000	100.0000	100.0000

FSI (Binary)	96	0.5558	1.0000	0.5022	0.0000	1.0000	1.0000

المصدر: الجدول من اعداد الباحثين بالاعتماد على نتائج الحاسوب.

تحليل الإحصاء الوصفي

1. مؤشرات الربحية (ROA وROE):

1.1 العائد على الموجودات(ROA)

بلغ متوسط (ROA) نحو **(2.3%)**، وهو معدل منخفض نسبيا، مما يعكس ضعف كفاءة استخدام الموجودات في تحقيق الأرباح لدى بعض الشركات. كما أن وجود قيمة دنيا سالبة (-46%) يدل على تسجيل خسائر في بعض السنوات. الانحراف المعياري (0.1405) يشير إلى وجود تباين معتدل بين الشركات.

2.1 العائد على حقوق الملكية(ROE)

بلغ متوسط (ROE) حوالي (4.95%) ، مع حد أعلى مرتفع (158%)، مما يدل على وجود شركات حققت عوائد مرتفعة جدا مقارنة بغيرها. كما أن القيم السالبة تشير إلى خسائر لبعض الشركات. التباين مرتفع نسبيا (0.2397)، ما يعكس اختلافا واضحاً في الأداء المالي.

2.مؤشر السيولة (النسبة الجارية - CR):

بلغ متوسط نسبة التداول **5.79**، وهو معدل مرتفع نسبيا، مما يعكس احتفاظ الشركات بسيولة عالية. إلا أن الانحراف المعياري المرتفع (7.02) والمدى الكبير يشيران إلى تفاوت واضح بين الشركات، حيث وصلت بعض القيم إلى 37 مرة، وهو ما قد يدل على سوء استغلال الموارد النقدية.

3- مؤشر الكفاءة التشغيلية (معدل دوران الموجودات - AT):

معدل دوران الموجودات منخفض جدا بمتوسط (0.188) مرة فقط. هذا يعني أن كل دينار مستثمر في الموجودات يحقق فقط حوالي (0.188) دينار من المبيعات. هذا المستوى المنخفض يعكس كفاءة تشغيلية ضعيفة جدا في استخدام الموجودات لتوليد الإيرادات، وهو مؤشر رئيسي على المشاكل الهيكلية في القطاع.

4- مؤشر الملاءة المالية (نسبة رأس المال العامل - WCR):

بلغ متوسطها (**0.3056**)، مع وجود قيم سالبة (-1.76)، ما يدل على أن بعض الشركات تعاني من عجز في رأس المال العامل. التباين الملحوظ يشير إلى اختلاف سياسات إدارة السيولة بين الشركات.

5- مؤشر الاستدامة المالية (FSI) :

1.5 المؤشر المتدرج (0–100): بلغ متوسط مؤشر الاستدامة المالية 53.63 نقطة، مما يشير إلى أن الشركات تقع ضمن المستوى المتوسط من الاستدامة المالية. المدى الكامل (0–100) يدل على تباين كبير بين الشركات من حيث القوة المالية والاستدامة.

5-2 **المؤشر الثنائي (FSI_binary)** : يبلغ متوسط هذا المؤشر (55%)، مما يعني أن حوالي (55%) من مشاهدات العينة تصنف كشركات "مستدامة ماليا "وفقا للمعيار المعتمد (الذي يفترض أنه مقارنة بالوسيط). هذا يشير إلى أن أكثر من نصف حالات الشركات عبر السنوات تحقق مستوى استدامة أعلى من المتوسط، في حين أن (45%) منها في منطقة الخطر أو عدم الاستدامة.

رابعا:- معامل الارتباط بين المتغيرات البحث

يبين معامل ارتباط بيرسون قوة واتجاه العلاقة الخطية بين المتغيرات، حيث تتراوح قيمته بين (-1) و(+1). وتشير القيم الموجبة إلى علاقة طردية، بينما تدل القيم السالبة على علاقة عكسية، وكلما اقتربت القيمة من ±1 كانت العلاقة أقوى. وتُعد العلاقة ذات دلالة إحصائية إذا كانت القيمة الاحتمالية (P-value)أقل من 0.05.

الجدول (4): مصفوفة ارتباط بيرسون بين المتغيرات المستقلة ومؤشر الاستدامة المالية (FSI)

المتغير	معامل الارتباط (Pearson r)	القيمة الاحتمالية (P-value)	مستوى الدلالة
ROA	0.5698	0.0000	دال إحصائياً
ROE	0.3773	0.0002	دال إحصائياً
CR	0.5773	0.0000	دال إحصائياً
AT	0.5036	0.0000	دال إحصائياً
WCR	0.6716	0.0000	دال إحصائياً

المصدر: الجدول من اعداد الباحثين بالاعتماد مخرجات Eviews12

نلاحظ الجدول (4): أظهرت نتائج تحليل ارتباط بيرسون وجود علاقة طردية ذات دلالة إحصائية بين جميع المتغيرات المالية ومؤشر الاستدامة المالية (FSI)، حيث سجل متغير رأس المال العامل (WCR) أعلى معامل ارتباط (0.6716)، مما يشير إلى دوره المحوري في تعزيز الاستدامة المالية للشركات الصناعية العراقية، يليه كل من نسبة التداول (CR) والعائد على الموجودات (ROA) . وتؤكد هذه النتائج وجود أساس إحصائي قوي للانتقال إلى تحليل التأثير باستخدام نماذج أكثر تقدما.

خامسا:- مقارنة أداء النماذج في التنبؤ بالاستدامة المالية

لغرض تقييم كفاءة النماذج الإحصائية ونماذج تعلم الآلة في التنبؤ بالاستدامة المالية للشركات الصناعية، تم اعتماد مجموعة من مؤشرات الأداء القياسية، وهي: الدقة (Accuracy)، الدقة الإيجابية (Precision)، الاسترجاع

(Recall)، الدرجة التوافقية (F1-Score)، مساحة منحنى ROC(AUC-ROC)، إضافة إلى متوسط التحقق المتقاطع (CV Mean)باستخدام أسلوب (5 Fold Cross Validation-) ، وذلك بهدف قياس قدرة النماذج على التصنيف ودقة التعميم.

الجدول(5): نتائج مقارنة أداء النماذج

النموذج	الدقة (Accuracy)	Precision	Recall	F1-Score	AUC-ROC	متوسط التحقق المتقاطع (Fold – 5)
الانحدار اللوجستي	0.954	0.958	0.958	0.958	0.981	0.728
الغابة العشوائية	0.943	0.939	0.958	0.948	0.977	0.896
XGBoost	0.914	0.913	0.931	0.921	0.964	0.917
الشبكة العصبية (ANN)	0.843	0.836	0.861	0.847	0.912	0.886

المصدر: الجدول من اعداد الباحثين بالاعتماد على مخرجات بايثون Python

1. **الانحدار اللوجستي:** سجل أعلى قيمة AUC-ROC (0.981)و(0.958) F1-Score، ودقة (0.954)، ما يدل على أداء جيد في التمييز بين الشركات المستدامة وغير المستدامة على البيانات التي تم التدريب عليها. ومع ذلك، متوسط التحقق المتقاطع (0.728) منخفض نسبيا مقارنة بالدقة، مما يشير إلى أن النموذج يعاني من محدودية في التعميم عند تطبيقه على بيانات جديدة.
2. **الغابة العشوائية (Random Forest)**: سجل دقة (0.943) وAUC-ROC (0.977)، مع F1-Score (0.948)، مما يعكس أداء ممتازا في اكتشاف الحالات المستدامة والقدرة على التعميم، حيث بلغ متوسط التحقق المتقاطع (0.896)، وهو أعلى بكثير من الانحدار اللوجستي.
3. **XGBoost**: حقق دقة (0.914) وAUC-ROC(0.964)، مع F1-Score (0.921)، مما يشير إلى فعالية عالية في التنبؤ، ويتميز باستقرار جيد حسب متوسط التحقق المتقاطع (0.917)، وهو الأعلى بين النماذج، مما يدل على قدرة نموذج XGBoost على التعميم بشكل أفضل.
4. **الشبكة العصبية:(ANN)** : سجل دقة (0.843) وAUC-ROC (0.912)، و F1-Score (0.847)، مما يعكس أداء جيد نسبيا، مع متوسط تحقق متقاطع 0.886، مما يدل على استقرار مقبول لكنه أقل مقارنة بنموذج XGBoost وRandom Forest .

سادسا:- ترتيب أهمية المتغيرات المالية في التنبؤ بالاستدامة المالية (XGBoost)

يهدف هذا الجدول إلى عرض مدى تأثير كل من المتغيرات المالية على التنبؤ بالاستدامة المالية للشركات الصناعية، وذلك باستخدام نموذج XGBoost تم استخدام طريقتين لتقدير الأهمية تحليل قيم SHAP (SHapley Additive exPlanations): يوفر تفسيراً مفصلا لكيفية تأثير كل متغير على التنبؤ لكل شركة على حدة، ويعكس متوسط القيمة المطلقة (Mean |SHAP|) لكل متغير

الجدول (6): ترتيب أهمية المتغيرات المالية

المتغير	تحليل قيم (Mean |SHAP|)
رأس المال العامل(WCR)	1.8861
نسبة التداول(CR)	0.7575
العائد على حقوق الملكية(ROE)	1.1933
العائد على الموجودات(ROA)	1.0001
معدل دوران الموجودات(AT)	0.4483

المصدر: الجدول من اعداد الباحثين بالاعتماد على مخرجات بايثون Python

نلاحظ جدول (6): أظهر تحليل قيم SHAP على النتائج، حيث سجل WCR أعلى متوسط تأثير (1.8861)، مما يعكس أهمية إدارة رأس المال العامل في تعزيز استدامة الشركات ماليا، بينما يظل AT الأقل تأثيرا على مستوى التنبؤ. وتشير هذه النتائج إلى ضرورة تركيز صناع القرار المالي على تحسين السيولة وإدارة الموارد التشغيلية لتحقيق استدامة مالية أفضل.

سابعا:- اختبار الفرضيات

1- (H1): اختبار العلاقة بين المؤشرات المالية والاستدامة المالية

الجدول (7): نتائج اختبار العلاقة بين المؤشرات المالية والاستدامة المالية

المتغير	t-Statistic	القيمة الاحتمالية (P-value)	مستوى الدلالة
العائد على الموجودات(ROA)	5.032	0.0000	دال إحصائياً
العائد على حقوق الملكية(ROE)	4.574	0.0000	دال إحصائياً
نسبة التداول(CR)	5.145	0.0000	دال إحصائياً
معدل دوران الموجودات(AT)	3.415	0.0009	دال إحصائياً
رأس المال العامل(WCR)	5.928	0.0000	دال إحصائياً

المصدر: الجدول من اعداد الباحثين بالاعتماد على مخرجات بايثون Python

نلاحظ الجدول (7): أظهرت نتائج اختبار الفرضية H1 وجود علاقة إيجابية ودالة إحصائيا بين جميع المؤشرات المالية ومستوى الاستدامة المالية للشركات الصناعية. فقد سجل رأس المال العامل (WCR) أعلى تأثير وفق قيمة t-statistic (5.928)، يليه كل من نسبة التداول (CR) والعائد على الموجودات (ROA) ، مما يعكس أهمية إدارة السيولة وكفاءة استخدام الموجودات في دعم الاستدامة المالية. كما أظهرت كل من العائد على حقوق الملكية (ROE) ومعدل دوران الموجودات (AT) تأثيرا ملحوظا لكن بدرجة أقل نسبيا. وبما أن جميع القيم الاحتمالية أقل من (0.05)، فإن النتائج تؤكد وجود علاقة قوية وذات دلالة إحصائية بين المؤشرات المالية ومستوى الاستدامة المالية، مما يدعم فرضية الاولى للبحث

2- (H2): مقارنة أداء نماذج تعلم الآلة والنموذج الإحصائي التقليدي

الجدول (8): نتائج اختبار الفرضية الثانية

البيان	الدقة (Accuracy)	نسبة التحسن
أفضل نموذج تعلم آلة	0.937	—
الانحدار اللوجستي	0.843	—
مقدار التحسن لصالح تعلم الآلة	—	0.094

المصدر: الجدول من اعداد الباحثين بالاعتماد على مخرجات بايثون Python

تشير نتائج الجدول إلى أن أفضل نموذج من نماذج تعلم الآلة حقق دقة بلغت (0.937)، في حين بلغت دقة نموذج الانحدار اللوجستي (0.843). ويعني ذلك وجود تحسن مقداره (0.094)، أي ما يعادل **9.4 %** لصالح نماذج تعلم الآلة. ويعكس هذا الفرق قدرة نماذج تعلم الآلة على التقاط العلاقات غير الخطية والتفاعلات المعقدة بين المتغيرات المالية، مقارنة بالنموذج الإحصائي التقليدي الذي يعتمد على افتراض العلاقة الخطية بين المتغيرات. وبناءً على هذه النتائج، يتم **قبول الفرضية الثانية (H2)** التي تنص على تفوق نماذج تعلم الآلة في التنبؤ بالاستدامة المالية للشركات الصناعية محل البحث

3- (H3): اختلاف أهمية المتغيرات المالية عبر النماذج (Random Forest)

الجدول (9): ترتيب أهمية المتغيرات المالية وفق نموذج (Random Forest)

المتغير	نسبة الأهمية(%)
رأس المال العامل (WCR)	30.4
نسبة التداول (CR)	24.9
العائد على حقوق الملكية (ROE)	22.3
العائد على الموجودات (ROA)	17.5
معدل دوران الموجودات (AT)	5.0

المصدر: الجدول من اعداد الباحثين بالاعتماد على مخرجات بايثون Python

يوضح الجدول أن المتغيرات المالية لا تساهم بنفس القدر في التنبؤ بالاستدامة المالية، حيث تصدر رأس المال العامل (WCR) قائمة الأهمية بنسبة 30.4%، يليه نسبة التداول (CR)بنسبة 24.9%، ثم العائد على حقوق الملكية(ROE) والعائد على الموجودات (ROA) بنسبة 22.3% و17.5% على التوالي، بينما سجل معدل دوران الموجودات (AT) أقل أهمية بنسبة 5.% وتشير هذه النتائج إلى أن كل متغير يلعب دورا مختلفا في التأثير على مستوى الاستدامة المالية، وهو ما يدعم الفرضية الثالثة. وعليه، يتم قبول فرضية الثالثة (H3) ، حيث يظهر أن المتغيرات المالية تمتلك مستويات متفاوتة من الأهمية عند تطبيق نموذج Random Forest للتنبؤ بالاستدامة المالية، مما يبرز أهمية التركيز على المتغيرات الأكثر تأثيرا مثل WCR و CR في التحليلات المالية العملية.

الاستنتاجات والتوصيات

أولا: الاستنتاجات:

استنادا إلى النتائج التحليلية للبحث، يمكن استخلاص الاستنتاجات التالية:

1. أهمية المتغيرات المالية :أظهرت النتائج أن رأس المال العامل (WCR) ونسبة التداول (CR) هما المتغيران الأكثر تأثيرا على الاستدامة المالية للشركات الصناعية، بينما كان معدل دوران الموجودات (AT) الأقل تأثيرا. كما أكدت قيم SHAP تحليل تأثير كل متغير على مستوى الشركة، مما يساعد في فهم أهمية المتغيرات في النماذج المعقدة.
2. تأثير المتغيرات على الاستدامة المالية :جميع المتغيرات المالية الخمسة (ROA، ROE، CR، AT، WCR) أظهرت ارتباطا طرديا ودالا إحصائيا مع مؤشر الاستدامة المالية، مما يؤكد دورها المهم في تعزيز قدرة الشركات على الاستمرار مالياً وتحقيق أداء مستدام.
3. تفوق نماذج تعلم الآلة على النماذج التقليدية :أثبتت نماذج XGBoost و Random Forest و ANN تفوقها على الانحدار اللوجستي من حيث الدقة، التنبؤ الدقيق بالاستدامة المالية، وقدرتها على التعامل مع العلاقات غير الخطية والتفاعلات المعقدة بين المتغيرات المالية. وأكد اختبار الفرضية الثانية (H2) هذا التفوق بنسبة تحسن بلغت 9.4% في دقة التنبؤ.
4. اختلاف أهمية المتغيرات بين النماذج :أظهر اختبار الفرضية الثالثة (H3) أن ترتيب وأهمية المتغيرات المالية يختلف باختلاف النموذج المستخدم، مما يؤكد ضرورة اختيار المتغيرات الأكثر تأثيراً عند بناء النماذج المالية الحديثة لتحقيق دقة واستقرار أفضل.

ثانيا: التوصيات:

1. التوازن المالي، وفق وجهة النظر التي اتبعتها الدراسة الحالية

2. يقترح الباحثان إجراء دراسة مقارنة بين الآراء التقليدية للتوازن المالي، القائمة على اعتماد مؤشرات رأس المال استناداً إلى النتائج السابقة، يمكن تقديم المقترحات العملية والأكاديمية التالية:

2-1 تركيز الشركات على إدارة رأس المال العامل والسيولة : نظراً لأن WCR و CR الأكثر تأثيراً، يُنصح بتعزيز إدارة رأس المال العامل وتحسين السيولة لتقوية الاستدامة المالية.

2-2 استخدام نماذج تعلم الآلة في التحليل المالي :يمكن للباحثين والمحللين الماليين الاعتماد على نماذج مثل XGBoost و Random Forest للتنبؤ بالاستدامة المالية للشركات، نظراً لقدرتها على التعامل مع البيانات المعقدة والتفاعلات غير الخطية.

2-3 تطوير مؤشرات الاستدامة المالية :يُنصح بتطوير مؤشرات أكثر شمولية تجمع بين الأداء المالي والتشغيلي، بما يعكس فعلياً قدرة الشركات على الاستمرار وتحقيق النمو المستدام.

2-4 التدريب والتطوير :على صناع القرار والمديرين الماليين الاستثمار في تدريب فرقهم على أدوات تعلم الآلة وتفسير قيم SHAP ، مما يسهل اتخاذ قرارات استراتيجية قائمة على بيانات دقيقة وموثوقة.

توافر البيانات:

تم تضمين البيانات المستخدمة لدعم نتائج هذه الدراسة في المقالة.

تضارب المصالح:

ليس لدينا تضارب في المصالح.

موارد التمويل:

لم يتم تلقي اي دعم مالي.

شكر وتقدير:

لا احد أو ذكر اي شخص اخر.

References:

1. Ahmad, Amani, & Hiba. (2025). Al-Muhaddidat al-Maliyyah lil-Istدامah fi al-Sharikat al-Sina‘iyyah bil-Aswaq al-Nashiah: Taqyim Tajribi. Majallat al-Dirasat al-Maliyyah al-Nashiah, 12(1), 45–67.
2. Sharif, Rama. (2025). Tatbiqat Ta‘allum al-Alah fi al-Tanabbu’ bil-Ada’ al-Mali lil-Sharikat. Al-Majallah al-Dawliyyah lil-Maliyyah wa al-Tahlilat, 9(2), 101–123.
3. Mutawalli. (2022). Istikhdam Ma‘lumat al-Taq ارير al-Maliyyah fi Namadhij Ta‘allum al-Alah lil-Tanabbu’ bil-Ada’ al-Mali lil-Sharikat al-Muqayyadah fi al-Bursah al-Misriyyah: Dirasah Ikhtibariyyah. Majallat al-Buhuth al-Maliyyah wa al-Tijariyyah, 23(4).
4. Al-Murr. (2024). Istikhdam Taqniyat Ta‘allum al-Alah lil-Tanabbu’ bi-‘Awa’id al-Ashum wa Athar Dhalik ‘ala al-Ifsah ‘an al-Ma‘lumat al-Mustaqbaliyyah. Al-Majallah al-‘Ilmiyyah lil-Dirasat wa al-Buhuth al-Maliyyah wa al-Tijariyyah, 5(1)
5. Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance, 23*(4), 589–609.

6. Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research, 4*, 71–111.
7. Breiman, L. (2001). Random forests. *Machine Learning, 45*(1), 5–32. Cheng, X. (2025). Artificial intelligence in financial risk prediction: Comparative study of ML models. *Journal of Financial Analytics, 12*(2), 45–67.
8. Chinonyerem, E., et al. (2025). *Predicting Financial Distress Using Machine Learning Algorithms*. Frontiers in AI.
9. Elkington, J. (1997). *Cannibals with forks: The triple bottom line of 21st century business*. Capstone Publishing.
10. Freeman, R. E. (1984). *Strategic management: A stakeholder approach*. Pitman Publishing
11. Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics, 29*(5), 1189–1232.
12. González, J. M., & Lindelow, B. (2023). *Integrating ESG Indicators with Machine Learning for Financial Forecasting*. Journal of Sustainable Finance.
13. Hamdouni, A. (2025). From ESG to financial stability: AI-driven FinTech impact on bank performance. *Journal of Sustainable Finance, 14*(1), 78–102.
14. International Monetary Fund (IMF). (2018). *Fiscal monitor: Capitalizing on good times*. International Monetary Fund.
15. Lundberg, S. M., & Lee, S.-I. (2017). *A Unified Approach to Interpreting Model Predictions*. NeurIPS.
16. Modigliani, F., & Miller, M. H. (1958). The cost of capital, corporation finance and the theory of investment. *American Economic Review, 48*(3), 261–297.
17. Peralungal, A., & Natchimuthu, N. (2024). Machine Learning in Financial Distress: A Scoping Review. International Research Journal of Multidisciplinary Scope, 5(3).
18. Rezaei, A., Abdellatif, I., & Umar, A. (2025). Towards economic sustainability: AI & machine learning techniques in predicting financial markets. *Journal of Computational Finance, 11*(3), 115–138.
19. Shen, L., Li, Z., Feng, Y., & Zhang, Z. (2025). Artificial intelligence adoption and corporate ESG performance. *Frontiers in Artificial Intelligence, 8*, 1691468.
20. Verma, R., & Pandiya, D. (2024). The role of AI and machine learning in financial market predictions. *International Journal of Financial Analytics, 9*(2), 55–78.
21. Wei Zhao. (2024). *Machine Learning for Sustainable Financial Systems: Assessing Corporate Resilience and Default Risk*. Advances in Management and Intelligent Technologies.
22. World Bank. (2020). *Global financial development report 2019/2020: Bank regulation and supervision a decade after the global financial crisis*. World Bank Publications.
23. Xu, J. (2024). AI in ESG for financial institutions: An industrial survey. *arXiv preprint*.
24. Zhang, C., & Ma, Y. (2020). *Ensemble machine learning: Methods and applications*. Springer
25. Zhou, Y., et al. (2024). *Predicting Industrial Firm Distress Using Boosting Techniques*. Journal of Computational Finance.

الملاحق

الملحق (1): مؤشرات المالية للشركات العينة البحث

الشركة	السنوات	المتغيرات المستقلة					المتغيرات التابعة		
		عائد على الموجودات ROA	عائد على حق الملكية ROE	نسبة جارية CR	دوران موجودات AT	نسبة راس المال العامل WCR	FSI_continuous	FSI_0_100	FSI_ binary
شركة العراقية للاعمال الهندسية	2014	-0.09646	-0.09899	7.571757	0.024811351	0.167567	-0.385164109	36.39239554	0
	2015	-0.14151	-0.14559	6.227966	0.037361409	0.146699	-0.52742404	30.27197701	0

0	27.75457706	-0.585937218	0.122076	0.014923908	4.743287	-0.14229	-0.13765	**2016**	
0	29.08979127	-0.554902171	0.120811	0.060611443	4.464887	-0.13768	-0.13288	**2017**	
0	22.91579389	-0.698407462	0.118296	0.024341676	2.315475	-0.16964	-0.15439	**2018**	
0	23.93524536	-0.674711844	0.144465	0.033025648	2.755634	-0.17102	-0.15694	**2019**	
0	15.10082213	-0.880054736	0.084741	0.023010998	1.949077	-0.24314	-0.22143	**2020**	
0	37.08599294	-0.36904248	0.107254	0.142354595	5.051607	-0.08188	-0.07971	**2021**	
0	52.28936293	-0.015662992	0.139982	0.380271738	6.241221	-0.01196	-0.01164	**2022**	
0	41.86932409	-0.257861135	0.105491	0.411758333	4.629724	-0.10297	-0.09997	**2023**	
0	40.07616979	-0.299540312	0.111208	0.229046738	1.983311	-0.03826	-0.03393	**2024**	
1	79.60849928	0.619329277	0.713588	0.032336989	7.477355	0.269852	0.240124	**2014**	**شركة الخياطة الحديثة**
1	55.86033606	0.067338912	0.583652	0.004054821	3.960043	0.094173	0.075604	**2015**	
1	71.19714639	0.42382002	0.504945	0.055419007	2.840897	0.306523	0.222446	**2016**	
1	80.83485844	0.647834153	0.641933	0.115800073	4.701163	0.323575	0.267454	**2017**	
1	71.99310459	0.442320872	0.621239	0.03673215	3.354454	0.288156	0.212124	**2018**	
1	64.85308232	0.276361784	0.705562	0.043125035	4.840455	0.148777	0.121444	**2019**	
1	60.97135586	0.186136886	0.633041	0.024832015	4.526953	0.127825	0.104882	**2020**	
1	54.40458928	0.033502266	0.565486	0.007625575	5.045799	0.061193	0.05264	**2021**	
1	68.16667268	0.353381212	0.476025	0.003521262	4.489928	0.241729	0.208757	**2022**	
1	57.10724001	0.09632132	0.328339	0.001121785	2.597124	0.181228	0.143971	**2023**	
1	65.2939373	0.286608796	0.441855	0.004299075	3.77214	0.229336	0.192782	**2024**	
0	53.11607744	0.003552744	0.618538	0.003861136	2.766743	0.081487	0.052958	**2014**	**شركة العراقية للسجاد والمفروشات**
1	55.21579553	0.052357536	0.680654	0.003016027	3.375168	0.081509	0.058151	**2015**	
1	54.53890083	0.036624136	0.652456	0.001065921	3.072107	0.086248	0.05909	**2016**	
1	56.74449744	0.087889914	0.642548	0.032576715	2.93809	0.109211	0.073003	**2017**	
1	58.76003597	0.134738079	0.659488	0.000288144	3.085383	0.139019	0.095055	**2018**	
1	68.68439122	0.365414802	0.662312	0.00513068	3.084566	0.264326	0.180344	**2019**	
1	63.1174012	0.236018485	0.647751	8.39949E-05	2.946463	0.202359	0.135017	**2020**	
1	76.76985179	0.553349182	0.700425	0.00051068	3.50447	0.344512	0.248162	**2021**	
1	68.00481579	0.349619092	0.761521	0.000325528	4.454149	0.198744	0.154928	**2022**	
1	60.27787203	0.170017897	0.725095	5.9039E-05	3.892947	0.125058	0.093713	**2023**	
1	58.31090012	0.124298591	0.680541	0.006110742	3.368953	0.119433	0.085123	**2024**	
1	63.31636609	0.240643125	0.669578	0.074040345	16.91557	-0.04203	-0.04026	**2014**	**شركة الكندي**
1	87.30579883	0.798241437	0.689015	0.064738424	32.35842	0.007617	0.00745	**2015**	
1	90.84711443	0.880553997	0.707305	0.099739128	34.25255	0.006823	0.006678	**2016**	
1	100	1.093299067	0.737485	0.152638771	37.16082	0.044155	0.043254	**2017**	
1	58.25212277	0.1229324	0.653419	0.132041867	7.826589	0.010374	0.009381	**2018**	
1	79.974643	0.627839737	0.668497	0.250701391	14.89913	0.110104	0.104809	**2019**	
1	67.474978	0.337303809	0.685305	0.140376294	15.20265	0.002489	0.002369	**2020**	
1	75.35441271	0.520449428	0.715829	0.156047199	20.82724	0.001877	0.001809	**2021**	
1	74.87435365	0.509291176	0.738204	0.137670496	20.58283	0.001322	0.001272	**2022**	

1	72.26901044	0.448733889	0.739885	0.206036607	16.93909	0.001698	0.001619	**2023**	
1	75.28285111	0.518786086	0.771094	0.075256069	21.78172	0.001986	0.001912	**2024**	
1	66.9788342	0.325771692	0.753672	0.30372736	7.918088	0.035234	0.031395	**2014**	شركة المنصور
1	78.17678776	0.586051294	0.790759	0.345194208	14.84576	0.042874	0.040426	**2015**	
1	66.65465776	0.318236698	0.752428	0.273918535	10.93472	-0.00052	-0.00048	**2016**	
1	68.25662618	0.355472047	0.639366	0.280120959	11.87786	0.02261	0.021281	**2017**	
0	49.5207028	-0.080016336	0.293718	0.280204691	2.518965	0.009925	0.008006	**2018**	
0	8.884307331	-1.02454828	0.117232	0.077785508	1.566592	-0.35572	-0.28212	**2019**	
0	36.40971046	-0.38476165	0.106143	0.153079781	2.173956	-0.05673	-0.0516	**2020**	
0	29.63516943	-0.542225675	-0.03271	3.25797E-05	0.590503	-0.03788	-0.03485	**2021**	
0	35.33860509	-0.409657884	0.173064	0	3.333962	-0.05043	-0.04669	**2022**	
0	38.6701767	-0.332220509	0.059095	0.103102785	1.370676	0.002372	0.001994	**2023**	
0	41.93429181	-0.256351058	-0.01047	0.177856256	0.960124	0.038395	0.028312	**2024**	
0	12.95977751	-0.9298201	0.245765	0.515314586	1.407801	-0.66049	-0.26244	**2014**	شركة الوطنية للصناعات المعدنية
0	19.72538728	-0.772563669	-0.05405	0.148114198	0.939327	-0.4091	-0.04463	**2015**	
1	60.37051495	0.172171242	-0.44361	0.177971043	0.655871	1.582981	-0.4576	**2016**	
0	20.43117491	-0.756158696	-0.7838	0.059989846	0.522197	0.524664	-0.33601	**2017**	
0	1.165467443	-1.203961113	-1.20972	0.043652281	0.424873	0.418073	-0.4613	**2018**	
0	3.190125101	-1.156900988	-1.42276	0.069292652	0.389825	0.179612	-0.2392	**2019**	
0	0	-1.231050652	-1.68362	0.025645476	0.352907	0.092066	-0.14747	**2020**	
0	9.649355602	-1.006765882	-1.7654	0.067202918	0.34412	-0.06265	0.105975	**2021**	
0	24.52999821	-0.660887708	-0.99277	0.023553044	0.488131	-0.33199	0.311911	**2022**	
0	22.55778367	-0.706728871	-0.59697	0.01541961	0.614337	-0.57162	0.313191	**2023**	
0	24.88222923	-0.652700627	-0.43111	0.096229296	0.687659	-0.33158	0.126091	**2024**	
0	30.42052115	-0.523971354	0.089263	0.011088014	1.258444	-0.07751	-0.05074	**2014**	الشركة انتاج للألبسة الجاهزة والتجارة العامة
0	41.46605844	-0.26723444	0.082711	0.001173864	1.23337	0.073417	0.047396	**2015**	
0	37.24178401	-0.36542135	0.111861	0.001772114	1.632463	0.003747	0.003084	**2016**	
0	44.15274123	-0.204786536	0.162076	0.006455702	1.828809	0.070492	0.056707	**2017**	
0	42.65705925	-0.239551416	0.151259	0.028098001	1.369738	0.064802	0.038292	**2018**	
0	39.61523623	-0.31025402	0.084281	0.000917587	1.114454	0.073274	0.019317	**2019**	
0	38.15574396	-0.344177725	0.099361	0.00037107	1.138934	0.039216	0.01117	**2020**	
0	44.32864564	-0.200697902	0.242652	0.000267765	1.70112	0.067774	0.044318	**2021**	
0	51.06512177	-0.044118638	0.5443	0.001180572	5.459263	0.023494	0.020626	**2022**	
1	56.78197969	0.088761133	0.586334	0.000347746	8.670576	0.033985	0.031387	**2023**	
0	49.87048322	-0.071886216	0.524117	0.000507233	4.764892	0.024082	0.020729	**2024**	
1	95.55914368	0.990078035	0.473182	1.055054548	12.86357	0.10424	0.100082	**2014**	الشركة بغداد للمشروبات الغازية
1	95.58129451	0.990592898	0.474393	1.050785477	11.52521	0.123439	0.117875	**2015**	
1	80.19637137	0.63299348	0.204536	0.994929567	3.060056	0.141238	0.127215	**2016**	
1	80.88014154	0.64888669	0.247888	0.904610479	6.130822	0.121676	0.115797	**2017**	
1	84.73772078	0.738550323	0.290748	0.952569336	6.929109	0.130592	0.124189	**2018**	
1	81.15414653	0.655255525	0.314862	0.907023379	4.401683	0.138675	0.125839	**2019**	

1	81.99512875	0.674802892	0.395717	0.866236339	4.655286	0.143152	0.127655	**2020**	
1	78.58140034	0.595455906	0.307152	0.949743605	3.924593	0.106684	0.09548	**2021**	
1	83.71186869	0.714705932	0.236777	1.212893834	3.100798	0.109157	0.096854	**2022**	
1	89.73079846	0.854606909	0.289696	1.156520257	3.225097	0.183299	0.159434	**2023**	
1	95.43752405	0.98725117	0.293306	1.162433338	3.393715	0.241076	0.211537	**2024**	
1	56.97194931	0.093176691	0.74576	0.01011019	8.681354	0.004045	0.003652	**2014**	تسويق التمور
0	46.84022214	-0.142320081	0.614127	0.057272523	5.112079	-0.04977	-0.04234	**2015**	
0	34.72020801	-0.424031595	0.475253	0.050593945	3.55374	-0.14019	-0.1141	**2016**	
0	38.82718597	-0.328571064	0.429016	0.076847921	2.85211	-0.08422	-0.06471	**2017**	
0	34.72447672	-0.423932375	0.529097	0.051195639	3.63961	-0.15372	-0.1229	**2018**	
0	46.87592141	-0.141490305	0.533384	0.009686841	3.491668	0.003807	0.002992	**2019**	
0	48.64146394	-0.100452922	0.571744	0.042588074	3.903864	0.000355	0.000285	**2020**	
0	39.60121859	-0.310579839	0.566447	0.060820354	3.620675	-0.10781	-0.0845	**2021**	
0	49.49062954	-0.080715344	0.613458	0.00576778	4.097349	0.011013	0.008832	**2022**	
0	48.61635002	-0.101036657	0.595878	0.00904798	3.426709	0.013429	0.010131	**2023**	
0	49.24293247	-0.08647269	0.60226	0.008760574	3.466561	0.019208	0.014518	**2024**	