Comprehensive Journal of Science
Volume (10), Issue (37), (NOV. 2025)
SICST2025, www.sicst.ly
ISSN: 3014-6266

مجلة العلوم الشاملة
عدد خاص بالمؤتمر الدولي الثالث للعلوم والتقنية
المجلد (10)، العدد (37)، (نوفمبر2025)
ردمد: 3014-6266

# تقييم المقاربات الكلاسيكية مقابل مقاربات لغة التعلّم الآلي (الذكاء الاصطناعي) في قياس شدة الضائقة المالية في المصارف أدلة (تقارير مالية) من مصرف الجمهورية ليبيا (2018–2022)

**زياد معيوف[1]، عبدالرؤوف السني[2]، محمد العجيلي[3]، أكرم ابوصاع[4]**

[1] المحاسبة، المعهد العالي للعلوم والتقنية سوق الجمعة، طرابلس، ليبيا

[2] القسم، المعهد العالي للعلوم والتقنية يفرن، يفرن، ليبيا

[3] القسم، المعهد العالي للعلوم والتقنية يفرن، يفرن، ليبيا

[4] تقنية المعلومات، المعهد العالي للعلوم والتقنية يفرن، يفرن، ليبيا

[*] البريد الإلكتروني (للباحث المرجعي):shehaby232@gmail.com

# Evaluating classical approaches versus machine learning (artificial intelligence) approaches in measuring the severity of financial distress in banks. Evidence (financial reports) from the ALJUMHOURIA BANK of Libya (2018-2022)

**Ziyad Maeyouf [1], Abdul Raouf Al-Sunni [2], Mohammed Al-Ajili[3], Akram Abu Sa'a[4]**

[1] Accounting, Higher Institute of Science and Technology, Souk Al-Juma, Tripoli, Libya

[2] Accounting t, Higher Institute of Science and Technology, Yafran, Yafran, Libya

[3] Information Technology, Higher Institute of Science and Technology, Yafran, Yafran, Libya

[4] Information Technology, Higher Institute of Science and Technology, Yafran, Yafran, Libya

Received: 30-09-2025; Revised: 10-10-2025; Accepted: 31-10-2025; Published: 25-11-2025

الملخص:

تُعد الصحة المالية للقطاع المصرفي ضرورية لمرونة الاقتصاد، خاصة في الاقتصادات الهشة مثل ليبيا. مصرف الجمهورية، وهو أكبر ممول حكومي في البلاد، يمثل ركناً أساسياً للاقتصاد الليبي، وقد عانى من مشاكل مزمنة في العقد الماضي. تؤكد نماذج التنبؤ بالضائقة التقليدية، مثل درجة Z–ألتمان، على وجود ضعف مزمن ولكنها غير فعالة في تحديد

الشدة عندما تقع جميع الحالات في منطقة الضائقة. تقدم هذه الورقة تحليلاً مزدوج المنهج، باستخدام درجة-Z ألتمان بالاقتران مع خوارزمية تعلم آلي لكشف الشذوذ المسماة "غابة العزل- الذكاء الاصطناعي (Isolation Forest)"، من أجل الحكم على سلامة مصرف الجمهورية في الفترة ما بين 2018 و2022. تُظهر النتائج وجود ضغط مزمن في جميع السنوات، حيث أخفت السيولة الاحتياطية مؤقتاً نقاط الضعف الهيكلية في الملاءة المالية والربحية. قدرت طريقة كشف الشذوذ (غابة العزل- الذكاء الاصطناعي) أن عام 2018 كان عاماً شاذاً بسبب السيولة الأفضل، في حين أن عام 2020 استمر فيه سيناريو الضائقة. تم اكتشاف أن السيولة والربحية هما السببان الرئيسيان للضغط من خلال أهمية الميزة (feature importance)، مدعومةً بنسب القروض المتعثرة المرتفعة. يقدم البحث إسهامات منهجية من خلال تطبيق المقاربات التقليدية بالإضافة إلى مقاربات الذكاء الاصطناعي، فضلاً عن آثار عملية كبيرة لصانعي السياسات والجهات التنظيمية المهتمين بتعزيز أنظمة الإنذار المبكر في النظم المصرفية الهشة.

الكلمات المفتاحية :الضائقة المالية؛ درجة ألتمان المعيارية؛ غابة العزل لغة التعلم الآلي R (الذكاء الاصطناعي)؛ كشف الشذوذ؛ مصرف الجمهورية؛ القطاع المصرفي الليبي.

**Abstract:**

Economic resilience requires the soundness of financial health in the banking sector, as is the case with fragile economies like Libya. ALJUMHOURIA BANK, the country's largest state financier, has demonstrated chronic problems over the past decade. However, traditional models for distress prediction, such as Altman's Z-score, focus on a firm's chronic vulnerability but cannot identify severity when all cases fall in the distress zone. This paper discusses an analysis using a dual approach: Altman's Z-score and anomaly detection, Isolation Forest, to assess Jumhouria Bank's health from 2018 to 2022. Results indicate the occurrence of chronic stress in all years, with excess liquidity transiently disguising structural solvency and profitability weakness. Anomaly detection using the Isolation Forest estimated 2018 to be an anomalous year as a function of higher liquidity, while 2020 continued to present a distress scenario. In this regard, liquidity and profitability take precedence as the primal drivers of stress impelled by feature importance, supported by high non-performing loan ratios. The significant methodological contributions the research provides involve applying traditional and artificial intelligence approaches and offers considerable practical relevance for policy makers and regulators interested in enhancing early warning systems in fragile banking systems.

**Keywords:** Financial distress; Altman's standard score; Isolation Forest (machine learning); Anomaly detection; Jumhouria Bank; Libyan banking sector.

## 1. مقدمة:

تُعد الصحة المالية أساس التنمية الاقتصادية، خاصة في الاقتصادات النامية حيث تشكل المصارف الوسطاء الرئيسيين لتدفق رأس المال والائتمان .(Demirgüç-Kunt & Detragiache, 2002) المصارف المملوكة للدولة هي النوع الشائع من المصارف في ليبيا، ومعظم الأصول والودائع مملوكة لمصرف الجمهورية. لسلامته آثار فورية على الاقتصاد العام، وبالتالي فإن قياسه يجعله مصلحة وطنية. ومع ذلك، وعلى مدى السنوات العديدة الماضية، وُصف هذا المصرف: بأنه تحت ضغط مستمر، تفاقم بسبب عدم الاستقرار السياسي وأزمات السيولة والمؤسسات الهشة ( International Monetary Fund [IMF], **2023).**

الضائقة المالية للبنوك هي فشل المصرف في الوفاء بالتزاماته تجاه الدائنين والمودعين، وعادة ما تكون مقدمة للإعسار أو الفشل (Platt & Platt, 2002). تم استخدام النماذج التقليدية مثل درجة–**Z** ألتمان على نطاق واسع للتنبؤ بالضائقة، على الرغم من أن هذه النماذج تفقد قوتها التمييزية إذا كانت جميع نقاط البيانات ضمن منطقة الضائقة (Altman et al., 2017). في حالة مصرف الجمهورية من عام 2018 حتى عام 2022، يمنع هذا القيد المنهجي التمييز الهادف بين درجات الشدة. وهذا يفرض ضرورة استخدام لغة التعلم الآلي، مصممة خصيصا لكشف الشذوذ، لغة التعلم الآلي **R** والمتمثلة في غابة العزل (الذكاء الاصطناعي)، والتي بدورها لا تتطلب مجموعات بيانات متوازنة لتحديد الأنماط المالية غير المألوفة.

تهدف هذه الدراسة إلى تقييم الضائقة المالية لمصرف الجمهورية باستخدام درجة–**Z** ألتمان ولغة التعلم الآلي لغابة العزل التابعة للذكاء الاصطناعي. يساهم هذا المشروع نظرياً وعملياً من خلال اعتباره ابتكاراً منهجياً جديداً ضمن حالات الضائقة المستمرة، ويوفر معرفة قابلة للتطبيق لصانعي السياسات المالية والجهات التنظيمية في ليبيا.

### 1.1 مشكلة البحث

يتناول البحث مشكلة أساسية وهي: الهشاشة المالية الهيكلية للقطاع المصرفي الليبي بالإضافة الى عوامل خارجية، أيضاً قصور منهجية المؤشرات التقليدية كأداة في تحديد مدى هذه الضائقة المستمرة. انطلاقاً من الإطار السابق، يمكن تلخيصها في التالي:

- تعرّض القطاع المصرفي في ليبيا لهشاشة مطولة منذ العقد الماضي نتيجةً لعدم الاستقرار السياسي، وتقلبات الاقتصاد الكلي، وضعف الترتيبات المؤسسية.
- لم تتمكن المصارف العامة، وخاصةً مصرف الجمهورية (أكبر مصرف في ليبيا)، من الحفاظ على الربحية والملاءة المالية.
- تكشف الملاحظات المستندة إلى التقارير المالية لمصرف الجمهورية للفترة بين عام 2018 و2022 عن استمرار الضائقة المالية، كما هو مُقاس بنموذج **Z–Score** ألتمان للشركات غير الصناعية.
- يفتقر إلى آليات قوية لرصد ومعالجة الضائقة المالية، وبالتالي يظل المصرف عُرضةً لنوبات نقص السيولة وانخفاض جودة الأصول.

### 1.2 أهداف البحث

يهدف البحث بشكل عام إلى تقييم ومقارنة الضائقة المالية الذي يعاني منها مصرف الجمهورية، باستخدام أساليب تقليدية مقابل أساليب معاصرة متمثلة في لغة التعلم الآلي (غابة العزل).

وتتمثل أهداف البحث في:

- تقدير وتفسير مستوى الضائقة المالية التي عانى منها مصرف الجمهورية في السنوات من 2018 الى 2022 بناءً على الدرجة المعيارية ألتمان للشركات غير الصناعية.
- استخدام لغة التعلم الآلي "غابة العزلة" لتحديد الشذوذ لقياس عمق الضائقة المالية خلال الفترة الزمنية نفسها.
- ربط الدرجات المعيارية ألتمان بنتائج كشف الشذوذات لتحديد أوجه التشابه والاختلاف.
- دراسة أهمية السمات الخاصة بـ "غابة العزلة"، وتحديد أي المؤشرات المالية الأكثر دلالة في شدة الضائقة.
- تقديم إرشادات عملية لمصرف الجمهورية والسلطات المالية في ليبيا بشأن تعزيز إجراءات الرصد والاستجابة للضائقة المالية.

### 1.3 أسئلة البحث

تستند الدراسة البحثية إلى أسئلة بحثية، تُستخدم لتوجيه البحث ومقارنته بالتحليل المالي التقليدي والاستخدامات المتطورة للغة التعلم الآلي (الذكاء الاصطناعي).

- ما هي ظروف التمويل المتعثر لمصرف الجمهورية من عام 2018 إلى عام 2022، بناءً على مقياس **Z-Score** ألتمان للشركات غير الصناعية؟
- كيف يمكن تطبيق أساليب الكشف عن الشذوذ، وتحديداً **Isolation Forest**، لتقييم التباينات في شدة الضائقة المالية عند فشل نماذج التصنيف التقليدية؟
- ما هي الارتباطات بين نتائج **Z-Score** ألتمان ودرجات الشذوذ لـ **Isolation Forest**؟
- ما هي المؤشرات المالية (مثل رأس المال العامل، والربحية، وحقوق الملكية، ونسبة القروض إلى الودائع) التي تُفسر أعلى شدة ضائقة مالية لمصرف الجمهورية؟

## 2 مراجعة الأدبيات

### 2.1 مفاهيم الضائقة المالية

شهد تعريف الضائقة المالية تحولاً جذرياً في الأبحاث. فقد عرّفت الأبحاث السابقة الضائقة بأنها مرادفة للإفلاس أو عدم القدرة على الوفاء بالالتزامات، معتبرةً إياها حدثاً مؤقتاً. إلا أن الأبحاث اللاحقة أكدت أن الضائقة هي عملية تستمر لعدة سنوات، وتتميز بانخفاض الربحية والسيولة وتدهور المؤشرات المالية (Whitaker, 1999). هذا المنظور الواسع للضائقة كسلسلة متصلة، وليس نقطة زمنية محددة، يسمح للباحثين باستكشاف علامات الإنذار المبكر للضائقة واختلاف شدتها. تتميز الضائقة المالية عن الإعسار والإفلاس: فالإعسار هو حالة قانونية محاسبية تتجاوز فيها الالتزامات مبالغ الأصول أو يتعذر فيها سداد المدفوعات، بينما الإفلاس هو إجراء قانوني رسمي لإعادة التنظيم أو التصفية. تشمل الضائقة كليهما ولكنها تمتد إلى أبعد من ذلك، حيث قد تظل الشركات متعثرة دون الدخول في إجراءات الإفلاس ( **Platt & Platt**, 2002). بالنسبة للبنوك، تشكل السيولة وجودة الأصول مصدر قلق خاص، حيث تحتاج النماذج الخاصة بالقطاعات إلى دمج الهياكل المالية الفريدة ( Charitou, Neophytou, & Charalambous, 2004).

2.2 النماذج الكلاسيكية للتنبؤ بالضائقة المالية

اعتمدت الجهود المبكرة للتنبؤ بالضائقة المالية على تحليل النسب، حيث قورنت مؤشرات الربحية والرافعة المالية والسيولة بمعايير الصناعة لتقييم احتمالية الفشل. ورغم سهولة هذا النهج، إلا أنه كان معيباً لكونه مفرطاً في الذاتية وعدم توفيره مقاييس احتمالية (**Beaver**, 1966). ولتصحيح هذا الوضع، تم بناء نماذج إحصائية قادرة على إدخال النسب بطريقة منهجية لإنشاء مؤشرات تنبؤية.

كانت أول تقنية شائعة هي تحليل التمييز المتعدد (MDA)، حيث أوضحت الدرجة المعيارية الكلاسيكية ألتمان (Z–Score) عام 1968 كيف يمكن لمجموعة خطية من النسب أن تميز بنجاح بين الشركات الفاشلة وغير الفاشلة. وعلى الرغم من تعرض الدرجة المعيارية للنقد في افتراضات الحالة الطبيعية والتباين المتساوي، فقد وفرت أساساً مستداماً لأبحاث التنبؤ بالضائقة. وظهر الانحدار اللوجستي (Logistic regression) كبديل شائع في سبعينيات القرن الماضي، نظراً لقدرته على التنبؤ باحتمالات التخلف عن السداد. كان لنموذج O–Score الذي وضعه Ohlson's عام 1980 تأثيرٌ بالغ، إذ أُدرجت تسع متغيرات مالية في نموذج تنبؤ شائع.

ثم خطت نماذج المخاطر خطوةً إلى الأمام في توسيع نطاق التحليل من خلال مراعاة وقت حدوث الفشل بدلاً من اعتباره حدثاً ثابتاً. أظهر Shumway (2001) أن دمج متغيرات السوق الديناميكية يُحسّن القدرة على التنبؤ. ومع ذلك، تُقيّد الافتراضات الخطية، بالإضافة إلى الاعتماد على المعلومات المحاسبية التاريخية، المناهج التقليدية، مما يحدّ من قدرتها على رصد التفاعلات المالية المعقدة ( Tsai & Wu, 2008).

### 2.3 درجة ألتمان المعيارية (Z–Score) وتعديلاتها

شكّل نموذج درجة ألتمان المعيارية، الذي طُرح لأول مرة عام 1968، نقطة تحول في التنبؤ بالضائقة المالية. فبتطبيق تحليل التمييز المتعدد، جمع ألتمان خمس نسب مالية في درجة واحدة تُصنّف الشركات إلى مناطق "آمنة" أو "رمادية" أو "ضائقة" بدقة عالية، مُتنبئاً بدقة تصل إلى 95% من حالات الإفلاس قبل عام واحد من الفشل (Altman, 1968). ومنذ ذلك الحين، خضعت الصيغة لعدة تعديلات لتوسيع نطاق تطبيقها ليشمل شركات التصنيع الأمريكية. بالنسبة للشركات الخاصة وغير الصناعية، حيث غالباً ما تكون قيم أسهم السوق غير متاحة، طوّر ألتمان نسخاً مُعدّلة من النموذج. ويُعبّر عن درجة ألتمان المعيارية الشائعة الاستخدام على النحو التالي:

$$Z = 0.717X_1 + 0.847X_2 + 3.107X_3 + 0.420X_4 + 0.998X_5$$

| المتغير | التعريف | الصيغة |
|---|---|---|
| $X_1$ | رأس المال العامل / إجمالي الأصول | الأصول المتداولة – الخصوم المتداولة / إجمالي الأصول |
| $X_2$ | الأرباح المحتجزة / إجمالي الأصول | الأرباح المحتجزة / إجمالي الأصول |
| $X_3$ | الأرباح قبل الفوائد والضرائب / إجمالي الأصول | الربح قبل المخصصات والضرائب / إجمالي الأصول |
| $X_4$ | القيمة الدفترية لحقوق الملكية / إجمالي الالتزامات | إجمالي حقوق الملكية / إجمالي الالتزامات |
| $X_5$ | الإيرادات / إجمالي الأصول | الدخل التشغيلي / إجمالي الأصول |

بناءً على هذه الصيغة، تُشير الدرجات الأعلى من 2.9 إلى السلامة المالية، وتقع الدرجات بين 1.23 و2.9 في المنطقة الرمادية لعدم اليقين، بينما تُشير الدرجات الأقل من 1.23 إلى ضائقة مالية شديدة. أثبتت دراسات عديدة صحة الدرجة المعيارية دولياً، على الرغم من تراجع دقتها التنبؤية بمرور الوقت (Grice & Dugan, 2001). أما بالنسبة للبنوك، فيواجه النموذج قيوداً، إذ قد لا تعكس نسب مثل رأس المال العامل، السيولة وكفاية رأس المال بشكل كامل. لذا، مع أن الدرجة المعيارية لا تزال أداة تشخيصية

قيّمة من البداية، إلا أنه ينبغي دعمها بمؤشرات خاصة بالمصارف أو تقنيات متقدمة توفر إنذار مبكر أكثر دقة ( Čihák & Hesse, 2010; Hillegeist, Keating, Cram, & Lundstedt, 2004).

2.4 غابة العزل – الذكاء الاصطناعي (AI Isolation Forest-)

يُعرف كشف الشذوذ أيضاً بكشف القيم الشاذة، وهو فرع من فروع تعلم الآلة يُركز على رصد البيانات التي تنحرف بشكل كبير عن الأنماط المتوقعة. على عكس التصنيف الخاضع للإشراف، والذي يتطلب مجموعات بيانات مُسمّاة بأمثلة إيجابية وسلبية، يفترض اكتشاف الشذوذ أن معظم نقاط البيانات "طبيعية"، في حين أن الشذوذ نادر ومميز. وهذا ما يجعله ذا قيمة خاصة في التمويل، حيث غالباً ما تُشير الشذوذات إلى احتيال، أو نشاط تجاري غير اعتيادي، أو تحذيرات مبكرة من ضائقة مالية ( Chandola, Banerjee, & Kumar, 2009). تُعدّ غابة العزل– الذكاء الاصطناعية (**Isolation Forest**)، التي طورها **Liu** وآخرون (2008)، إحدى الطرق الرائدة في هذا المجال. فبدلًا من الاعتماد على مقاييس المسافة أو الكثافة، تعمل هذه الطريقة عن طريق تقسيم البيانات بشكل متكرر عشوائيًا لعزل الملاحظات. ونظًراً لأن الحالات الشاذة أكثر ندرة وتميزاً، يُمكن فصلها بتقسيمات أقل. هذا يجعل هذه الطريقة فعّالة حسابياً وفعّالة للغاية، حتى مع مجموعات البيانات كبيرة الأبعاد أو صغيرة الحجم أو غير المتوازنة – وهي حالات شائعة في البيانات المالية. تتعدد تطبيقات كشف الشذوذ في المجال المالي. ففي مجال كشف الاحتيال، يُستخدم هذا الكشف لتحديد معاملات بطاقات الائتمان غير القانونية، وغسيل الأموال، وممارسات المحاسبة التلاعبية. أما في أسواق رأس المال، فيساعد هذا الكشف على كشف أنشطة التداول غير الطبيعية، وسلوك الأسعار غير المعتاد، وتراكم المخاطر النظامية. وقد طبّقه الباحثون مؤخراً على القطاع المصرفي، حيث غالباً ما تسبق الشذوذات الإشارات التقليدية للأزمات المالية. على سبيل المثال، أظهر Kou وآخرون (2019) أن النماذج القائمة على الشذوذات حددت العلامات المبكرة للمخاطر النظامية، مما يوفر إضافات قيّمة لمقاييس الضائقة المالية التقليدية. تكمن إحدى نقاط القوة الرئيسية في كشف الشذوذ في قدرته على تقييم الشدة النسبية. بالنسبة للبنوك التي تعاني من ضائقة مالية مزمنة مثل مصرف الجمهورية، يمكن لدرجات الشذوذ التمييز بين سنوات الضغط الشديد وتلك التي شهدت تحسناً طفيفاً. بالإضافة إلى ذلك، تُسلّط تصنيفات أهمية الميزات الضوء على المتغيرات التي تُؤدّي إلى الشذوذ، وتربط اللغة التعلم الآلي المتقدمة برؤى عملية وقابلة للتنفيذ (Ahmed, Mahmood, & Hu, 2016). مع ذلك، فإنّ لكشف الشذوذ حدوداً. فهو لا يُولّد مخرجات قائمة على الاحتمالات، وقد تختلف النتائج باختلاف إعدادات المعلمات، ولا يزال حديثاً نسبياً في أبحاث الضائقة المالية ( García, Marqués, & Sánchez, 2019). ومع ذلك، فإنّ أهميته في معالجة المشاكل أحادية الفئة تُظهر إمكانات قوية في سياقات هشة ومحدودة البيانات، مثل القطاع المصرفي الليبي.

## 3 المنهجية

### 3.1 تصميم البحث

يتبع البحث تصميماً كمياً تحليلياً. واستُخدم التصميم الطولي، لتحليل البيانات المالية التاريخية لخمس سنوات (2018–2022) لمصرف الجمهورية لتحديد التغيرات الزمنية في شدة الضائقة. وهو منهج مقارن باستخدام تصنيف درجة Score–Zوكشف الشذوذ غابة العزل (لغة التعلم الآلي R – الذكاء الاصطناعي).

مكننا هذا التصميم من فحص التقارير السنوية لمصرف الجمهورية عن الفترة المذكورة، مما سهَّلت رصد التباين الزمني في شدة الضائقة المالية بدلاً من الفحص المقطعي. بالإضافة إلى ذلك، أجرينا دراسة مقارنة بتطبيق منهجين متكاملين: الدرجة المعيارية ألتمان (**Score–Z**) كمقياس تقليدي وكمرجع معياري، في مقابل منهجية لغة التعلم الآلي **R** لغابة العزلة (Isolation forest) كإطار عمل جديد للكشف عن الشذوذ. ولا تقتصر مقارنة هذه الطرق على اختبار اتساقها فحسب، بل تُقيّم أيضاً ما إذا كان الكشف عن الشذوذ يُتيح رؤىً أعمق حول شدة الضائقة، لا سيما في سياقات الضعف المالي المستمر.

### 3.2 البيانات والمتغيرات

- جمع البيانات ومصادرها:

اعتمدت هذه الدراسة على بيانات ثانوية فقط. استُخلصت البيانات من التقارير المالية السنوية المراجعة لمصرف الجمهورية للفترة من 2018 إلى 2022، والموجودة على الموقع الرسمي لمصرف الجمهورية.

- المتغيرات:

تشمل نسب درجة Score–Z ألتمان رأس المال العامل وإجمالي الأصول ($X_1$)، والأرباح المحتجزة وإجمالي الأصول ($X_2$)، والأرباح قبل الفوائد والضرائب وإجمالي الأصول ($X_3$)، وحقوق الملكية والالتزامات (**$X_4$**)، ودخل التشغيل وإجمالي الأصول (**$X_5$**). المتغيرات الإضافية المستخدمة في كشف الشذوذ (غابة العزل– الذكاء الاصطناعي) كانت العائد على الأصول (ROA)، ونسبة القروض المتعثرة (NPL)، ونسبة القروض إلى الودائع (LDR)، وحقوق الملكية إلى الأصول ( .(Equity

### 3.3 الإجراءات التحليلية

- حساب درجة Score–Z: تم استخدام صيغة Z–Score التي تستخدمها الشركات غير الصناعية. الحدود: **Z** < 1.1 = ضائقة؛ 1.1 – 2.6 = منطقة رمادية؛ > 2.6 = آمن.

- غابة العزل: تم تنفيذها في لغة بايثون، وتولد أوامر أهمية الميزة (feature importance) ودرجات الشذوذ (anomaly scores). وترتبط الدرجات الأعلى بشدة أعلى من الضائقة.
- دراسة مقارنة: أكدت ارتباط سبيرمان (Spearman correlation) ما إذا كانت درجات Score–Z ودرجات الشذوذ (anomaly scores) متوافقة.

### 3.4 الأدوات

جرى تحليل البيانات باستخدام لغة بايثون (الإصدار 3.12)، مستفيداً من مكتباتها الواسعة لنمذجة التمويل والإحصاء. ويطبّق البرنامج مكتبة scikit–learn في نشر Isolation Forest، بينما تُدار معالجة البيانات المسبقة بواسطة pandas وNumPy. كما يُستخدم matplotlib وseaborn في تصور البيانات، وتم ذلك عن طريق استخدام برنامج RStudio (حزمة Isolation Forest) لاكتشاف الشذوذ، مما سهَّل الإخراج البياني للدرجات المعيارية (Z–Score)، ودرجات الشذوذ (Anomaly Scores)، وأهمية السمات. بالإضافة إلى ذلك، استُخدم برنامج SPSS (الإصدار 27) لإجراء اختبارات إحصائية، مثل معامل ارتباط سبيرمان (**Spearman's correlation**)، للتحقق المتبادل من النتائج التقليدية والنتائج القائمة على الشذوذ. يضمن تكامل SPSS وPython سلامة تصميم البحث، بالإضافة إلى سهولة تفسير النتائج.

## 4 النتائج

### 4.1 نتائج درجة **Z– Score**

جميع السنوات من 2018 حتى 2022 تقع ضمن نطاق الضائقة، حيث تراوحت درجات الشذوذ من 0.215– في 2020 إلى 0.174 في 2018. وهذا يشير إلى خطر إعسار مستمر وضعف عميق في الملاءة المالية والربحية.

| السنة | الدرجة المعيارية (Z–Score) | الرتبة (1 = الاشد في الضائقة) |
|---|---|---|
| **2020** | **0.215–** | 1 |
| **2021** | **0.077** | 2 |
| **2022** | **0.140** | 3 |
| **2019** | **0.170** | 4 |
| **2018** | **0.174** | 5 |

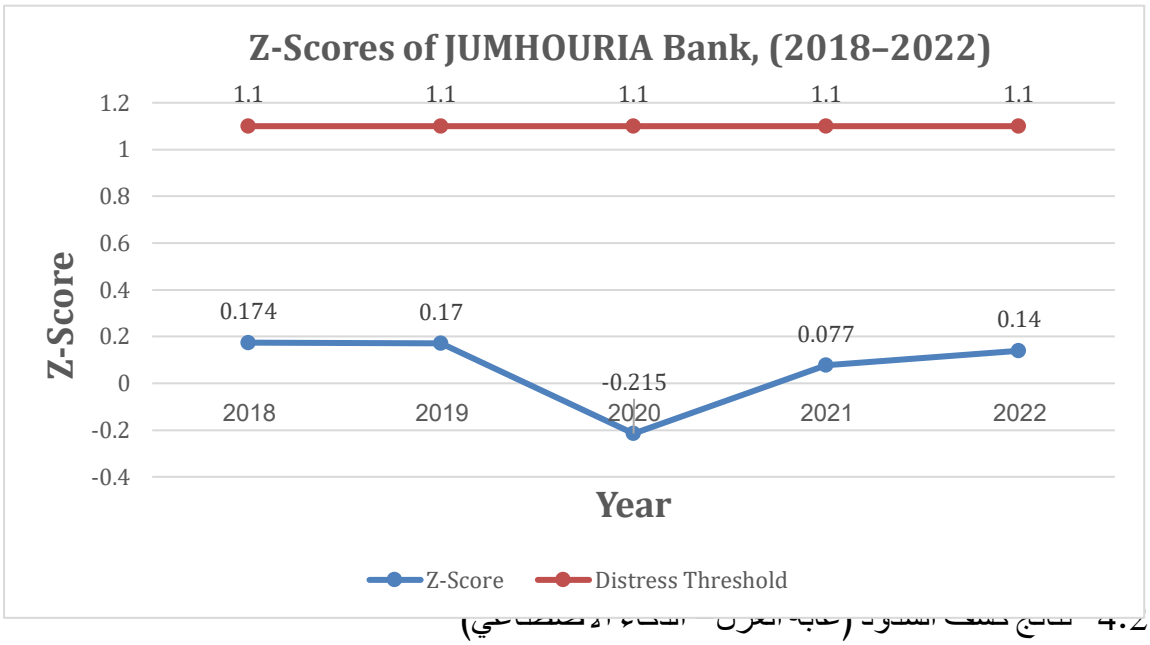


4.2 نتائج كشف الشذوذ (غابة العزل "الذكاء الاصطناعي")

اكتشفت غابة العزل درجات متفاوتة من الشذوذ خلال السنوات الخمس. كان عام 2018 هو العام الأكثر شذوذاً بناءً على السيولة الأقوى نسبياً، وكان عام 2020 هو الأقل شذوذاً مع نمط ضائقة معتاد. في عام 2022، تحسنت الربحية قليلاً مع بقاء الوضع العام ضمن نطاق الضائقة.

| السنة | درجة الشذوذ (ANOMALY SCORE) | الرتبة (1 = الاشد في الضائقة) |
|---|---|---|
| **2018** | 0.442 | 1 |
| **2019** | 0.468 | 2 |
| **2022** | 0.497 | 3 |
| **2021** | 0.514 | 4 |
| **2020** | 0.553 | 5 |

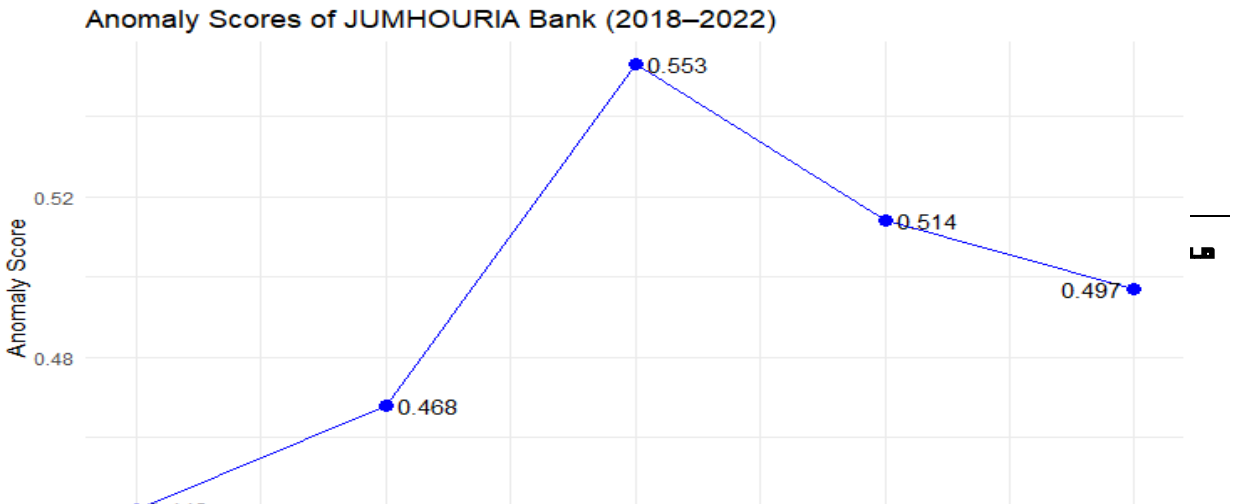

### 4.3 أهمية العامل أو الميزة (Feature Importance)

كانت السيولة (**$X_1$**) والربحية ($X_5$, ROA) أقوى المعايير المساهمة، تليها نسبة القروض إلى الودائع (**LDR**) والقروض المتعثرة (NPL). ساهمت المعايير القائمة على حقوق الملكية (Equity) بشكل ضئيل وأشارت إلى أن قضايا الملاءة المالية هيكلية وليست مؤقتة.

| العامل أو الميزة (Feature) | الاهمية (Importance) |
|---|---|
| **$X_1$** رأس المال العامل / إجمالي الأصول | 0.022 |
| **$X_5$** الدخل التشغيلي / إجمالي الأصول | 0.019 |
| نسبة القروض إلى الودائع | 0.018 |
| نسبة القروض المتعثرة | 0.008 |
| العائد على الأصول | 0.005 |
| **$X_2$** الأرباح المحتجزة / إجمالي الأصول | 0.005 |
| **$X_3$** الأرباح قبل الفوائد والضرائب / إجمالي الأصول | 0.003 |
| **$X_4$** حقوق الملكية / إجمالي الخصوم | 0.002 |

### 4.4 اختبار الارتباط

أكد ارتباط سبيرمان وجود ارتباط سلبي كامل ($p = -1.0$, $p < 0.01$) بين درجات Score–Z ودرجات الشذوذ من غابة العزل– الذكاء الاصطناعي، ففي الفترات التي كانت درجات **Z** المعيارية منخفضة، والتي تظهر على أنها أكثر شدة للضائقة المالية، قابلها وفي نفس الفترة درجات شذوذ أعلى. تُظهر الدلالة الإحصائية لهذا الارتباط أن النهجين، على الرغم من اختلاف أطرهما التحليلية، متكاملان للغاية في تشخيص الضائقة المالية وشدتها، وهذه النتيجة تؤكد متانة الطريقة القائمة على الشذوذ كأداة مُكملة وفعّالة إلى جانب النماذج التقليدية في تقييم الضائقة المالية.

### 4.5 ملخص النتائج

نتائج الضائقة المالية لمصرف الجمهورية (2018–2022).

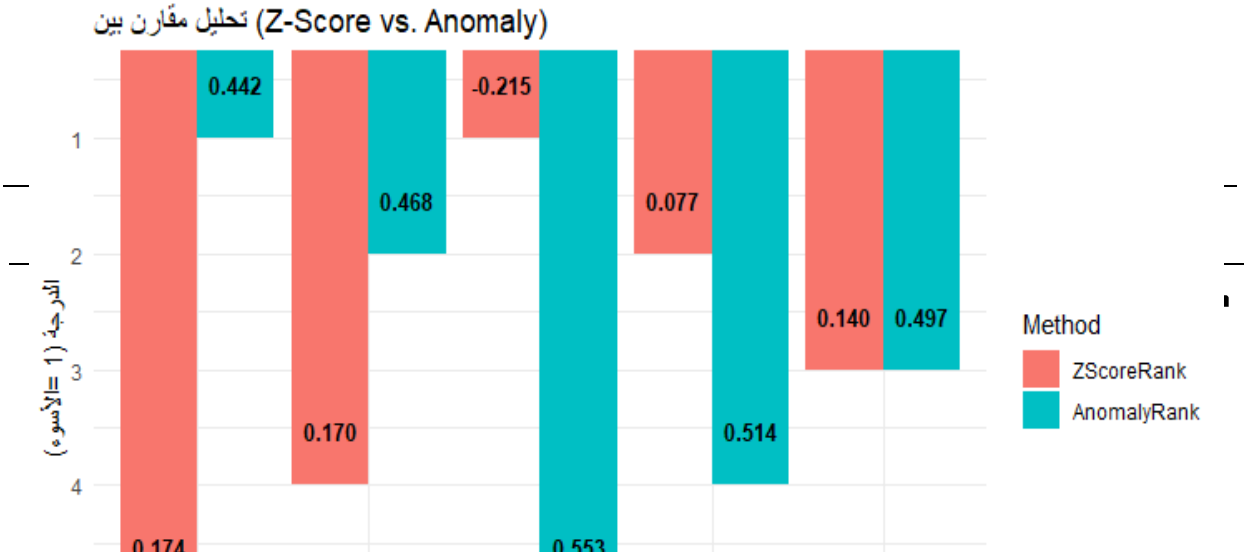

| | E | | | |
|---|---|---|---|---|
| **2018** | 0.174 | إعسار | الأكثر شذوذاً (انحراف سيولة مرتفع) | قوة السيولة، ضعف الملاءة المالية |
| **2019** | 0.170 | إعسار | شاذ بشكل معتدل | انخفاض الربحية، ارتفاع القروض المتعثرة |
| **2020** | – 0.215 | إعسار | الأقل شذوذاً (حالة إعسار نموذجية) | إعسار هيكلي، انخفاض حقوق الملكية |
| **2021** | 0.077 | إعسار | شاذ بشكل معتدل | ضغط السيولة، القروض المتعثرة لا تزال مرتفعة |
| **2022** | 0.140 | إعسار | تحسن طفيف، لا يزال في حالة إعسار | انتعاش طفيف في الربحية، استمرار مشاكل القروض المتعثرة |

توضيح: تستند درجات Z–Score إلى نموذج Altman لدرجات **Z**، حيث تقع جميع القيم ضمن نطاق العسر ($Z < 1.1$). تُستمد نتائج كشف الشذوذ من نموذج غابة العزل– الذكاء الاصطناعي ( Isolation Forest). تُسلط العوامل الرئيسية الضوء على العوامل المالية الرئيسية التي تؤثر على العسر سنوياً، مثل السيولة، والربحية، والملاءة المالية، والقروض المتعثرة.

## 5 المناقشة

تتفق النتائج على أن مصرف الجمهورية يواجه ضغوطاً مالية دائمة تتجلى في ضعف رأس المال، وانخفاض الربحية، وتكرار خطر الائتمان. حجبت الموارد المالية المؤقتة السنوية من السيولة شدة نقاط الضعف الكامنة. بينما ميزت درجة **Z–Score** ألتمان خطر الإعسار المستمر، أضاف كشف الشذوذ (غابة العزل– الذكاء الاصطناعي) فارقاً دقيقاً من خلال الكشف عن الانحرافات النادرة وعلامات الإنذار بالخطر.

تتفق النتائج مع إطار Diamond–Dybvig لضعف المصرف بحيث لا تكون إدارة السيولة نفسها كافية لضمان مرونة الملاءة المالية (Diamond & Dybvig, 1983). وهي تتفق أيضاً مع تركيز بازل 3 على كفاية رأس المال وجودة الائتمان ( Basel Committee on Banking Supervision [BCBS], 2011). من منظور منهجي، يُظهر الجمع بين الأساليب الكلاسيكية والتعلم الآلي فائدة حيث تكون مجموعات البيانات صغيرة وتُعاني من ضائقة منتظمة في الاقتصادات الهشة.

## 6 الخاتمة والآثار المترتبة

تساهم هذه الورقة في أدبيات الضائقة المالية من خلال تقديم منهجية مزدوجة باستخدام درجة Z–Score ألتمان وكشف الشذوذ (غابة العزل – الذكاء الاصطناعي) لتحديد شدة الضائقة. تثبت النتائج التي تم التوصل إليها أن مصرف الجمهورية كان في حالة ضائقة مالية، هيكلية من عام 2018 إلى 2022 وأن السيولة الاحتياطية لم تكن كافية للتغلب على انخفاض الربحية، وضعف رأس المال، وارتفاع مخاطر الائتمان.

السياسة المصرفية، زيادة متطلبات كفاية رأس المال، واستراتيجيات فعالة للحد من القروض المتعثرة، والتركيز على أدوات الإنذار المبكر القائمة على الشذوذ. تُعد المعلومات التي يستمدها المنظمون من حالات الشذوذ، والتي لا تراها النماذج التقليدية الاخرى، بمثابة تكملة للمعلومات.

القيود والعوائق، في أنها تستند إلى دراسة حالة واحدة وبيانات محدودة، وذلك لمحدودية المصادر من تقارير تفصيلية للبنود المهمة، نتيجة للسرية التي تتبعها المصارف في ليبيا وعدم مشاركة بياناتها المصرفية. يُقترح عمل إضافي لتوسيع بُعد البيانات واستخدام طرق كشف الشذوذ (غابة العزل– الذكاء الاصطناعي) الجماعية.

## REFERENCES


- Ahmed, M., Mahmood, A. N., & Hu, J. (2016). A survey of network anomaly detection techniques. Journal of Network and Computer Applications, 60, 19–31.
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. Journal of Finance, 23(4), 589–609.
- Altman, E. I., Iwanicz–Drozdowska, M., Laitinen, E. K., & Suvas, A. (2017). Financial distress prediction in an international context: A review and empirical analysis of Altman's Z–Score model. Journal of International Financial Management & Accounting, 28(2), 131–171.
- Basel Committee on Banking Supervision (BCBS). (2011). Basel III: A global regulatory framework for more resilient banks and banking systems. Bank for International Settlements.

- Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. ACM Computing Surveys, 41(3), 1–58.
- Beaver, W. H. (1966). Financial ratios as predictors of failure. Journal of Accounting Research, 4, 71–111.
- Charitou, A., Neophytou, E., & Charalambous, C. (2004). Predicting corporate failure: Empirical evidence for the UK. European Accounting Review, 13(3), 465–497.
- Čihák, M., & Hesse, H. (2010). Islamic banks and financial stability: An empirical analysis. Journal of Financial Services Research, 38(2–3), 95–113.
- Demirgüç-Kunt, A., & Detragiache, E. (2002). Does deposit insurance increase banking system stability? An empirical investigation. Journal of Monetary Economics, 49(7), 1373–1406.
- Diamond, D. W., & Dybvig, P. H. (1983). Bank runs, deposit insurance, and liquidity. Journal of Political Economy, 91(3), 401–419.
- García, V., Marqués, A. I., & Sánchez, J. S. (2019). Exploring the synergetic effects of sample types and sampling strategies for financial distress prediction. Information Fusion, 47, 88–101.
- Grice, J.S., Dugan, M.T. (2001). The Limitations of Bankruptcy Prediction Models: Some Cautions for the Researcher. Review of Quantitative Finance and Accounting 17, 151–166.
- Hillegeist, S. A., Keating, E. K., Cram, D. P., & Lundstedt, K. G. (2004). Assessing the probability of bankruptcy. Review of Accounting Studies, 9(1), 5–34.
- International Monetary Fund (IMF). (2023). Libya: Financial sector assessment. Washington, DC: IMF.

- Kou, G., Yang, P., Peng, Y., & Xiao, F. (2019). Financial systemic risk early warning of Chinese banking system: An ensemble learning approach. PLOS ONE, 14(4), e0215129.
- Liu, F. T., Ting, K. M., & Zhou, Z. H. (2008). Isolation Forest. In Proceedings of the 2008 IEEE International Conference on Data Mining (pp. 413–422). IEEE.
- Platt, H. D., & Platt, M. B. (2002). Predicting corporate financial distress: Reflections on choice-based sample bias. Journal of Economics and Finance, 26(2), 184–199.
- Shumway, T. (2001). Forecasting bankruptcy more accurately: A simple hazard model. The Journal of Business, 74(1), 101–124.
- Tsai, C. F., & Wu, J. W. (2008). Using neural network ensembles for bankruptcy prediction and credit scoring. Expert Systems with Applications, 34(4), 2639–2649.
- Whitaker, R. B. (1999). The early stages of financial distress. Journal of Economics and Finance, 23(2), 123–132.