

Using Multilayer Perspectives (MLP) Neural Networks
to Predict Banking Stability

استخدام الشبكات العصبية متعددة الطبقات (MLP) للتنبؤ
بالاستقرار المصرفي



Mohammad Yousef, Reem Mahmoud
Syria

mohamadyou662@gmail.com, rime_mahmoud@yahoo.fr

*(Corresponding author) e-mail: mohamadyou662@gmail.com

الملخص

هدف هذا البحث الى تطوير نموذج يعتمد على الشبكات العصبية متعددة الطبقات (MLP) للتنبؤ بمستوى الاستقرار المصرفي للمصارف السورية التجارية الخاصة باستخدام بيانات مالية سنوية للفترة (2010-2023). كما سعى الى مقارنة أداء نموذج الشبكة العصبية (MLP) بأداء نموذج شجرة القرار (DT) من حيث القدرة التنبؤية بالاستقرار المصرفي. تم قياس الاستقرار المصرفي بمؤشر (Z-score). بينما تم تضمين أحد عشر مؤشرا ماليا في النموذج التنبؤي. وباستخدام الاختبارات (RMSE, MSE, R2) أظهرت النتائج كفاءة نموذج MLP في التنبؤ بالاستقرار المصرفي متفوقاً على نموذج شجرة القرار التقليدي من حيث الدقة التفسيرية، إذ فسر ما يقارب 56% من التغيرات في مؤشر الاستقرار المصرفي باستخدام كافة المؤشرات المالية الـ 11 مع أخطاء أقل. إضافة لما سبق، تم تحديد المزيج الأمثل للنموذج التنبؤي باستخدام تقنية Importance Permutation وظهرت النتائج أن استخدام المؤشرات الستة المتمثلة بـ (إجمالي الالتزامات/ حقوق الملكية، والقروض/ حقوق الملكية، الرافعة المالية، نسبة كفاية رأس المال، العائد على حقوق الملكية، وحجم البنك) يرفع من قدرة النموذج التفسيرية إلى نحو 77.6%.

ABSTRACT

This research aimed to develop a model based on multi-layer permutation (MLP) neural networks to predict the level of banking stability of private Syrian commercial banks, using annual financial data for the period (2010-2023). It also sought to compare the performance of the MLP neural network model with that of the decision tree (DT) model in terms of its predictive ability to measure banking stability.

Banking stability was measured using the Z-score, while eleven financial indicators were included in the predictive model. Using tests (RMSE, MSE, R²), the results demonstrated the MLP model's effectiveness in predicting banking stability, outperforming the traditional DT model in terms of interpretive accuracy. It explained approximately 56% of the changes in the stability index using all (11) financial indicators with fewer errors. In addition to the above, the optimal combination of the predictive model was determined using the Permutation Importance technique, and the results showed that using the six indicators (total liabilities/equity, loans/equity), financial leverage, capital adequacy ratio, return on equity, and bank size) increases the explanatory power of the model to approximately 77.6%.

Article history:

Submission ID: 461

Submission Date: 04/09/2025

Reviewing Date: 25/09/2025

Revision Date: 14/10/2025

Acceptance Date: 30/10/2025

Publishing Date: 13/11/2025

DOI: 10.6520/q3mdcs63

Keywords:

-Banking Stability Prediction, Multi Layer Neural Networks (MLP), Decision Tree Model, Syria

Cite as:

Yousef, M., Mahmoud, R. (2025) Using Multilayer Perspectives (MLP) Neural Networks to Predict Banking Stability. Jersah for Research and Studies 25(4). <https://doi.org/10.6520/q3mdcs63e2025461>



© The authors (2025). This is an Open Access article distributed under the terms of the Creative Commons Attribution (CC BY) license, which permits non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited. For commercial re-use, please contact admin@jpu.edu.jo.

استخدام الشبكات العصبية متعددة الطبقات (MLP) للتنبؤ بالاستقرار المصرفي

(دراسة تطبيقية على المصارف التجارية الخاصة السورية للفترة 2010-2023)

د. ريم محمود

أستاذ مساعد في قسم العلوم المالية والمصرفية - كلية الاقتصاد - جامعة اللاذقية - سوريا

rime_mahmoud@yahoo.fr

محمد فؤاد يوسف

طالب دكتوراه في قسم العلوم المالية والمصرفية - كلية الاقتصاد - جامعة اللاذقية - سوريا

mhammadyousef123456@gmail.com

الملخص

هدف هذا البحث إلى تطوير نموذج يعتمد على الشبكات العصبية متعددة الطبقات (MLP) للتنبؤ بمستوى الاستقرار المصرفي للمصارف السورية التجارية الخاصة، باستخدام بيانات مالية سنوية للفترة (2010-2023). كما سعى إلى مقارنة أداء نموذج الشبكة العصبية (MLP) بأداء نموذج شجرة القرار (DT)، من حيث القدرة التنبؤية بالاستقرار المصرفي.

تم قياس الاستقرار المصرفي بمؤشر (Z-score)، بينما تم تضمين إحدى عشر مؤشراً مالياً في النموذج التنبؤي، وباستخدام الاختبارات (RMSE, MSE, R²) أظهرت النتائج كفاءة نموذج MLP في التنبؤ بالاستقرار المصرفي متفوقاً على النموذج التقليدي (DT) من حيث الدقة التفسيرية؛ إذ فسّر ما يقارب 56% من التغيرات في مؤشر الاستقرار باستخدام كافة المؤشرات المالية الـ (11) مع أخطاء أقل. إضافة لما سبق، تم تحديد الميزج الأمثل للنموذج التنبؤي باستخدام تقنية Permutation Importance، وأظهرت النتائج أن استخدام المؤشرات الستة المتمثلة بـ (إجمالي الالتزامات/حقوق الملكية، والقروض/حقوق الملكية)، الرافعة المالية، نسبة كفاية رأس المال، العائد على حقوق الملكية، وحجم البنك) يرفع من قدرة النموذج التفسيري إلى نحو 77.6%.

الكلمات المفتاحية: التنبؤ بالاستقرار المصرفي، الشبكات العصبية متعددة الطبقات (MLP)، نموذج شجرة القرار، سوريا

1. مقدمة

يُعدّ الاستقرار المصرفي من العوامل الرئيسة لسلامة النظام المالي، نظراً لدوره الحيوي في تعزيز الثقة بين الفاعلين الاقتصاديين وضمان استمرارية الوساطة المالية، بما يدعم النمو الاقتصادي طويل الأجل. فالمصارف، بصفتها مؤسسات وسيطة، تؤدي دوراً محورياً في تعبئة المدخرات وتخصيص الموارد بكفاءة، كما تسهم في إدارة وتوزيع المخاطر ضمن الاقتصاد. ومع تصاعد التحديات التي تواجه الأنظمة المصرفية عالمياً، لاسيما بعد الأزمات المالية المتكررة، أصبح من الضروري تبني أدوات تنبؤية دقيقة، تساعد في تقييم مستويات الاستقرار المصرفي والتنبؤ بمخاطر التعثر المحتمل قبل حدوثها (Kvashuk et al., 2023).

تمثل الشبكات العصبية أحد أبرز أساليب الذكاء الاصطناعي المستخدمة للتنبؤ باستقرار القطاع المصرفي وحالات التعثر والافلاس، إذ تقدم بديلاً عن الطرق التقليدية من خلال التقاط العلاقات المعقدة وغير الخطية داخل البيانات المالية (Minasyan, 2024). تعد الشبكات متعددة الطبقات (Multilayer Perceptron - MLP)، من أنواع الشبكات التي أظهرت قدرة ملحوظة على التنبؤ بسلوك الأنظمة غير الخطية والمعقدة، وتحليل البيانات المالية الضخمة والمتغيرة، وعلى التنبؤ بالمخاطر والاضطرابات المحتملة قبل وقوعها (Chen et al., 2025).

فيما يتعلق بسورية، فقد شهد القطاع المصرفي الخاص تطورات مؤسساتية ملحوظة منذ بداية الألفية الثالثة، والتي تضمنت إطلاق عملية تحرير العمل المصرفي وفتح المجال أمام تأسيس مصارف تجارية خاصة. إلا أنّ هذه التطورات واجهت تحديات عميقة بعد اندلاع الأزمة السورية عام 2011، والتي شكّلت نقطة تحول سياسي واقتصادي انعكست بشكل مباشر على أداء المؤسسات المصرفية. فقد أدت تداعيات الأزمة الداخلية إلى تراجع النشاط الاقتصادي، وتقلص الاستثمارات وارتفاع مستوى المخاطر التشغيلية والمالية. تزامن ذلك مع فرض مجموعة من العقوبات الاقتصادية الدولية التي استهدفت المصارف السورية، مما قيد تعاملاتها الخارجية وقدرتها على الوصول إلى النظام المالي العالمي. أدت تلك الظروف مجتمعة في حدوث تقلبات حادة في سعر الصرف، وتدهور البيئة الاستثمارية، وتراجع معدلات السيولة، وارتفاع نسب القروض المتعثرة، وضعف مؤشرات الربحية في العديد من سنوات فترة الدراسة (زرير والحوي، 2016؛ يوسف، 2023). في ظل ما سبق، برزت الحاجة إلى تقديم أدوات جديدة باستخدام الشبكات الاصطناعية تستجيب لخصوصية البيئة المصرفية السورية وتحدياتها المركبة، وتسهم في تعزيز آليات الإنذار المبكر لدى صناع القرار والجهات الرقابية.

بناءً عليه، يسعى هذا البحث إلى توظيف نموذج الشبكات العصبية متعددة الطبقات (MLP) للتنبؤ بمستوى الاستقرار المصرفي للمصارف السورية التجارية الخاصة، كونها تشكّل إحدى أبرز نتائج تحرير العمل المصرفي، كما أن ادراجها في سوق دمشق للأوراق المالية منذ عام 2010 قد وفّر بيانات مالية سنوية خلال الفترة 2010-2023، موحدة وقابلة للتحليل والمقارنة. إضافةً إلى ذلك، كانت هذه المصارف الأكثر عرضة للتقلبات الاقتصادية والعقوبات الدولية، مما يعكس أهمية تقييم قدرتها على تحقيق الاستقرار المصرفي باستخدام أدوات تنبؤية متقدمة.

2. المراجعة الأدبية:

قدّمت العديد من الدراسات مناهج نظرية مختلفة لتقييم الاستقرار المصرفي، إذ سلّطت دراسة (Giraldo et al., 2024) الضوء على الاستقرار المالي للمؤسسات المصرفية، مشيرةً إلى أهمية العوامل الخارجية كالظروف الاقتصادية الكلية، والسياسات

التنظيمية، والتكامل المالي التي قد تؤثر في استقرار القطاع المصرفي من خلال دراسته التي تناولت تأثير الانفتاح المالي في استقرار القطاع المصرفي بـ 58 دولة للفترة (2010 – 2020)، باستخدام نموذج التعلم الآلي المزدوج غير المتحيز (DDML)، مستخدماً مقاييس مختلفة للانفتاح من بينها (إجمالي الأصول الأجنبية، نسبة إجمالي الالتزامات الأجنبية إلى الناتج المحلي الإجمالي، وحقوق الملكية للمستثمرين الأجانب وصافي القروض إلى الشركات المقيمة، وصافي الاستثمار الأجنبي المباشر كنسبة مئوية من الناتج المحلي الإجمالي، ومؤشر سيادة القانون، و(الصادرات + الواردات)/ الناتج المحلي الإجمالي). بينما شملت العوامل الداخلية خصائص المصارف مثل الملاءة المالية، والتعثر في السداد، ومؤشرات الربحية والسيولة في المصارف (Fernández, 2020)، إذ قام Fernández بتحليل استقرار المصارف في الولايات المتحدة خلال الفترة (1990 – 2017) باستخدام نماذج الذكاء الصناعي، وأظهرت النتائج أنّ نموذج الغابات العشوائية قد حقق أعلى دقة تنبؤية مقارنةً بغيره. علاوةً على ذلك، أشارت العديد من الدراسات إلى أنّ الشبكات العصبية تعد أدوات فعّالة لتقييم الاستقرار المالي، إذ أشارت دراسة (Zhou et al., 2024) إلى أنّ نماذج التعلم العميق تُوفّر دقة عالية وأداءً أفضل في التنبؤ في مجالي التمويل والخدمات المصرفية، بما في ذلك التنبؤ بالائتمان والمخاطر، والتنبؤ بالاقتصاد الكلي، وإدارة المحافظ، والتنبؤ بالسلاسل الزمنية. بشكل مشابه، اختبر (Tölö (2020 إمكانية التنبؤ بالأزمات المالية النظامية خلال فترة تتراوح بين (سنة إلى خمس سنوات) باستخدام الشبكات العصبية المتكررة، حيث استخدمت الدراسة مجموعة بيانات تتضمن تواريخ الأزمات والسلاسل الاقتصادية الكلية السنوية للفترة (1870 – 2016) لـ 17 دولة، وأشارت النتائج إلى أن هياكل الشبكات العصبية البسيطة تتفوق على نماذج الانحدار اللوجستي التقليدية في التنبؤ بالأزمات المالية النظامية. من جهة أخرى، قارنت دراسة (Ariza et al., 2024) نماذج التعلم الآلي للتنبؤ بتخلف المقترضين عن السداد في القطاع المصرفي، مع التركيز على مرونة هذه النماذج تجاه التغيرات في بيانات الإدخال والظروف الاقتصادية الكلية، حيث حللت الدراسة النماذج الكلاسيكية والحديثة، بما في ذلك الانحدار اللوجستي، والغابات العشوائية، وتعزيز التدرج، والشبكات العصبية، وقامت بتقييم دقتها التنبؤية باستخدام مقاييس مثل مؤشر (PSI)¹، وأظهرت النتائج تفوق الشبكات العصبية من الناحية التنبؤية.

في سورية، ظهرت العديد من الدراسات محاولةً تقييم الاستقرار المصرفي أو الأداء المالي للمصارف الخاصة. إذ قامت دراسة (الناصر، 2012) بتقييم الأداء المالي للمصارف الخاصة في سورية خلال الفترة (2006–2010) باستخدام نموذج CAEL الذي يتضمن أربعة مؤشرات أساسية (كفاية رأس المال، جودة الأصول، الربحية، والسيولة)، وأظهرت النتائج أن المصرف الدولي للتجارة والتمويل قد حقق أفضل أداء وفقاً لمؤشرات نموذج CAEL مقارنةً ببقية المصارف. أمّا دراسة (الحموي، 2016) فقد سعت إلى بناء نموذج للتنبؤ المبكر من خلال اختبار مدى ملاءمة مؤشر (Texas²) لقياس إمكانية حدوث الفشل المالي في المصارف السورية الخاصة التقليدية، دراسة تطوّر أداء أهم مؤشرات الأداء المالي والسوقي المتمثلة بـ (ROE، ROA، السيولة، كفاية رأس المال، جودة المحفظة، نسبة التغطية، معدل نمو التسهيلات الائتمانية، معدل نمو الودائع، ومعدل توظيف الودائع) خلال الفترة من الربع الأول 2010 حتى الربع الرابع 2014، وأظهرت النتائج عدم تمتع معظم مصارف العينة بالاستقرار المالي خلال الفترة المدروسة، كما بينت مدى ملاءمة مؤشر (Texas) لقياس إمكانية حدوث الفشل المالي. في سياق متصل، سعت دراسة

¹ يمثل مؤشر PSI (Population Stability Index) أداة إحصائية تُستخدم على نطاق واسع في مجال الخدمات المالية لتقييم مدى دقة نماذج التنبؤ بمرور الوقت، إذ يقيس التغيرات في توزيع متغير واحد بين فترتين زمنيتين مختلفتين، مما يساهم في تحديد ما إذا كان النموذج لا يزال صالحاً للتطبيق أم أنه يحتاج إلى إعادة تدريب أو تعديل (Ariza et al., 2024).

² يقيس مؤشر (Texas) إمكانية حدوث التعثر المالي، ويتكون من نسبة الأصول غير المنتجة (القروض غير المنتجة + صافي الأصول الثابتة) / مخصصات القروض غير المنتجة + حقوق الملكية.

(زرير والحموي، 2016) إلى التأكد من قدرة تمثيل مؤشر (Z-score) للاستقرار المالي للمصارف السورية التقليدية الخاصة خلال الفترة 2010-2014 باستخدام سلسلة بيانات بانل، وظهرت النتائج ملائمة مؤشر (Z-score) لقياس الاستقرار المالي للمصارف عينة الدراسة، كما بيّنت تمتع كافة العينة بالاستقرار المالي. من جانب آخر، قام (الحكيم، 2020) بدراسة التشخيص المالي والاستراتيجي لبنك بيمو السعودي الفرنسي خلال الفترة (2015-2019) من خلال تحليل مؤشرات عدة مثل (إدارة التسهيلات الائتمانية، جودة السيولة، جودة الأرباح، الربحية، الكفاءة التشغيلية، الملاءة المالية، ومؤشرات السوق)، حيث تمّ حساب مؤشرات التشخيص المالي بالاعتماد على البيانات المالية، بينما تمّ حساب التشخيص الاستراتيجي من خلال مقابلات مع المدراء لتحديد نقاط القوة والضعف والتهديدات المؤثرة على عمل المصرف، وأشارت نتائج الدراسة إلى أنّ أهمية التشخيص المالي والاستراتيجي في تصوير الوضعية المالية للبنك.

بالرغم من تزايد الدراسات حول الاستقرار المصرفي واعتماد تقنيات الذكاء الاصطناعي في تقييم المخاطر المصرفية، إلا أنّها ركزت بشكل رئيس على القطاعات المصرفية المستقرة أو الناشئة، مع إيلاء اهتمام قليل للبيئات التي تتسم بالتقلبات الجيوسياسية والعقوبات الاقتصادية وضعف البنية التحتية المالية. علاوةً على ذلك، اعتمدت الدراسات السورية السابقة على المناهج الإحصائية التقليدية والنسب المحددة مسبقاً، متجاهلةً التفاعلات غير الخطية والمعقدة داخل البيانات المالية.

بناءً عليه، تبرز الفجوة البحثية في تطبيق تقنيات التعلم الآلي المتقدمة - وخاصةً شبكات MLP العصبية - لتقييم القدرة التنبؤية للمؤشرات المالية في السياق المصرفي السوري، لذا يسعى البحث الحالي إلى سدّ هذه الفجوة من خلال تطوير نموذج قائم على الذكاء الاصطناعي، مُصمّم بشكل خاص للقطاع المصرفي السوري.

3. أهداف البحث:

يهدف هذا البحث إلى تحقيق ما يلي:

1. تطوير نموذج تنبؤي يعتمد على الشبكات العصبية متعددة الطبقات (MLP) للتنبؤ بمستوى الاستقرار المصرفي في المصارف السورية الخاصة، باستخدام مجموعة من المؤشرات المالية للفترة (2010-2023).
2. مقارنة أداء نموذج الشبكة العصبية (MLP) بنماذج تقليدية بديلة مثل شجرة القرار (DT)، لتقييم مدى تفوق النموذج المقترح من حيث القدرة التفسيرية ودقة التنبؤ.
3. تحليل تأثير المؤشرات المالية المختلفة على مستوى الاستقرار المصرفي باستخدام تقنية Permutation Importance، وتحديد الميزج الأمثل للمؤشرات التي تسهم في تحسين دقة التنبؤ.

4. أهمية البحث:

يسعى هذا البحث إلى توظيف تقنيات الذكاء الاصطناعي في القطاع المصرفي، عبر تقديم نموذج متقدّم باستخدام الشبكات العصبية يتيح التنبؤ المبكر بالاستقرار المصرفي، مما يُعزز قدرة الجهات الرقابية والمصارف على اتخاذ قرارات استباقية للحدّ من المخاطر المالية. في سورية، تزداد أهمية هذا البحث في البيئة المصرفية السورية، التي تعاني من تحديات اقتصادية مركّبة تشمل العقوبات الاقتصادية، تقلبات سعر الصرف، ارتفاع نسب التعثر. وفي ظل غياب أدوات فعّالة للإنذار المبكر مثل (الشبكات العصبية متعددة الطبقات،

ونماذج الغابات العشوائية) والتي أثبتت قدرتها على التنبؤ المبكر بمخاطر التعثر وعدم الاستقرار، يُوقّر النموذج المقترح أداة تقنية قابلة للتطبيق العملي تساعد على تشخيص مواطن الضعف والقوة في أداء المصارف الخاصة.

5. مشكلة البحث:

يُعدّ الاستقرار المصرفي أحد المرتكزات الأساسية لسلامة النظام المالي، إذ يعكس قدرة المصارف على مواجهة الصدمات الداخلية والخارجية دون الإخلال بوظائفها الأساسية. في سورية، مرّ القطاع المصرفي الخاص بتحويلات هيكلية منذ انطلاخته عام 2001³، وتعمّقت تحدياته بعد عام 2011 نتيجة انطلاق الثورة السورية وما خلفته من تحديات سياسية واقتصادية الحادة، وما تبعها من عقوبات اقتصادية، وتقلبات سعر الصرف، وقيود على التعاملات المصرفية الدولية. في ظل هذا ما سبق، تعرّضت المصارف السورية لمخاطر متزايدة تمثّلت فيما يلي: ضعف نسب السيولة بمتوسط بلغ (12-) %، وارتفاع نسبة القروض المتعثرة بمتوسط (148) %، خلال فترة الدراسة؛ وتراجع مؤشرات الربحية (ROA, ROE) في العديد من السنوات (زرير والحُموي، 2016؛ يوسف، 2023)، ما أدى إلى شكوك حول مدى قدرتها على الاستمرار، ومن ثم الحاجة الملحة لنماذج تنبؤية قادرة على تشخيص الوضع المصرفي بدقة وتنبؤ باحتمالات عدم الاستقرار في وقت مبكر. وهنا تبرز التساؤلات الرئيسة للبحث:

1- ما مدى قدرة نموذج الشبكة العصبية متعددة الطبقات (MLP) للتنبؤ بالاستقرار المصرفي باستخدام مجموعة من المؤشرات المالية في بيئة المصارف التجارية الخاصة السورية؟

2- هل يعد أداء نموذج الشبكة العصبية (MLP) أفضل من أداء نموذج شجرة القرار (DT)، من حيث القدرة التفسيرية ودقة التنبؤ؟

3- ما هو المزيج الأمثل للمؤشرات المالية التي تسهم في تحسين دقة التنبؤ بالاستقرار المصرفي باستخدام نموذج الشبكة العصبية متعددة الطبقات (MLP)؟

6. منهجية البحث:

اعتمد هذا البحث على منهجية التحليل الإحصائي الكمي، إذ تمّ الدمج بين أدوات الذكاء الاصطناعي والتحليل المالي، وفيما يتعلق بالجانب التطبيقي، تمّ الاعتماد على لغة البرمجة Python لتنفيذ النماذج التنبؤية، وذلك لكونها تمتلك مكتبات متخصصة في الذكاء الاصطناعي مثل (Keras, scikit-learn) التي توفر أدوات لبناء الشبكات العصبية ومعالجة العلاقات غير الخطية بين البيانات المالية. كما تعد برمجية مفتوحة المصدر، وتتيح إمكانية إعادة التطبيق بمرونة، مما يجعلها الأكثر ملاءمة في تطبيق خوارزميات متعددة ومقارنة أدائها. تشمل خطوات التحليل ما يلي:

● **العينة والفترة الزمنية:** تمّ استخدام بيانات مالية سنوية للفترة الزمنية (2010-2023) على عينة مكونة من المصارف التجارية الخاصة المدرجة في سوق دمشق للأوراق المالية، والبالغ عددها إحدى عشر مصرفاً. تمّ اختيار الفترة الزمنية نظراً

³ رسم القانون /28/ البيئة التشريعية النازمة لعمل المصارف، وقد أعقبه صدور القانون رقم /23/ عام 2002، الخاص بمجلس النقد والتسليف، وإعادة إحياء دوره بعد أن توقف لسنوات طويلة. وكان صدور هذا القانون أولى خطوات الإصلاح والذي أرسى نظام النقد الأساسي في سورية، وسمح بقيادة النظام النقدي والمصرفي في سورية بأسلوب حديث. وكان الخطوة الأولى على طريق استقلالية المصرف المركزي، حيث نص على اعتبار مصرف سورية المركزي مؤسسة عامة ذات استقلال مالي وإداري تتولى تنفيذ السياسة النقدية الاقتصادية المعتمدة من قبل مجلس الوزراء. وحدد القانون أهم مهام مصرف سورية المركزي في إدارة السياسة النقدية، وإصدار النقد، والرقابة على المؤسسات المصرفية، وإدارة الاحتياطيّات الأجنبية الرسمية، بالإضافة إلى كونه مصرف الحكومة ومستشارها المالي (التقرير السنوي لمصرف سورية المركزي، 2014).

لكون عام 2010 يمثل تاريخ الانطلاق الفعلي لسوق دمشق للأوراق المالية، وهو ما يضمن توافر بيانات مالية سنوية موحدة. كما تم استثناء المصارف الإسلامية من هذا البحث نظراً لخصوصية عملها المتمثلة في الامتثال لأحكام الشريعة الإسلامية، والتي قد تؤدي إلى اختلاف في مصادر المخاطر، وهيكّل الأصول والخصوم، وبالتالي في مؤشرات قياس الاستقرار المصرفي مقارنة بالمصارف التجارية.

- معالجة البيانات: تمّ توحيد البيانات (Standardization)، وإزالة القيم المتطرفة.
- تقسيم البيانات: تمّ تقسيم البيانات إلى 80% تدريب، و20% اختبار باستخدام دالة (train_test_split) لضمان تقييم النموذج.
- بناء النموذج التنبؤي باستخدام MLP: تمّ تصميم 5 نماذج شبكية بمبائل مختلفة، ثمّ تمّ تقييم الأداء باستخدام اختبارات متعددة مثل (RMSE, MSE, R²).
- مقارنة الأداء التنبؤي: تمّ إجراء مقارنة أداء نموذج الشبكة العصبية (MLP) بنماذج تقليدية بديلة مثل شجرة القرار (DT)، لتقييم مدى تفوق النموذج المقترح من حيث القدرة التفسيرية ودقة التنبؤ.
- تحليل أهمية المتغيرات: تمّ تحليل أثر المؤشرات المالية المستخدمة في بناء النموذج التنبؤي الأساسي باستخدام تقنية Permutation Importance.
- اختبار النماذج البديلة باستخدام المؤشرات الأكثر تأثيراً.

7. التأسيس النظري:

1.7. مفهوم الاستقرار المصرفي:

يُعدّ الاستقرار المصرفي دعامة أساسية للاستقرار الاقتصادي، فهو يعكس مدى كفاءة القطاع المصرفي في أداء مهامه الأساسية المتمثلة بالوساطة المالية، إدارة المخاطر، تمويل الاستثمار، وحفظ المدخرات. إذ يشير الاستقرار المصرفي إلى سلامة الوضع المالي للمصارف وقدرتها على تخصيص الموارد بكفاءة، مما يجنبها أي اضطرابات كبيرة أو انهيارات قد تقوض الثقة بها (Kvashuk et al., 2023). كما عرّفه صندوق النقد الدولي (IMF, 2013) بأنه "القدرة المستمرة للنظام المالي على مقاومة الصدمات الاقتصادية والمالية والقيام بدوره بكفاءة"، ويشكل القطاع المصرفي جوهر هذا النظام في معظم الاقتصادات.

يُعدّ مؤشر (Z-score) من بين المؤشرات المستخدمة لتقييم الاستقرار المصرفي، إذ يعكس صورة متطورة عن نماذج التنبؤ الثنائي ذات النسب المالية المعقدة، والتي تستخدم في القياس والتنبؤ المالي، ويعد هذا المؤشر الذي وضعه Altman عام 1968 مقياساً شائعاً لقياس السلامة المصرفية وفي حالة تعثر المصرف ويحسب وفق المعادلة التالية (Altman, 1968):

$$Z = \frac{ROA + \left(\frac{Equity}{Assets}\right)}{\sigma ROA} \dots (1)$$

حيث أنّ: ROA : العائد على الأصول، $\left(\frac{Equity}{Assets}\right)$: حقوق الملكية إلى إجمالي الأصول، σROA : الانحراف المعياري للعائد على الأصول، وكلما ارتفعت قيمة مؤشر (Z-SCORE) كلما دل ذلك على احتمال البقاء في حالة الاستقرار المصرفي، والعكس صحيح.

لضمان استمرارية الاستقرار المصرفي كركيزة أساسية للاقتصاد، تتجلى أهمية مؤشرات التنبؤ به كأدوات فعالة لقياس وتقييم النظام المصرفي والإنذار المبكر بأي مخاطر محتملة.

2.7. مؤشرات التنبؤ بالاستقرار المصرفي

يُمكن التنبؤ بالاستقرار المصرفي من خلال استخدام مؤشرات كمية تعكس الوضع المالي والتشغيلي للمصارف، حيث ركزت العديد من الدراسات السابقة على المؤشرات الموضحة في الجدول (1) بوصفها تمثل الأبعاد الأساسية للاستقرار كما يلي:

الجدول رقم (1): المتغيرات المستخدمة في النموذج التنبؤي

اسم المتغير	طريقة القياس	مبرر استخدامه في النموذج التنبؤي	دراسات سابقة
ROA	صافي الربح بعد الضريبة / إجمالي الأصول	يقيس كفاءة البنك في استخدام أصوله لتوليد الأرباح، وهو مؤشر مباشر على الأداء المالي.	Alqahtani et al. (2017)
ROE	صافي الربح بعد الضريبة / حقوق الملكية	يعكس قدرة المصرف على مقاومة الضغوط المالية والاستمرار في تحقيق نتائج إيجابية في الأجل الطويل	Alqahtani et al. (2017)
CAR	رأس المال التنظيمي / الأصول المرجحة بالمخاطر	يعكس قدرة البنك على امتصاص الخسائر، وتحمل المخاطر، وهو مؤشر رئيسي للاستقرار وفقاً لمقررات بازل	Paule-Vianez et al., (2019)
Leverage	إجمالي الديون / حقوق الملكية	يستخدم لقياس مدى اعتماد البنك على الدين في التمويل، مما قد يزيد المخاطر في حالات الضغوط.	Altunöz, (2024)
Loans/Deposits	إجمالي القروض / إجمالي الودائع	يقيس سيولة البنك ومدى اعتماده على التمويل من الودائع مقابل توجيهها للإقراض.	Paule-Vianez et al., (2019)
Bank Size	اللوغاريتم الطبيعي لإجمالي الأصول	يُستخدم لاختبار تأثير الحجم على الاستقرار، حيث يُعتقد أن البنوك الأكبر أكثر تنوعاً وأماناً.	Altunöz, (2024)
Liquid Assets/Liquid Liabilities	الأصول السائلة / الخصوم السائلة	يقيس قدرة البنك على الوفاء بالتزاماته قصيرة الأجل، وهو عنصر مهم في تحليل السيولة والاستقرار.	Altunöz, (2024)
NPL / Total Loans	القروض المتعثرة / إجمالي القروض	يقيس جودة الأصول الائتمانية، وارتفاعه يعني تراجع القدرة على التحصيل مما يهدد الاستقرار.	Liu et al., (2024)
Operational Efficiency	المصاريف التشغيلية / الإيرادات	مؤشر على مدى كفاءة إدارة البنك للموارد، وتراجع الكفاءة قد يؤثر سلباً على الأداء والاستقرار.	An et al., (2024)

Reid et al., (2014)	يوضح مدى اعتماد البنك على التمويل عبر رأس المال لتغطية القروض، ويعكس المخاطر الائتمانية.	إجمالي القروض / حقوق الملكية	Loan/Equity Ratio
Reid et al., (2014)	يعكس هيكل رأس المال والمخاطر التمويلية، وكلما زادت النسبة زادت هشاشة البنك في الأزمات.	إجمالي الالتزامات / حقوق الملكية	Total Liabilities/Equity Ratio

المصدر من إعداد الباحثين استناداً إلى الدراسات السابقة

بناءً على العرض السابق، سيتم الاعتماد على المؤشرات الموضحة في الجدول (1) لبناء النموذج التنبؤي الخاص في الدراسة الحالية.

3.7. الشبكات العصبية:

تعدّ الشبكات العصبية إحدى تقنيات الذكاء الاصطناعي، وتُعرف بأنها مجموعة من العقد والوحدات وعناصر المعالجة البسيطة المترابطة، وتعتمد وظيفتها بشكل أساسي على الخلايا العصبية. بمعنى آخر، هي خوارزمية تعلم آلي تُحاكي طريقة نقل الخلايا العصبية البيولوجية للإشارات فيما بينها (Gurney, 2018; Macukow, 2016). علاوةً على ذلك، أصبحت الشبكات العصبية أكثر تطوراً وتعقيداً من الأساليب التقليدية، إذ تمثل الأسلوب المثالي لتمثيل العلاقات بين المتغيرات، وتتكون من مجموعة مركبة من عناصر المعالجة الضخمة القادرة على إجراء العمليات الحسابية المعقدة، ويطلق عليها العصبونات أو نيورونات (Neurons)، ثم يتم تخزين المعرفة العلمية وجعلها متاحة للاستخدام عن طريق ضبط الأوزان النسبية (عثمان، 2022).

في سياق التطور التاريخي، شهدت الفترة (1943-1949) المحاولات الأولى لإصدار الشبكات العصبية، وتميزت بتأسيس وتطوير أول نماذج الشبكات العصبية عام 1943. في عام 1958 اقترح Rosenblatt المدرك، الذي شكّل أساس الشبكات العصبية وآلات المتجهات الداعمة. أما في عام 1986، فقد اقترح (Rumelhart; Hinton; and Williams) خوارزمية الانتشار الخلفي، وهي طريقة فعّالة في تدريب الشبكات العصبية متعددة الطبقات (MLP)، ومكّنتها من حل مسائل غير خطية أكثر تعقيداً. وفي عام 1997، اقترح (Hochreiter and Schmidhuber) شبكة ذاكرة قصيرة الأمد (LSTM)، وهي شبكة عصبية متكررة مُحسّنة (RNN) حلت مشكلة اختفاء وانفجار التدرجات، في معالجة اللغة الطبيعية، والتعرف على الكلام، ومجالات أخرى.

يشهد عصر الشبكات العصبية اليوم تحولات جذرية، حيث أحرز تقدماً ملحوظاً في العديد من المجالات كالتصنيف، التجميع، والنماذج التنبؤية، مما يجعلها تُقدّم دعماً فعالاً في التعامل مع المشكلات المعقدة وغير المعقدة في العديد من المجالات الاقتصادية، الصحية، النفسية، الاجتماعية وغيرها.

4.7. أنواع الشبكات العصبية:

تتميز الشبكات العصبية بمزايا تتفوق بها على النماذج الإحصائية والاقتصادية القياسية التقليدية في تقييم المخاطر المالية، نظراً لقدرتها على نمذجة العلاقات غير الخطية دون افتراضات صارمة حول توزيع البيانات (Chen et al., 2025). وتُستخدم أنواع عديدة من هياكل الشبكات العصبية، ومنها:

✓ الشبكات العصبية الاصطناعية (ANN) Artificial Neural Networks: النطاق الأوسع للشبكات العصبية، يُشير بشكل عام إلى أي شبكة تتكون من وحدات حسابية (خلايا عصبية اصطناعية) تُشبه الخلايا العصبية في الدماغ، ولها استخدامات عدة منها: (التصنيف (مثل تصنيف الصور، النصوص)، التنبؤ (مثل أسعار الأسهم)، الترجمة الآلية، والتمييز الصوتي) (Altunöz, 2024).

✓ الشبكات متعددة الطبقات (MLP) Multilayer Perceptron: نوع من الشبكات العصبية الاصطناعية يتكون من طبقات متعددة من الخلايا العصبية الاصطناعية (داخلة، مخفية، وخارجة)، وهو أحد أبسط أنواع الشبكات العميقة، يُستخدم في مهام تنبؤ متنوعة، بما في ذلك الأزمات المصرفية، المخاطر المالية، والاستقرار المالي (Reid et al., 2014).

✓ الشبكات العصبية التلافيفية (CNN) Convolutional Neural Networks: تُستخدم لمعالجة بيانات السلاسل الزمنية المالية كصور، والتقاط الارتباطات المعقدة بين الأصول، كما تُستخدم في التدقيق المالي وأنظمة التحذير من المخاطر (Zhao et al., 2023) ; (Wang et al., 2024).

✓ الشبكات العصبية المتكررة (RNNs) Recurrent Neural Networks: نوع من الشبكات العصبية الاصطناعية يستخدم في معالجة البيانات المتسلسلة أو الزمنية، إذ يحتفظ بمعلومات عن المدخلات السابقة. يعدّ مناسباً لبيانات السلاسل الزمنية نظراً لقدرته على حفظ المدخلات السابقة، ويشتهر منه شبكات الذاكرة طويلة المدى (LSTM)، وهي نوع من الشبكات العصبية المتكررة، فعالة بشكل خاص في التنبؤ المالي (An et al., 2024)، (Liu et al., 2024).

✓ الشبكات العصبية البيانية (GNNs) Graph Neural Networks: نوع من الشبكات العصبية الاصطناعية يستخدم للتعامل مع البيانات الممثلة على شكل رسوم بيانية، إذ تتمثل البيانات في عقد وروابط. كما أنّها مصممة لنمذجة العلاقات المعقدة داخل البيانات المالية الممثلة كرسوم بيانية، مما يجعلها مناسبة للتنبؤ بالضائقة المالية، يمكن لشبكة عصبية بيانية معززة بالانتباه (AE-GNN) التقاط الترابطات غير الخطية المعقدة (Zhao et al., 2023; Wang et al., 2024).

5.7. التجارب والأدلة

أظهرت العديد من الدراسات فعالية الشبكات العصبية في التنبؤ بمجال استقرار القطاع المصرفي، سواء بشكل مباشر أو غير مباشر من خلال العوامل المؤثرة فيه:

- التنبؤ بالتخلف عن السداد: تُستخدم نماذج التعلم الآلي، بما في ذلك الشبكات العصبية، للتنبؤ بتخلف المقترضين عن السداد، مع تقييم المرونة باستخدام مقاييس مثل مؤشر استقرار السكان (Altunöz, 2024).
- التنبؤ بالأزمات المصرفية: طبقت الشبكات العصبية على القطاعين المصرفيين التركي والإسباني للتنبؤ بالضائقة المالية باستخدام متغيرات مالية تستند إلى رأس المال والأصول والإدارة والأرباح والسيولة (Paule-Vianez et al., 2019).
- تقييم الاستقرار المالي: تُستخدم الشبكات العصبية لتقييم الاستقرار المالي للمؤسسات من خلال مراعاة التسويق، واستقرار الموظفين، والقدرة الإنتاجية، والوضع المالي (Kvashuk et al., 2023).
- التنبؤ بمخاطر الائتمان: تُقارن الانحدار اللوجستي (LR) والشبكات العصبية الاصطناعية (ANN) للتنبؤ بمخاطر الائتمان في القطاع المصرفي البريطاني، وتحليل البيانات المالية وغير المالية الفصلية (Altunöz, 2024).
- التنبؤ بأسعار الأسهم: تُستخدم نماذج قائمة على شبكات GAN مع LSTM أو GRU كمودلات للتنبؤ بأسعار الأسهم، بهدف تحسين استخلاص الميزات ودقة التنبؤ، إذ يمكن أن يُحسن دمج مؤشرات التحليل الفني مع الشبكات العصبية البحث عن نقاط تداول مربحة (Shi et al., 2021).
- التنبؤ بمخاطر السيولة: تُستخدم الشبكات العصبية للتنبؤ بمخاطر السيولة في البنوك الخاصة الهندية، وهو أمر مهم لإدارة ومراقبة مخاطر السيولة كما هو موضح في توصيات بازل (KV et al., 2024).
- التنبؤ بالمخاطر المالية: تُستخدم الحقول العشوائية الشرطية (CRFs) لالتقاط العلاقات بين البيانات المالية، مما يُحسن التنبؤ بالمخاطر المالية (Guishan, 2025).

6.7. بعض قيود الشبكات الاصطناعية:

إنّ قدرة الشبكات العصبية على نمذجة العلاقات بين المتغيرات وتحسين دقة التنبؤ لها آثار كبيرة على المؤسسات المالية وهيئات التنظيمية والمستثمرين. فالتنبؤ المبكر والدقيق بعدم استقرار القطاع المصرفي يُمكن من التدخل في الوقت المناسب، مما يُخفف من المخاطر المالية ويمنع الأزمات المالية. علاوة على ذلك، يُمكن لهذه النماذج أن تُعزز ممارسات إدارة المخاطر، وتُحسن استراتيجيات الاستثمار، وتُحسن رضا العملاء في الخدمات المصرفية (Kvashuk et al., 2023).

على الرغم من مزاياها، إلا أن الشبكات العصبية لها أيضاً قيود (Altunöz, 2024; Wang, 2023):

- الاعتماد على البيانات: تتطلب الشبكات العصبية كميات كبيرة من البيانات عالية الجودة للتدريب، التي قد لا تكون متاحة دائماً أو موثوقة في المجال المالي.
- الإفراط في التجهيز: الشبكات العصبية معرضة للإفراط في التجهيز، خاصةً مع البيانات المالية المضطربة أو المتقلبة.
- القدرة على التعميم: قد لا تتمكن النماذج المدربة على البيانات التاريخية من التعميم بشكل جيد على ظروف السوق الجديدة أو غير المتوقعة.

8. النتائج والمناقشة:

1. اختبار دقة الأداء التنبؤي للنموذج الأساسي (MLP) باستخدام كافة المؤشرات الـ(11):

الخطوة الأولى: لتوحيد البيانات (Standardization)، ومعالجة القيم المتطرفة باستخدام قاعدة الانحراف المعياري على جميع المؤشرات المالية المستخدمة، تم استدعاء دالة (`fit_transform(data)`) بهدف جعل قيم المؤشرات ضمن نطاق متوازن للتحليل، مما يساهم في تقليل تأثير القيم الشاذة المتطرفة.

الخطوة الثانية: بعد معالجة البيانات من القيم المتطرفة وتوحيدها (Standardization)، تم استدعاء دالة (`train_test_split`) من مكتبة (`scikit-learn`) لتقسيم البيانات إلى: 80% تدريب (Training Set) لتدريب النماذج (تعديل الأوزان الداخلية)، و20% اختبار (Testing Set) تُستخدم بعد التدريب لتقييم أداء النماذج. ثم تم استدعاء دالة (`model.fit(X_train, y_train)`) إذ تم تدريب نموذج شبكة عصبية متعددة الطبقات (MLP) باستخدام كافة المؤشرات المالية الـ 11، وأظهرت النتائج 5 نماذج مختلفة من الشبكات العصبية متعددة الطبقات (MLP) بمعايير مختلفة، كما يوضح الجدول (2):

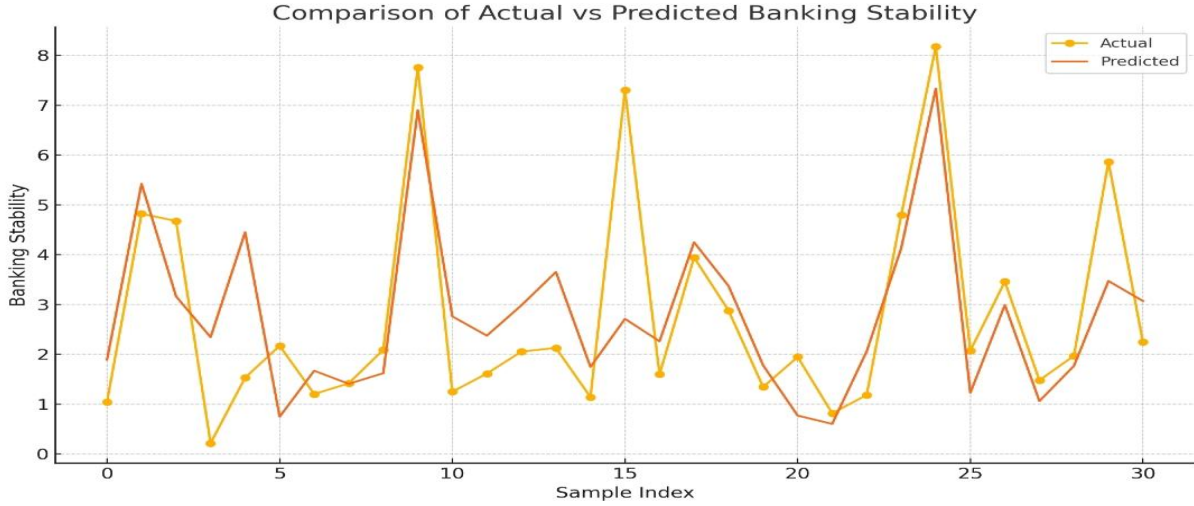
الجدول رقم (2): نتائج تدريب الشبكات العصبية

النموذج	RMSE (الجذر التربيعي لمتوسط مربع الخطأ)	MSE (متوسط مربع الخطأ)	R ² (معامل التحديد)
MLP_1Layer_50	1.3794	1.9027	0.5626
MLP_2Layers_50_25	3.9199	15.3658	-2.5324
MLP_3Layers_100_50_25	1.9331	3.7367	0.1410
MLP_2Layers_100_50	2.4112	5.8140	-0.3366
MLP_3Layers_150_75_30	1.7230	2.9687	0.3175

المصدر: من إعداد الباحثين استناداً إلى مخرجات برمجية Python

يُلاحظ من نتائج الجدول (2) أنّ النموذج الأوّل المتمثل بـ **MLP_1Layer_50** (طبقة مخفية واحدة بـ 50 خلية) قد حقق أفضل أداء من حيث دقة التنبؤ بالاستقرار المصرفي، إذ حقق أفضل النتائج (أقل متوسط مربع الخطأ (MSE) حيث بلغ 1.9027، ومعامل تفسير جيد (R²) حيث بلغ 0.5626). بناءً على ما سبق، تشير هذه النتائج إلى أنّ النموذج استطاع تفسير ما يقارب 56.26% من التغيرات في مؤشر الاستقرار المصرفي، وهو أداء جيد بالنظر إلى الطبيعة غير الخطية للبيانات المالية المصرفية في البيئة السورية، كما أنّ حجم الخطأ مقبول نسبياً إذ يدعم إمكانية اعتماد هذا النموذج كأداة للتنبؤ بمستويات الاستقرار المصرفي.

استناداً إلى استخدام النموذج **MLP_1Layer_50** للتنبؤ بالاستقرار المصرفي، يظهر الشكل البياني رقم (1) المقارنة بين القيم الفعلية والمتوقعة كما يلي:



الشكل رقم (1): المقارنة بين القيم الفعلية والتنبؤية لمؤشر الاستقرار المصرفي (كامل المؤشرات)

المصدر: مخرجات برمجية Python

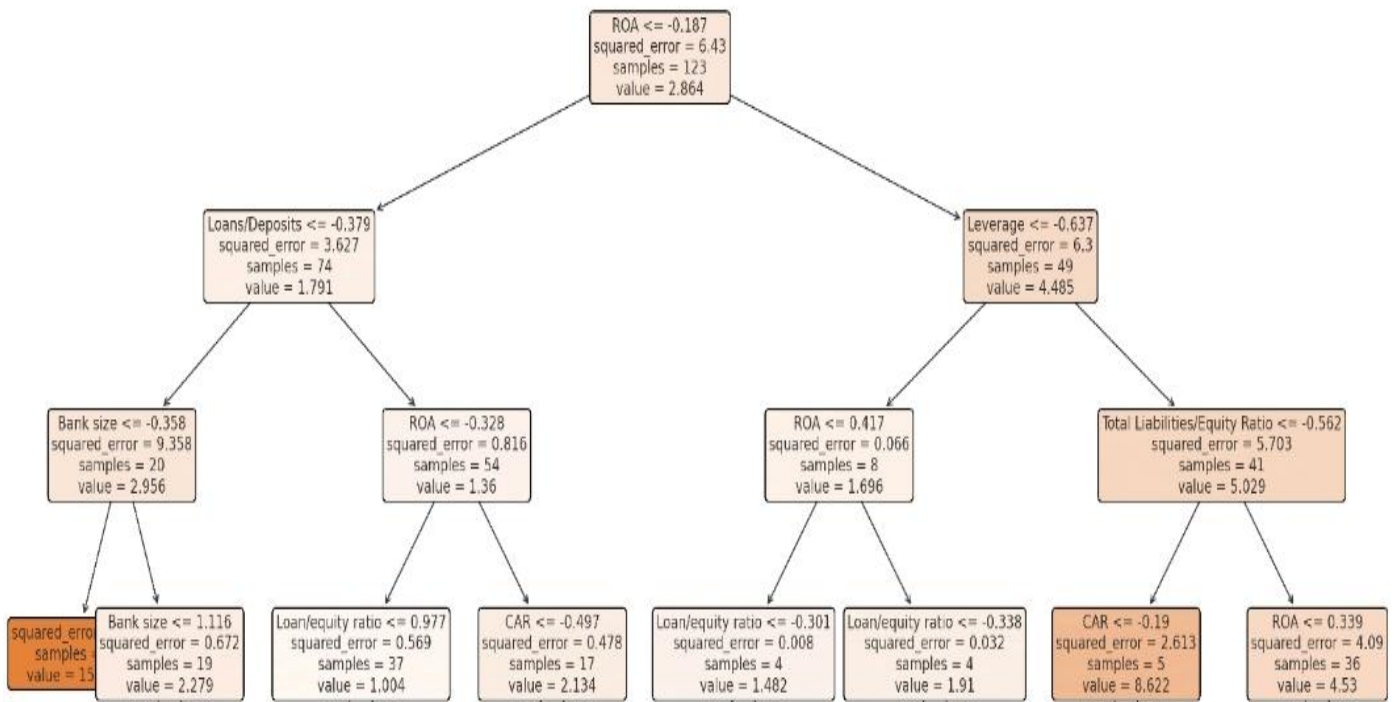
يظهر الشكل رقم (1) أنّ النموذج يقترب بدرجة مقبولة من القيم الحقيقية في العديد من النقاط، مع وجود بعض الفروقات في بعض العينات.

2. مقارنة الأداء التنبؤي بين نموذج الشبكة العصبية متعددة الطبقات **MLP** (المختار) ونموذج شجرة القرار **DT**.

تمثل نماذج شجرة القرار (**Decision Tree**) خوارزميات تعلم آلي، إذ تُستخدم في مهام التصنيف و/أو الانحدار، كما تقوم ببناء نموذج على شكل شجرة لاتخاذ قرارات مرتكزة على بيانات الإدخال. في حالة البحث الحالي (التنبؤ بالاستقرار المصرفي) تم تقسيم البيانات إلى مجموعات فرعية للوصول إلى القيمة المستهدفة الأفضل في كل فرع، تتكون شجرة القرارات من عقدة جذرية (**Root Node**): أول نقطة تقسم البيانات حسب المتغير الأكثر تأثيراً، عقد داخلية (**Internal Nodes**): الاستمرارية في التقسيم، الأوراق (**Leaves**): تمثل القيم النهائية أو التنبؤية.

في الخطوة الأولى تم تحليل كافة المؤشرات المالية، ثم تم اختيار العقدة الأفضل لتقسيم البيانات باستخدام مقياس (MSE, R^2) ، ثم تم بناء النموذج النهائي باستخدام أسلوب التقسيم المتكرر (Recursive Partitioning)، وأظهرت النتائج وفق الشكل رقم (2) الذي يوضح البنية الهيكلية لنموذج شجرة القرار (بعمق 3 مستويات بهدف التبسيط البصري) والمدرب على بيانات الاستقرار المصرفي للمصارف الخاصة التجارية السورية خلال الفترة (2010-2023) باستخدام المؤشرات المالية الـ (11)، أن المؤشرات التي تقع في العقد العلوية للشجرة تمثل العوامل الأكثر تأثيراً في النموذج وهي: ROA، الرافعة المالية (Leverage)، القروض/الودائع (Loans/ Deposits).

Decision Tree Structure (Depth: 3)



الشكل رقم (2): البنية الهيكلية لنموذج شجرة القرار

المصدر: مخرجات برمجية Python

بعد بناء النموذج التنبؤي استناداً إلى خوارزمية شجرة القرار (Decision Tree)، تم استدعاء دالة $(DecisionTreeRegressor(). fit())$ لمقارنة الأداء التنبؤي بينه وبين نموذج MLP_1Layer_50 وأظهرت النتائج ما يلي:

الجدول رقم (3): مقارنة الأداء التنبؤي بين نمودي Decision Tree و MLP

R ²	MSE	RMSE	النموذج
0.563	1.903	1.379	MLP_1Layer_50
0.159	3.659	1.913	Decision Tree

المصدر: من إعداد الباحثين استناداً إلى مخرجات برمجية Python

يُلاحظ من نتائج الجدول (3) أنّ أداء نموذج الشبكات العصبية (MLP_1Layer_50) كان أفضل بكثير من نموذج Decision Tree، إذ يشير معامل التحديد R^2 إلى أنّ MLP يفسر حوالي 56.3% من التباين في الاستقرار المصرفي بينما لم يفسر نموذج الشجرة إلا 15.9%، كما يُظهر الجدول أنّ (MSE, RMSE) أقل بكثير في MLP.

3. تحليل أهمية المتغيرات المستقلة:

باستخدام تقنية Permutation Importance، تمّ استدعاء دالة (permutation_importance(model, X_test, y_test)) لقياس أهمية كل مؤشر مالي من خلال مقارنة أداء النموذج المختار MLP_1Layer_50 قبل وبعد خلط قيم هذا المؤشر عشوائياً، بهدف قياس التأثير النسبي لكل مؤشر على دقة النموذج، وأظهرت النتائج أنّ أكثر المؤشرات تأثيراً على التنبؤ بالاستقرار المصرفي كانت كما يعرضها الجدول (4):

الجدول رقم (4): الأهمية النسبية للمؤشرات المالية

الترتيب	المؤشر المالي	الأهمية النسبية
1	Total Liabilities/Equity	0.1645
2	Loan/Equity	0.1451
3	Leverage	0.1311
4	CAR	0.1126
5	Bank Size	0.1048
6	ROE	0.0994
7	NPL/ Total Loans	0.0982
8	Loans/ Deposits	0.0869
9	Liquid assets/liquid liabilities	0.0805
10	Operational Efficiency	0.0647
11	ROA	0.0483

المصدر: من إعداد الباحثين استناداً إلى مخرجات برمجية Python

أظهرت نتائج الجدول (4) الخاص بتحليل أهمية المتغيرات باستخدام تقنية Permutation Importance أنّ المؤشرات الستة الأولى المتمثلة بـ (إجمالي الالتزامات/حقوق الملكية، إجمالي القروض/حقوق الملكية، الرافعة المالية، نسبة كفاية رأس المال، حجم المصرف، والعائد على حقوق الملكية) هي الأكثر تأثيراً في تفسير التغيرات بمؤشر الاستقرار المصرفي للمصارف السورية الخاصة خلال الفترة (2010-2023)، وهو ما يتسق مع واقع القطاع المصرفي السوري الذي يعاني من تحديات تمويلية وهيكلية متراكمة نتيجة الأوضاع الاقتصادية والسياسية (زير والحوي، 2016؛ يوسف، 2023).

علاوة على ما سبق، يعكس مؤشر إجمالي الالتزامات إلى حقوق الملكية (Total Liabilities/Equity) هشاشة البنية التمويلية للمصرف، إذ يؤدي ارتفاع هذه النسبة إلى اعتماد مفرط على مصادر التمويل الخارجية مقارنةً بقاعدة رأس المال، وهو ما يزيد من حساسية المصارف تجاه الأزمات ويُضعف قدرتها على الاستمرار، وهو ما أكدته دراسات سابقة مثل (Reid et al., 2014). وبالمثل، فإن ارتفاع نسبة القروض إلى حقوق الملكية (Loan/Equity) تعبر عن تصاعد المخاطر الائتمانية، ويُضعف

قدرة رأس المال على امتصاص الخسائر المحتملة المرتبطة بمحفظة الإقراض، خاصة في بيئة تتسم بارتفاع معدلات القروض المتعثرة كما أظهرت دراسة (الحكيم، 2020). أما الرافعة المالية (Leverage)، فتشير إلى مدى اعتماد المصارف على الديون، فهي تؤثر بشكل مباشر في هيكل المخاطر، إذ يؤدي الإفراط في استخدام الدين إلى تضخيم العوائد في الأوقات المستقرة، لكنه يزيد من احتمالية التعرض للأزمات في ظل بيئة متقلبة وهو ما أشارت إليه دراسة (Altunöz, 2024). من جهة أخرى، تمثل نسبة كفاية رأس المال (CAR) خط الدفاع الأساسي للمصارف، إذ تُظهر قدرة المصرف على امتصاص الخسائر وتعزيز استقراره المالي، وهو ما أكدته مقررات بازل الدولية ودراسات عديدة (Paule-Vianez et al., 2019). كذلك، فإن حجم المصرف (BS) يُعدّ مؤشراً حيوياً للاستقرار، إذ تتمتع المصارف الأكبر حجماً بقدرات عالية على تنويع الأنشطة والحد من المخاطر، فضلاً عن سهولة الوصول لمصادر تمويل أوسع، وهو ما ينسجم مع نتائج الدراسات حول تأثير وفورات الحجم على الاستقرار المالي (Altunöz, 2024). أخيراً، فإن العائد على حقوق الملكية (ROE) يعكس الأداء المالي للمصرف وقدرته على تحقيق أرباح مستدامة، وهو مؤشر جوهري لقياس مرونة المصرف في مواجهة الضغوط الاقتصادية والمالية، كما أشار دراسة (Alqahtani et al., 2017).

4. اختبار النماذج البديلة:

في هذه المرحلة، تم بناء عدة نماذج جديدة باستخدام التركيب السابق للمؤشرات في الجدول رقم (4) بهدف تحديد المزيج الأمثل من المؤشرات للتنبؤ بالاستقرار المصرفي، حيث تم البدء باستخدام أفضل 5 مؤشرات، ومن ثم إضافة مؤشر واحد تدريجياً في كل مرة، والجدول رقم (5) يوضح النتائج كما يلي:

الجدول رقم (5): اختبار النماذج البديلة

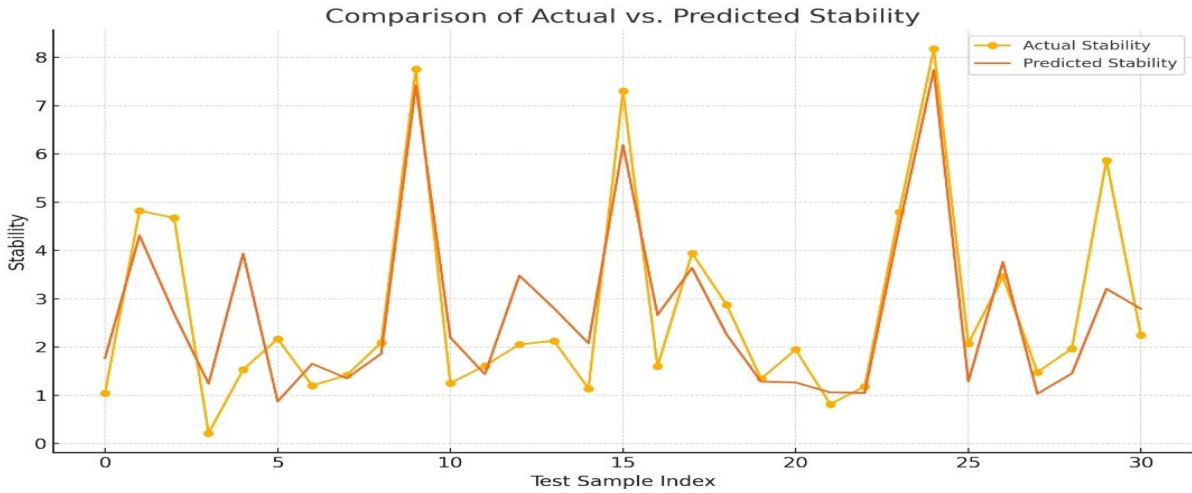
R ²	MSE	RMSE	المؤشرات المستخدمة	عدد المؤشرات
0.564	1.898	1.378	TL/Equity + Loan/Equity + Leverage + CAR + BS	5
0.776	0.973	0.986	+ROE	6
0.624	1.635	1.279	+NPL/ Total Loans	7
0.333	2.900	1.703	+Loans/ Deposits	8
-0.398	6.081	2.466	+Liquid assets/liquid liabilities	9
-0.137	4.948	2.224	+Operational Efficiency	10
0.273	3.161	1.778	+ ROA	11

المصدر: من إعداد الباحثين استناداً إلى مخرجات برمجية Python

يُلاحظ من الجدول (5) أنّ أفضل أداء للتنبؤ في الاستقرار المصرفي كان عند استخدام 6 مؤشرات، إذ بلغ معامل التفسير (R^2) ما يقارب 0.776 وهو أعلى قيمة من بين القيم الموجودة مع أقل مستوى للخطأ وفق اختباري (MSE, RMSE)، بمعنى أنّ النموذج أصبح قادر على تفسير ما يقارب 77.6% من التغيرات في مؤشر الاستقرار المصرفي. بناءً على ما سبق، فإن النتائج الإحصائية للنموذج التنبؤي التي أظهرت ارتفاع القدرة التفسيرية للنموذج عند استخدام هذه المؤشرات الستة تؤكد مدى مركزية هذه المؤشرات في تقييم الاستقرار المصرفي في البيئة السورية الخاصة، مقارنةً بباقي المؤشرات التي أظهرت تأثيراً أقل، وهو ما يعكس

خصوصية الأزمات الهيكلية والمخاطر التمويلية التي تواجهها المصارف السورية في ظل العقوبات الاقتصادية، تقلبات سعر الصرف، وضعف البيئة التشريعية والتقنية، الأمر الذي يجعل التركيز على هذه المؤشرات ضرورة في بناء نماذج التنبؤ الدقيقة، ودعم قرارات الإنذار المبكر وتعزيز متانة النظام المصرفي.

استناداً إلى استخدام النموذج **MLP_1Layer_50** للتنبؤ بالاستقرار المصرفي، مع 6 مؤشرات مالية فقط الموضحة في الجدول (5)، يظهر الشكل البياني رقم (3) المقارنة بين القيم الفعلية والمتوقعة كما يلي:



الشكل رقم (3): المقارنة بين القيم الفعلية والتنبؤية لمؤشر الاستقرار المصرفي (مع 6 مؤشرات)

المصدر: مخرجات برمجية Python

يُلاحظ من الشكل رقم (3) وجود تطابق بين القيم المتوقعة مع القيم الفعلية لمؤشر الاستقرار المصرفي، إذ تبين أن النموذج يتنبأ بدقة جيدة لمعظم العينات مع بعض الانحرافات البسيطة.

9. الاستنتاجات والتوصيات:

1.9. الاستنتاجات:

1. أثبت نموذج MLP (طبقة مخفية واحدة بـ 50 خلية) كفاءته في التنبؤ بالاستقرار المصرفي في بيئة اقتصادية مضطربة كالبيئة السورية، متفوقاً على النماذج التقليدية. يتسق هذا الاستنتاج مع ما أشار إليه Fernández (2020) الذي أكد تفوق نماذج الذكاء الاصطناعي على الأساليب التقليدية في التنبؤ بالاستقرار المصرفي في الولايات المتحدة. كما تتوافق النتائج مع ما توصلت إليه دراسة Zhou et al (2024) التي أثبتت قدرة نماذج التعلم العميق على تقديم دقة أعلى في التنبؤ بالمخاطر المالية مقارنة بالنماذج الإحصائية التقليدية.
2. كشف النموذج البديل (Decision Tree) عن محدودية قدرته على التقاط التفاعلات المعقدة بين المتغيرات، مما يعزز الحاجة لاستخدام نماذج الشبكات العصبية الأكثر تطوراً. يتوافق هذا الاستنتاج مع نتائج دراسة Ariza et al (2024) التي قارنت بين النماذج الكلاسيكية (مثل Decision Tree والانحدار اللوجستي) والنماذج القائمة على

الذكاء الاصطناعي، إذ أظهرت أن الشبكات العصبية تفوقت بوضوح في قدرتها على التعامل مع العلاقات غير الخطية المعقدة في البيانات المصرفية.

3. كانت المؤشرات المتعلقة بالتمويل (إجمالي الالتزامات/حقوق الملكية، والقروض/حقوق الملكية)، الرافعة المالية، وكفاية رأس المال إضافةً لحجم البنك هي الأكثر تأثيراً، ما يعكس طبيعة المخاطر التي تواجهها المصارف السورية. ينسجم هذا الاستنتاج مع نتائج دراسة Paule-Vianez et al (2019) التي أكدت أن مؤشرات كفاية رأس المال وجودة الأصول والسيولة هي من أبرز العوامل المؤثرة في الاستقرار المصرفي، كما تتفق النتائج مع Reid et al (2014) التي أبرزت أهمية مؤشرات الرافعة المالية والالتزامات إلى حقوق الملكية في تفسير هشاشة المصارف.

4. أظهر النموذج قدرة واضحة على العمل بكفاءة أعلى عند الاقتصار على أهم 6 مؤشرات، ما يعكس مرونة وذكاء تقنيات MLP في التقاط الأنماط الأكثر تأثيراً دون تشويش. يدعم هذا الاستنتاج ما طرحته دراسة Kvashuk et al (2023) التي أكدت أن الشبكات العصبية قادرة على تحسين الأداء التنبؤي عند التركيز على المتغيرات الأكثر تفسيراً للاستقرار.

2.9. التوصيات:

1. يوصي البحث بضرورة قيام المصارف التجارية الخاصة في سورية بتبني تقنيات الذكاء الاصطناعي، لاسيما الشبكات العصبية متعددة الطبقات (MLP)، ضمن أدوات التقييم المالي الداخلي كجزء من التحول الرقمي، لما أثبتته النموذج من قدرة على التنبؤ بمستوى الاستقرار المصرفي.
2. يوصي البحث مصرف سورية المركزي بتحديث وتحوّل منظومة الرقابة المصرفية لتصبح رقمية، من خلال دمج مؤشرات عالية التأثير - ك "نسبة الالتزامات إلى حقوق الملكية"، و "الرافعة المالية"، و "نسبة القروض إلى حقوق الملكية" - في نظام إنذار مبكر، نظراً لما أثبتته الدراسة من دور جوهري لهذه المؤشرات.
3. يوصي البحث بالتركيز على المؤشرات الستة الأكثر تأثيراً التي أثبتت فعاليتها في النموذج التنبؤي، بهدف تبسيط إجراءات التقييم وتقليل العبء الرقابي في ظل شحّ الموارد البشرية والتقنية.
4. ضرورة تحديث البنية التقنية لنظم إدارة المخاطر لتصبح رقمية وتنبؤية، من خلال دمج نتائج النماذج المعتمدة على الذكاء الاصطناعي ضمن منظومة التقييم الداخلي للملاءة والسيولة.
5. يوصي البحث بضرورة دعم المؤسسات الأكاديمية والبحثية لتطوير نماذج تنبؤية تأخذ بعين الاعتبار خصوصية الاقتصاد السوري، وقيوده التقنية والمعلوماتية، وتشجيع التعاون مع القطاع المصرفي.

10. حدود البحث:

هناك عدداً من القيود البحثية التي ينبغي أخذها بعين الاعتبار:

1. ارتبطت الدراسة بمحدودية جودة وتوافر البيانات المالية في السوق السورية، إذ اقتصر على المصارف الخاصة التجارية المدرجة منذ عام 2010، مما قد يؤثر على شمولية النتائج.

2. تعاني الشبكات العصبية من مخاطر الإفراط في التكيف (Overfitting)، خاصة مع البيانات المالية المتقلبة، رغم محاولات الحد منها عبر تقسيم البيانات إلى عينيّ تدريب (80%) واختبار (20%).
3. يعدّ تعميم النتائج على بيانات مصرفية أخرى خارج سورية محدوداً، وذلك لخصوصية الأزمة السياسية والاقتصادية والعقوبات الدولية التي واجهتها سورية.
4. لم يتطرق البحث الحالي إلى دمج المتغيرات الكلية (مثل معدلات النمو الاقتصادي، التضخم، أو سعر الصرف) التي قد تؤثر على الاستقرار المصرفي، وهو ما يمثل مجالاً مهماً للدراسات المستقبلية.

11. المراجع:

باللغة العربية:

- الحكيم، فراس. التشخيص المالي والاستراتيجي للمصارف السورية الخاصة: دراسة حالة بنك بيمو السعودي الفرنسي، رسالة ماجستير منشورة، الإدارة المالية: المعهد العالي لإدارة الأعمال، 2020.
- الحموي، نزمين. نموذج مقترح للتنبؤ المبكر بالفشل المالي في المصارف السورية الخاصة، رسالة ماجستير منشورة، كلية الاقتصاد: جامعة دمشق، 2016.
- زير، رانيا؛ الحموي، نزمين. مدى ملائمة مؤشر (Z-score) لقياس الاستقرار المالي للمصارف السورية الخاصة التقليدية، مجلة جامعة اللاذقية للبحوث والدراسات العلمية، سلسلة العلوم الاقتصادية والقانونية، 38(1)، عدد الصفحات (303-321)، 2016.
- عثمان، حسام. استخدام الشبكات العصبية متعددة الطبقات في التنبؤ بمخاطر الائتمان، مجلة الدراسات المالية والتجارية، العدد الأول: عدد الصفحات (169-219)، 2022.
- الناصر، بانه. تقييم الأداء المالي للمصارف الخاصة في سورية باستخدام مؤشرات CAEL، رسالة ماجستير منشورة، كلية الاقتصاد: جامعة حلب، 2012.
- يوسف، محمد فؤاد. أثر المخاطر الائتمانية في الأداء المالي للمصارف: دراسة تطبيقية على المصارف التجارية الخاصة في سورية للفترة (2010-2021)، مجلة حمص: سلسلة العلوم الاقتصادية والسياحية، المجلد 45 العدد 22، 2023.

باللغة الاجنبية:

- Alqahtani, F., Mayes, D. G., & Brown, K. Economic turmoil and Islamic banking: Evidence from the GCC. *Pacific-Basin Finance Journal*, 42, 210–221, 2017.
- Altman, E. I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, vol. 23, no. 4, pp. 589-609, 1968.
- Altunöz, U. Prediction of Banking Credit Risk Using Logistic Regression and The Artificial Neural Network Models: A Case Study of English Banks, *Journal of Social Research and Behavioral Sciences*, 2024, <https://doi.org/10.52096/jsrbs.10.21.32>.
- An, Z; Wu, Y; Hao, F; Chen, Y; He, X. A novel hierarchical feature selection with local shuffling and models reweighting for stock price forecasting, *Expert Systems with Applications, Elsevier*, 2024.

- Ariza, L; Aigimik, N. Machine Learning Models for Default Prediction in the Banking Sector: A Stability Assessment, *Ekonomika I Upravljenje: Problemy, Resheniya*, 2024.
- Bolotov, R; Suglobov, A. Using of neural networks for assessing of the financial stability of companies, *Russian Journal of Management*, PP: 106-110, 2020.
- Chen, X; Zhu, L. Attention-enhanced graph neural network for financial distress and bankruptcy risk prediction, *Applied Economics Letters*, 3(2), PP: 25-36, 2025.
- Fernández, J. United States banking stability: An explanation through machine learning, *Banks and Bank Systems*, 15(4), PP: 137-149, 2020.
- Giraldo, C; Giraldo, I. Gonzalez, J; Uribe, J. Financial integration and banking stability: A post-global crisis assessment, *Economic Modelling*, 4(2), 2024.
- Guishan, X. A Financial Risk Prediction Method Based on Conditional Random Fields, *International Journal of High-Speed Electronics and Systems*, 2025.
- Gurney, K. An introduction to neural networks. CRC press 2018.
- KV, S. Neural network-based liquidity risk prediction in Indian private banks, *Intelligent Systems with Applications*, V21, 1-23, 2024.
- Kvashuk, O; Vapriote, I; Onyskiv, A. Assessment of the Financial Stability of Enterprises Using Neural Networks, *Scientific Notes of Ostroh Academy National University, "Economics" Series*, 30(58)-76-83, 2023.
- Liu, W; Ge, Y. Multi-factor stock price prediction based on GAN-TrellisNet, *Knowledge and Information Systems*, 66(7):1-22, 2024.
- Macukow, B. Neural networks—state of art, brief history, basic models and architecture. In *Computer Information Systems and Industrial Management: 15th IFIP TC8 International Conference, CISIM 2016, Vilnius, Lithuania, September 14-16, Proceedings 15* (pp. 3-14), 2016.
- Minasyan, D, G. Banking stability multifactor modelling in Armenia using Machine Learning, *Регион и мир / Region and the World*, 2024.
- Paule-Vianez, J; Fernández, M; Pérez, J. Prediction of financial distress in the Spanish banking system, *Applied Economic Analysis*, Emerald group publishing, 2019.
- Reid, D; Hussain, A; Tawfik, H. Financial Time Series Prediction Using Spiking Neural Networks, 9(8), 2014, <https://doi.org/10.1371/journal.pone.0103656>.
- Shi, Y; Li, B; Long, W; Dai, W. Method for Improving the Performance of Technical Analysis Indicators by Neural Network Models, *Computational Economics*, 2021.
- Tölö, E. Predicting systemic financial crises with recurrent neural networks, *Journal of Financial Stability*, 6. (1), 2020.
- Vinnytska, O. Theoretical Approaches to The Assessment of The Financial Stability of Banking Institutions, *Economies' Horizons*, 2024.

Wang, W; Wang, Y; Liu, Y; Jiang, W. Unmanned System Financial Risk Warning Based on Convolutional Neural Networks, 4th International Conference on Machine Learning and Intelligent, 2024.

Zhao, H; Wang, Y. A Big Data-Driven Financial Auditing Method Using Convolution Neural Network, IEEE Access PP (99):1-1, 2023. doi:[10.1109/ACCESS.2023.3269438](https://doi.org/10.1109/ACCESS.2023.3269438),

Zhou, C; Dai, P. A comprehensive review of deep learning-based models for heart disease prediction, Artificial Intelligence Review, 10. (7), 2024.

ملحق رقم (1)

Code	Purpose
<code>train_test_split(X, y, test_size=0.2, random_state=42)</code>	To split the dataset into training (80%) and testing (20%) sets, ensuring reproducibility.
<code>StandardScaler().fit_transform(data)</code>	To standardize the data by removing the mean and scaling to unit variance.
<code>MLPRegressor(hidden_layer_sizes=(50,), max_iter=1000)</code>	To initialize a multilayer perceptron model with one hidden layer of 50 neurons.
<code>model.fit(X_train, y_train)</code>	To train the MLP model using the training data.
<code>mean_squared_error(y_test, y_pred)</code>	To calculate the average squared difference between predicted and actual values.
<code>r2_score(y_test, y_pred)</code>	To compute the coefficient of determination (R^2).
<code>permutation_importance(model, X_test, y_test)</code>	To estimate the importance of each feature by measuring the increase in model error after permuting the feature.
<code>DecisionTreeRegressor().fit(X_train, y_train)</code>	To train a decision tree model for comparison with MLP.

Using Multilayer Perceptron (MLP) Neural Networks to Predict Banking Stability: (An Applied Study On Syrian Private Commercial Banks For The Period 2010-2023)

Dr. Rime Mahmoud

Assistant Professor, Department of Finance and Banking, Faculty of Economics,
Lattakia University- Lattakia- Syria.

E- mail: rime_mahmoud@yahoo.fr

Mohammad Fouad Yousef

PhD student in the Department of Finance and Banking, Faculty of Economics, Lattakia
University- Lattakia- Syria.

E- mail: mhammadyousef123456@gmail.com

Abstract

This research aimed to develop a model based on multi-layer perceptron (MLP) neural networks to predict the level of banking stability of private Syrian commercial banks, using annual financial data for the period (2010-2023). It also sought to compare the performance of the MLP neural network model with that of the decision tree (DT) model in terms of its predictive ability to measure banking stability.

Banking stability was measured using the Z-score, while eleven financial indicators were included in the predictive model. Using tests (RMSE, MSE, R^2), the results demonstrated the MLP model's effectiveness in predicting banking stability, outperforming the traditional DT model in terms of explanatory power. It explained approximately 56% of the changes in the stability index using all (11) financial indicators with fewer errors. In addition to the above, the optimal combination of the predictive model was determined using the Permutation Importance technique, and the results showed that using the six indicators (total liabilities/equity, loans/equity), financial leverage, capital adequacy ratio, return on equity, and bank size) increases the explanatory power of the model to approximately 77.6%.

Keywords: Banking Stability Prediction, Multi-Layer Neural Networks (MLP), Decision Tree Model, Syria.