



## Modern methods of predicting financial crises

الاساليب الحديثة في التنبؤ بالأزمات المالية

أ.د. جواد كاظم البكري

Prof. Dr. Jawad Kadhim AL-Bakri

bus.jawad.kadhim@uobabylon.edu.iq

أ.د. حيدر علي محمد الدليمي

Haidar.ali.aldulaimi@uomus.edu.iq

### 1. المقدمة

يُمكن التنبؤ بالأزمات المالية والحكومات والمؤسسات المالية من تطبيق تدابير استباقية، مثل تشديد اللوائح أو تعديل السياسات النقدية، للحد من المخاطر المحتملة، والكشف المبكر من الممكن أن يمنع تفاقم الأزمات من خلال تمكين التدخلات في الوقت المناسب.

يهدف البحث الى تسليط الضوء على النماذج القياسية الحديثة في التنبؤ بالأزمات المالية وهي نماذج الإنذار المبكر (Early Warning Systems - EWS)، والتعلم الآلي (Machine Learning)، والبيانات الضخمة (Big Data) وتحليل النصوص (Textual Analysis)، والنماذج المختلطة (Hybrid Models) واستكشاف أي من النماذج المذكورة هي الأفضل في التنبؤ بالأزمات المالية.

ينطلق البحث من فرضية مفادها أن بالرغم من أن النماذج الهجينة تُظهر باستمرار الأداء الأكثر تفوقاً في التنبؤ بالأزمات المالية، إلا أنه لا يوجد نموذج واحد يناسب جميع الحالات، إذ يعتمد النموذج الأفضل على عدد من العوامل مثل توافر البيانات، واحتياجات قابلية التفسير، والموارد الحسابية، ونوع الأزمة المالية المحددة التي يتم التنبؤ بها.

نحاول في هذا البحث تحليل كيفية عمل كل نموذج، وميزاته، وتحدياته، وقدرته على التنبؤ بالأزمات المالية بفاعلية. من خلال إجراء مقارنة بين هذه النماذج لتحديد النموذج أو مجموعة النماذج الأكثر كفاءة ودقة في تقديم إشارات مبكرة عن الأزمات المحتملة، مما يساهم في تعزيز استقرار الأنظمة المالية.

### المستخلص

يُعدّ التنبؤ الدقيق بالسلاسل الزمنية المالية أمرًا بالغ الأهمية لاتخاذ قرارات فعالة في مجالات مثل إدارة المخاطر، وتحسين المحافظ الاستثمارية، والتداول، ونظرًا لتعقيد الأسواق المالية وتقلبها، غالبًا ما تغفل أساليب التنبؤ التقليدية في استيعاب الديناميكيات الكامنة. تشير التطورات الحديثة في أبحاث التنبؤ بالأزمات المالية إلى استكشاف نماذج قياسية حديثة في التنبؤ بالأزمات المالية وهي نماذج الإنذار المبكر (Early Warning Systems – EWS)، و التعلم الآلي (Machine Learning)، والبيانات الضخمة (Big Data) وتحليل النصوص (Textual Analysis)، والنماذج المختلطة (Hybrid Models).

يحاول هذا البحث تحليل كيفية عمل كل نموذج، وميزاته، وتحدياته، وقدرته على التنبؤ بالأزمات المالية بفاعلية. من خلال إجراء مقارنة بين هذه النماذج لتحديد النموذج أو مجموعة النماذج الأكثر كفاءة ودقة في تقديم إشارات مبكرة عن الأزمات المحتملة، مما يساهم في تعزيز استقرار الأنظمة المالية.

وقد توصل البحث إلى مجموعة من الاستنتاجات من أهمها أن الأبحاث تُظهر أن دمج مصادر البيانات غير التقليدية، مثل البيانات النصية (أخبار، وسائل التواصل الاجتماعي، تقارير الشركات) والبيانات الضخمة، يعزز بشكل كبير دقة النماذج. يمكن أن توفر هذه المصادر رؤى حول معنويات السوق، والأحداث، والأنماط الشاذة التي قد لا تكون واضحة في البيانات المالية التقليدية.

### الكلمات المفتاحية

الإنذار المبكر، التعلم الآلي، البيانات الضخمة، تحليل النصوص، النماذج المختلطة.

### (Abstract)

Accurate financial time series forecasting is critical for effective decision-making in areas such as risk management, portfolio optimization, and trading. Given the complexity and volatility of financial

markets, traditional forecasting methods often fail to capture the underlying dynamics. Recent developments in financial crisis forecasting research point to the exploration of modern standard models for financial crisis forecasting, namely early warning systems (EWS), machine learning, big data and textual analysis, and hybrid models. This research attempts to analyze how each model works, its advantages, challenges, and ability to effectively predict financial crises. By comparing these models, we determine which model or combination of models is most efficient and accurate in providing early warning signals of potential crises, thus contributing to enhancing the stability of financial systems.

The research reached a set of conclusions, the most important of which is that research shows that integrating non-traditional data sources, such as text data (news, social media, company reports) and big data, significantly enhances the accuracy of models. These sources can provide insights into market sentiment, events, and anomalous patterns that may not be apparent in traditional financial data.

**Keywords:** Early Warning Systems – EWS, Textual Analysis, Big Data, Machine Learning, Hybrid Models

### 1.1. الخلفية وأهمية الأزمات المالية

تشكل الأزمات المالية تهديدًا للاستقرار الاقتصادي، فتؤدي إلى مجموعة من المشكلات الاقتصادية في معدلات نمو الناتج المحلي الإجمالي، الدين العام، معدلات البطالة، واضطرابات اجتماعية واسعة النطاق. يمكن أن يصل متوسط الخسارة التراكمية في الناتج المحلي الإجمالي خلال أزمة مصرفية إلى حوالي 20% على مدى عامين في المتوسط. يؤكد هذا الواقع على الأهمية الحاسمة للكشف المبكر عن الأزمات المالية ومنعها للتخفيف من تداعياتها الاقتصادية والاجتماعية والسياسية.

بعد الأزمة المالية العالمية لعام 2008، تم زيادة الاهتمام بتعزيز نظم الإنذار المبكر، وكان الهدف من هذه الاستجابة هو تخفيف عبء الدورات المالية وجعل النظام المالي أكثر مرونة.

تعكس هذه الاستجابة اهتمامًا أكاديميًا وسياسيًا متزايدًا بتطوير نماذج تنبؤ فعالة. ولكن وعلى الرغم من الجهود الكبيرة، فإنه لا يزال بناء نموذج إنذار مبكر مهمة معقدة تتطلب العديد من الافتراضات والخيارات العملية. يشير هذا التعقيد المستمر إلى أن التنبؤ بالأزمات المالية ليس مشكلة تم حلها بشكل نهائي، بل هو تحدٍ متطور بطبيعته. هذا يعني أن أي نموذج يُعتبر "الأفضل" يجب أن يكون ديناميكيًا وقابلًا للتكيف باستمرار، بدلاً من أن يكون حلاً ثابتًا.

لقد اعتمدت جهود البحث في الفترات السابقة في التنبؤ بالأزمات المالية بشكل أساس على النماذج الاقتصادية القياسية والإحصائية التقليدية، مثل نموذج Altman Z-score والانحدار اللوجستي، وغالبًا ما كانت هذه النماذج تركز على مجموعة محدودة من المؤشرات الرئيسية واعتمدت على افتراضات مبسطة حول السلوك الاقتصادي والعلاقات المستقرة في السوق، وبذلك أثبتت أنها غير فعالة في معالجة البيانات المالية المتزايدة والتغيرات الديناميكية في أسواق رأس المال.

بعد الازمة المالية في عام 2008 تطور العمل بشكل كبير من هذه الأساليب الإحصائية التقليدية إلى خوارزميات التعلم الآلي المتطورة، ومؤخرًا إلى النماذج الهجينة التي تجمع بين منهجيات متعددة. يعكس هذا التطور دافعًا مستمرًا للتغلب على قيود النماذج التقليدية، لا سيما عدم قدرتها على التقاط العلاقات غير الخطية السائدة في الأنظمة المالية. الأزمات المالية ليست مجرد استقرارات خطية للاتجاهات الاقتصادية؛ بل تتطوي على حلقات تغذية راجعة، وتغيرات مفاجئة في الأنظمة، وسلوك القطيع، لذلك لا يمكن نمذجة هذه التفاعلات المعقدة بشكل كافٍ بواسطة معادلات خطية بسيطة.

تكمّن قوة النماذج الحديثة في قدرتها على تعلم هذه الارتباطات المعقدة وغير الخطية من مجموعات البيانات الضخمة، مما يعالج بشكل مباشر القصور الأساسي للأساليب التقليدية في التنبؤ بالأزمات المالية.

## 1.2. نظرة عامة على النماذج القياسية الحديثة

سنحاول أولاً تقديم تحليل منهجي لخمسة مناهج حديثة للتنبؤ بالأزمات المالية: أنظمة الإنذار المبكر (EWS)، والتعلم الآلي (ML)، والبيانات الضخمة (Big Data)، وتحليل النصوص (Textual Analysis)، والنماذج الهجينة (Hybrid Models).

## 2. أنظمة الإنذار المبكر (EWS):

## 2.1. المبادئ الأساسية

يتمثل المبدأ الأساسي في نمذجة الإنذار المبكر في التمييز بين نقاط الضعف الكامنة التي تزيد من احتمالية حدوث الأزمات والمحفزات المحتملة التي تسبب التجسيد الفعلي للأزمات. يتضمن ذلك تحليل الأنماط المشتركة في البيانات التي تسبق حلقات الأزمات التاريخية لتحديد "الحالات الضعيفة". تُعنى أنظمة الإنذار المبكر عمومًا بتحديد هذه الحالات الضعيفة قبل الأزمات المالية، والتي يمكن اعتبارها مهمة تصنيف قياسية ثنائية الفئة، حيث يكون الهدف الرئيسي هو الفصل بين الحالات الضعيفة وغير الضعيفة.

كانت مسألة منع الأزمات المالية المستقبلية المحتملة مهمة بالفعل قبل الأزمة المالية في 2007-2008، ويستخدم البعض نهجًا للإشارة لبناء أنظمة إنذار مبكر قادرة على التنبؤ بأزمة مالية محتملة. تعتمد هذه الأنظمة على مراقبة سلوك العديد من المؤشرات الاقتصادية والسياسية في الفترات التي تسبق أزمة عملة محددة. وتُعد قيم هذه المؤشرات التي تتجاوز عتبة معينة مؤشرًا على أزمة مالية خلال الـ 24 شهرًا القادمة<sup>(1)</sup>.

نظام الإنذار المبكر (EWS)، وهو نظام مراقبة وإعداد تقارير وتنبيه، يتنبأ كمياً بمستويات النجاح، والانحرافات المحتملة، والمشاكل، والمخاطر، وحالات الإفلاس المحتملة، وشؤون المعاملات، وبالتالي، يُمكن تجنب المشاكل المحتملة أو التخفيف منها باستخدام أنظمة الإنذار المبكر، وتُستخدم البيانات المالية، مثل الميزانيات العمومية وجداول الدخل، التي تُوفر معلومات مالية، في أنظمة الإنذار المبكر، وهي في جوهرها تقنيات تحليل تُحدد الأوضاع الراهنة للوضع المالي. عند بناء نظام الإنذار المبكر بعد الأزمة، يجب تحديد أنواع الأحداث المرتبطة بها. ويمكن لبناء نموذج تحليلي أن يُحدد بشكل منهجي الأضرار الاقتصادية المحتملة. بعد ذلك، يُتوقع تحديد المسارات التي تبدأ منها الأزمة وتنتشر إلى قطاعات أخرى. وأخيرًا، يجب تحديد الظروف المواتية في القطاع المالي. يتضمن نظام الإنذار الفعال والكفؤ العديد من الميزات، مثل القدرة على رسم آفاق المالية العالمية والاقتصاد الكلي، وتقييم الأثر الاقتصادي للدول والقطاعات، وتحليل مسارات التأثيرات في القطاعات. وتُلاحظ مؤشرات مالية متنوعة في الدول، ويجب على صانعي السياسات فهم كيفية عمل أنظمة الإنذار المبكر هذه لمنع الأزمات. ومع ذلك، يُغفل بناء مثل هذه الأنظمة نظرًا لتشكيك صانعي السياسات في كفاءتها. بالإضافة إلى

(1) Erindi Allaj and Simona Sanfelici, Early Warning Systems for identifying financial instability, International Journal of Forecasting, 39(4), 1777-1803, 2024, page 2.

تشغيل هذه الأنظمة، ينبغي النظر في العديد من السياسات المناسبة والفعالة للحد من المخاطر. فالتواصل العالمي، على سبيل المثال، مهم للغاية في هذا الصدد. ومن المسلم به أن مثل هذه الأنظمة لا تُصدر إشارات دقيقة قبل وقوع أي أزمة. ومن الممكن إصدار إنذارات كاذبة. علاوة على ذلك، تُعد عوامل مثل التحليل المتقدم الفعال، والتدقيق قبل الأزمة، والتنسيق العالمي واسع النطاق، عوامل أساسية. وقد أُجريت مؤخرًا أبحاث حول تحديد وتيرة المخاطر بواسطة أنظمة الإنذار المبكر. تم اقتراح نظام تنبيه جديد قائم على الغابات العشوائية، يبحث في البيانات المالية على مستوى البنوك لتحديد الأنماط التي تُعرضها للمخاطر، ويُظهر أداءً أفضل من الطرق التقليدية<sup>(2)</sup>.

تتضمن منهجيات أنظمة الإنذار المبكر الحديثة غالبًا الجمع بين نهج دالة الخسارة لتقييم نماذج الإنذار المبكر مع الانحدار اللوجستي المنتظم والتحقق المتقاطع (cross-validation) للعثور على مواصفات نموذج ذات خصائص تنبؤية مثالية في الوقت الفعلي وخارج العينة. إن التمييز الصريح بين "نقاط الضعف" و"المحفزات" هو أساس مفاهيمي حاسم لأنظمة الإنذار المبكر. يشير هذا إلى أن الهدف الأساسي لأنظمة الإنذار المبكر ليس التنبؤ بالتوقيت الدقيق للأزمة (والذي غالبًا ما يكون غير متوقع بسبب المحفزات الخارجية)، بل تحديد فترات الهشاشة النظامية المتزايدة حيث يمكن أن تؤدي صدمة ما إلى أزمة. هذا يعيد صياغة مهمة التنبؤ من توقع حتمي إلى تقييم مخاطر احتمالي، وهو ما يُعد أكثر واقعية بالنظر إلى عدم اليقين المتأصل في الأسواق المالية. إذا كانت أنظمة الإنذار المبكر تتنبأ بـ "الحالات الضعيفة"، فإنها توفر لصانعي السياسات نافذة من الفرص لتنفيذ تدابير احترازية كلية وقائية قبل أن تتجسد الأزمة. يتيح ذلك للتدابير السياسية وقتًا كافيًا لتكون فعالة. كما يوضح سبب أن "الإشارات التي تصل في مراحل مبكرة جدًا يمكن أن تكون إشكالية أيضًا لأن تدابير السياسة مكلفة"، مما يعني الحاجة إلى التوقيت الأمثل، وليس مجرد التوقيت المبكر. هذا المبدأ يسلط الضوء على الطبيعة الاستباقية، بدلاً من مجرد رد الفعل، للوقاية الفعالة من الأزمات. إنه يحول التركيز من مجرد التنبؤ بحدث ما إلى إدارة المخاطر النظامية بشكل فعال، مما يمكن السلطات من تخفيف الدورات المالية وجعل النظام المالي أكثر مرونة<sup>(3)</sup>.

(<sup>2</sup>) . Guangju Li, Financial Early Warning System Model Combining Hybrid Semantic Hierarchy with Group Method of Data Handling Neural Network for Detection of Banks' Risks, Hindawi Discrete Dynamics in Nature and Society, Article ID 8607667, 2021, page 2.

(<sup>3</sup>) . Despo Malikkidou and others, A new approach to Early Warning Systems for smaller European, European Banking Authority, 2021, page14.

## 2.2. المؤشرات الرئيسية وتقييمها

تشمل مؤشرات الإنذار المبكر الرئيسية (EWIS) للالتزامات المصرفية فجوة الائتمان إلى الناتج المحلي الإجمالي، ونسبة خدمة الدين (DSR)، ونسبة الالتزامات غير الأساسية، ونمو الائتمان الحقيقي، ومعدلات النمو والفجوات في أسعار العقارات وأسعار الأسهم، ونمو الناتج المحلي الإجمالي الحقيقي، وتاريخ الأزمات المالية في البلد.

تشير النتائج التجريبية إلى أن فجوة الائتمان إلى الناتج المحلي الإجمالي ونسبة خدمة الدين (DSR) تتفوقان باستمرار على المؤشرات الأخرى. تُعد فجوة الائتمان إلى الناتج المحلي الإجمالي أفضل مؤشر على المدى الأطول (حتى خمس سنوات قبل الأزمة)، بينما تهيمن نسبة خدمة الدين على المدى الأقصر (تصبح دقيقة جدًا قبل عامين من الأزمة). يُعتبر الجمع بين هذين المؤشرين مثالًا من منظور السياسة<sup>(4)</sup>.

إن الأداء المتفوق والمستمر للمؤشرات المتعلقة بالائتمان (فجوة الائتمان إلى الناتج المحلي الإجمالي، نسبة خدمة الدين) عبر آفاق زمنية مختلفة، والتركيز على "الأسس المفاهيمية السليمة"، يشيران إلى أن التوسع المفرط في الائتمان وأعباء الديون غير المستدامة هي محركات أساسية ومستمرة لنقاط الضعف المالية، بغض النظر عن محفزات الأزمة المحددة. هذا يعزز وجهة نظر مينسكي حول عدم الاستقرار المالي، حيث يمكن أن تزرع فترات الاستقرار بذور الأزمات المستقبلية من خلال ارتفاع الرافعة المالية<sup>(5)</sup>.

## 3. التعلم الآلي (ML) في التنبؤ بالأزمات المالية

### 3.1. المفاهيم والخوارزميات الأساسية

برز التعلم الآلي (ML) كحل ثوري لمعالجة قيود النماذج التقليدية وتعزيز دقة التنبؤ بالاضطرابات المالية. تتميز خوارزميات التعلم الآلي بقدرتها على الكشف عن أنماط معقدة داخل البيانات المالية، والتكيف مع ديناميكيات السوق المتغيرة باستمرار، وتقديم دقة فائقة مقارنة بالتقنيات التقليدية.

<sup>(4)</sup> . Mathias Drehmann and Mikael Juselius, Evaluating early warning indicators of banking crises: Satisfying policy requirements, International Journal of Forecasting Volume 30, Issue 3, July–September 2014, Page 12.

<sup>(5)</sup> . Ibid, page 13.

تشمل خوارزميات التعلم الآلي المحددة المستخدمة في التنبؤ بالأزمات المالية ما يلي<sup>(6)</sup>:

- **الانحدار اللوجستي (Logistic Regression):** يُستخدم لتقييم نماذج الإنذار المبكر، ويُعد نموذجًا معياريًا غالبًا ما تُقارن به نماذج التعلم الآلي الأخرى.
- **الغابات العشوائية (Random Forests):** تُظهر أداءً فائقًا مقارنةً بنماذج الانحدار اللوجستي، وتتميز بقدرتها على التعامل مع مجموعات البيانات الكبيرة والوضائية، وتقديم تقديرات دقيقة للمخاطر، وتجاوز مشكلة الإفراط في التجهيز (overfitting)<sup>(\*)</sup>.
- **آلات المتجهات الداعمة (Support Vector Machines – SVM):** تُظهر أداءً جيدًا في التصنيف، وتُستخدم أيضًا في نماذج الإنذار المبكر.
- **الشبكات العصبية الاصطناعية (Artificial Neural Networks – ANN):** تُستخدم على نطاق واسع في التنبؤ بالأزمات المالية.
- **التعلم العميق (Deep Learning – DL):** هو فرع من التعلم الآلي يستخدم الشبكات العصبية الاصطناعية لتحليل مجموعات البيانات الكبيرة وتنفيذ مهام معقدة، وهي على ثلاثة أنواع:
  - **الشبكات العصبية المتكررة (Recurrent Neural Networks – RNN)** والذاكرة طويلة المدى (**Long Short-Term Memory – LSTM**): أظهرت تفوقًا في التنبؤ بالأزمات المالية، حيث حققت RNN دقة 99.2% وLSTM دقة 98.5%. تُعتبر هذه النماذج فعالة بشكل خاص في النقاط التبعيات الزمنية للبيانات المالية.
  - **الشبكات العصبية التلافيفية (Convolutional Neural Networks – CNN):** تُستخدم لاستخراج الميزات من المخططات المالية واتجاهات السوق.
  - **النماذج القائمة على المحولات (Transformer-based Models)** مثل **BERT**: تُظهر أعلى دقة تنبؤية (89.2%) في تقييم المخاطر المالية.
- **XGBoost**: يُعتبر أحد أفضل الخوارزميات للتحليل التنبؤي، ويستخدم تقنيات تعزيز التدرج لتحسين نتائج التنبؤ ودقة النموذج.

<sup>(6)</sup> . Iñaki Aldasoro and others, Predicting financial market stress with machine learning, BIS Working Papers No 1250, 2025, page 4-5.

<sup>(\*)</sup> . الإفراط في التجهيز (Overfitting) هو ظاهرة في التعلم الآلي تحدث عندما يكون النموذج مُصمَّمًا بشكل جيد جدًا لبيانات التدريب، بحيث يحفظ تفاصيلها وحتى ضوضاءها، ولكنه يفشل في التعميم والتنبؤ بدقة على بيانات جديدة لم يرها من قبل، بمعنى آخر، يؤدي إلى نتائج جيدة على مجموعة التدريب ولكنه يعطي نتائج سيئة على بيانات الاختبار أو البيانات الجديدة.

تُظهر نماذج التعلم الآلي عمومًا أداءً أفضل من نماذج الانحدار اللوجستي التقليدية في التنبؤات خارج العينة والتنبؤ بالأزمات المالية، ويُعزى ذلك إلى مرونتها في الكشف عن العلاقات غير الخطية وتفاعلات المتغيرات التي يصعب تحديدها بالتقنيات الكلاسيكية، على سبيل المثال، يمكن لنماذج التعلم الآلي أن تقلل من معدل الإنذارات الكاذبة بشكل كبير مقارنة بالانحدار اللوجستي (من 31% إلى 18% في بعض الدراسات)<sup>(7)</sup>.

#### 4. البيانات الضخمة في التنبؤ بالأزمات المالية

##### 4.1. الدور والفوائد

تُقدم البيانات الضخمة (Big Data) وتقنيات الذكاء الاصطناعي (AI) مناهج جديدة لتحليل السوق في الوقت الفعلي، باستخدام خوارزميات التعلم الآلي للكشف عن العلاقات غير الخطية والأنماط المخفية في مجموعات البيانات الكبيرة. يمكن للبيانات الضخمة والذكاء الاصطناعي التنبؤ بالأزمات المالية بفعالية أكبر من النماذج الاقتصادية التقليدية.

تشمل الفوائد الرئيسية للبيانات الضخمة في التنبؤ بالأزمات المالية ما يلي<sup>(8)</sup>:

- **معالجة البيانات في الوقت الفعلي:** تُمكن البيانات الضخمة من جمع وتحليل كميات هائلة من البيانات في الوقت الفعلي من مصادر متنوعة، بما في ذلك وسائل التواصل الاجتماعي، والمقالات الإخبارية، والأسواق المالية، وأنماط الإنفاق الاستهلاكي. تساعد هذه القدرة في الوقت الفعلي على اكتشاف العلامات المبكرة لعدم الاستقرار المالي التي قد تفوتها النماذج التقليدية.
- **التعرف على الأنماط المعقدة في البيانات:** تتفوق خوارزميات الذكاء الاصطناعي والتعلم الآلي في تحديد الأنماط المعقدة في البيانات، حتى تلك التي تتضمن متغيرات متعددة أو علاقات غير خطية. يمكن لنماذج الذكاء الاصطناعي تحليل التفاعلات بين آلاف

---

(7) . See:

- Simon Nusinovici Yih Chung Tham, Logistic regression was as good as machine learning for predicting major chronic diseases, Journal of Clinical Epidemiology, issue 122, March 2020, page 18.

- G. Shobana K. Umamaheswari, Forecasting by Machine Learning Techniques and Econometrics: A Review, International Conference on Inventive Computation Technologies (ICICT), January 2021, page 202.

(8) . F. O. Chernenkov, O. A. O. Mustafa, Benefits of Big Data in the Financial Sector and Financial Stability Risks, Scientific and Educational Initiative, September 2024, page 23.

العوامل، مثل معنويات السوق والأحداث الجيوسياسية وأسعار السلع، بطرق لا تستطيع النماذج التقليدية القيام بها.

- **القدرة التنبؤية:** يمكن تدريب نماذج الذكاء الاصطناعي على الأزمات المالية التاريخية وظروف السوق الحالية للتنبؤ بالأزمات المحتملة بناءً على الأنماط السابقة، بما في ذلك تلك التي تنطوي على مخاطر لم تُشاهد من قبل.
- **دمج البيانات غير التقليدية:** بينما تعتمد النماذج الاقتصادية التقليدية على البيانات المهيكلة (مثل الناتج المحلي الإجمالي، ومعدلات التضخم)، تدمج البيانات الضخمة مجموعة واسعة من البيانات غير المهيكلة، بما في ذلك منشورات وسائل التواصل الاجتماعي، والمقالات الإخبارية، وحتى صور الأقمار الصناعية للنشاط الصناعي. يمكن لأنظمة الذكاء الاصطناعي تحليل هذه الأنواع الجديدة من البيانات للكشف عن إشارات مبكرة لمعنويات السوق أو الاضطرابات الجيوسياسية أو اضطرابات سلسلة التوريد التي قد تسبق الأزمة المالية.
- **النماذج الديناميكية والتكيفية:** النماذج التقليدية غالبًا ما تكون ثابتة، وتعتمد على افتراضات ثابتة حول السلوك الاقتصادي. في المقابل، أنظمة الذكاء الاصطناعي تكيفية، وتتعلم وتتطور باستمرار مع البيانات الجديدة. يتيح هذا التكيف لها التكيف مع الظروف المتغيرة بسرعة ويعكس ديناميكيات السوق في الوقت الفعلي بشكل أفضل.

تُظهر البيانات الضخمة تحسنًا كبيرًا في دقة التنبؤ بالدورات المالية، حيث أظهرت دراسات أن دمج البيانات الضخمة المالية يحسن دقة التنبؤ بمكونات الدورة المالية بنسبة تتراوح من 30% إلى أربعة أضعاف<sup>(9)</sup>.

## 5. تحليل النصوص في التنبؤ بالأزمات المالية

### 5.1 دور معالجة اللغة الطبيعية (NLP) وتحليل المشاعر

برزت معالجة اللغة الطبيعية (NLP) كأداة قوية لتحليل المشاعر في الأسواق المالية، مما يمكّن المستثمرين والمحللين من قياس معنويات السوق من كميات هائلة من البيانات النصية غير المهيكلة.

---

<sup>(9)</sup> . See: Marinko SKARE, Małgorzata PORADA-ROCHON, FORECASTING FINANCIAL CYCLES: CAN BIG DATA HELP?, Technological and Economic Development of Economy, April 2020, Page 18.

تتضمن عملية استخراج الرؤى من البيانات النصية غير المهيكلة للتنبؤ بالسوق عدة منهجيات رئيسية<sup>(10)</sup>:

1. **المعالجة المسبقة للنصوص (Text Preprocessing)**: هي الخطوة الأولى لتنظيف وإعداد البيانات النصية الخام للتحليل. تشمل ترميز الكلمات (Tokenization)، وإزالة الكلمات الشائعة (Stop Words Removal)، والتجريد (Lemmatization and Stemming).

2. **استخراج الميزات (Feature Extraction)**: بعد المعالجة المسبقة، تُحوّل النصوص إلى تنسيق رقمي مهيكّل مناسب للتحليل الخوارزمي. تشمل حقيبة الكلمات (Bag of Words - BoW)، وتردد المصطلح-عكس تردد الوثيقة (TF-IDF)، وتضمينات الكلمات (Word Embeddings).

3. **طرق تصنيف المشاعر (Sentiment Classification Methods)**: تقوم هذه الطرق بتحليل المشاعر المعبر عنها في النص بعد استخراج الميزات، باستخدام خوارزميات التعلم الآلي (مثل آلات المتجهات الداعمة، بايز الساذج) والتعلم العميق (مثل الشبكات العصبية المتكررة، الذاكرة طويلة المدى، المحولات).

## 5.2. استخراج الأحداث والتحليل الدلالي

يُسهّم تحليل النصوص في التنبؤ بالأزمات المالية بما يتجاوز مجرد تحليل المشاعر. تُظهر الدراسات أن البيانات النصية تساعد في تقليل الإيجابيات الكاذبة والسلبيات الكاذبة في اختبار النماذج خارج العينة، خاصة في حالات الأزمات. علاوة على ذلك، عند استخدام المعلومات النصية جنباً إلى جنب مع المتغيرات المالية الكلية كمدخلات، يزداد أداء النماذج بشكل كبير مقارنة بالنماذج التي تستخدم نوعاً واحداً فقط من المدخلات. على سبيل المثال، تُظهر المعلومات النصية من خطابات رؤساء البنك المركزي الأوروبي قوة تنبؤية كبيرة لمخاطر انهيار أسعار أسهم البنوك.

تُستخدم تقارير الاستقرار المالي (FSRs) الصادرة عن البنوك المركزية لتحليل العلاقة بين الدورة المالية والمشاعر التي تنقلها هذه الاتصالات الرسمية. تُظهر النتائج أن معنويات البنوك المركزية تتدهور قبل بدء الأزمات المصرفية مباشرة.

---

(10) . Adetoyese Omoseebi and others, Natural language processing (NLP) for sentiment analysis in financial Markets, University of Technology Department of Ecotourism and Wildlife Management, November 2023, page 18.

بالإضافة إلى تحليل المشاعر، تُستخدم مناهج أخرى في التنبؤ المالي القائم على النصوص<sup>(11)</sup>:

- **التحليل الدلالي (Semantic-Based Approach)**: يركز على معالجة المعلومات النصية إلى تمثيلات ميزات رقمية لتمكين الآلات من فهم المعنى الدلالي للنص.
- **استخراج الأحداث (Event Extraction-Based Approach)**: يركز على استرداد معلومات الأحداث الأساسية من النص وتمثيلها في شكل مهيكّل لتقليل الضوضاء من النص غير ذي الصلة. يُعرف الحدث بأنه وقوع محدد في وقت ومكان معينين يتضمن أشخاصًا، ويصف تغييرًا في الحالة.

## 6. النماذج الهجينة للتنبؤ المعزز

### 6.1. منهجيات التكامل<sup>(12)</sup>

تُعد النماذج الهجينة (Hybrid Models) إطارًا واعدًا للتنبؤ بالأزمات المالية، حيث تجمع بين النماذج الاقتصادية القياسية التقليدية وتقنيات التعلم الآلي والتعلم العميق. يكمن المنطق وراء هذا التكامل في الاستفادة من نقاط القوة في كل منهجية مع التخفيف من نقاط ضعفها الفردية. تهدف هذه النماذج إلى النقاط كل من الأنماط الخطية وغير الخطية في البيانات، مما يوفر نظام إنذار مبكر قويًا وقابلًا للتفسير.

تُظهر النماذج الهجينة قدرة فائقة على استخراج الأنماط الخطية وغير الخطية في البيانات بشكل تسلسلي، مما أثبت فعاليته في تحسين التنبؤات الفردية. على سبيل المثال، تُظهر دراسة نموذج هجين يجمع بين Altman Z-score (مقياس مالي تقليدي) وأربع خوارزميات تعلم آلي (Random Forest، SVM، Logistic Regression، XGBoost) أن هذا الإطار يعزز دقة التنبؤ بالضائقة المالية بشكل كبير. في هذا الإطار، يُمنح Altman Z-score أعلى وزن (30%) نظرًا لأسسه النظرية الراسخة وقابليته للتفسير المباشر. تُوزع الأوزان المتبقية على خوارزميات التعلم الآلي، مما يخلق توازنًا استراتيجيًا بين تعقيد النموذج وقابليته للتفسير وقوته التنبؤية.

(11) . Mary Chen and others, Identifying Financial Crises Using Machine Learning on Textual Data, Journal of Risk and Financial Management, issue 16, 2023, page 33.

(12) . Dominik Stempieć, and Robert Slepaczuk, Hybrid Models for Financial Forecasting: Combining Econometric, Machine Learning, and Deep Learning Models, Cornellians university magazine, valium 1, Mon, 26 May 2025, page 5.

تشمل أمثلة أخرى للنماذج الهجينة:

- الجمع بين **ARIMA** (نموذج اقتصادي قياسي) و **SVM** أو **LSTM**: أظهرت هذه التركيبات أنها الأكثر فعالية في تطوير استراتيجيات تداول مربحة، متفوقة على مكوناتها الفردية.
- نموذج هجين قائم على **CNN** و **LSTM** لتحليل المؤشرات المالية والنصوص: يستخدم **CNN** لاستخراج الميزات من المؤشرات المالية، و **LSTM** مع آلية الانتباه لالتقاط الدلالات الكامنة في النصوص المالية (مثل تقارير الشركات السنوية)، ثم يجمع الميزات المستخرجة من كلا المصدرين للتصنيف الفعال.
- خوارزمية محسنة هجينة (**HUMC**): تجمع بين خصائص تصنيف شجرات القرار وقدرة الشبكات العصبية على تحديد البيانات المخفية والمستمرة، مما يعالج قيود النماذج الفردية ويزيد من دقة التنبؤ.

## 6.2. الفعالية والنتائج الكمية

تُظهر النماذج الهجينة باستمرار أداءً متفوقاً في التنبؤ بالأزمات المالية مقارنة بالنماذج الفردية.

- نموذج **Altman Z-score** الهجين مع التعلم الآلي: حقق دقة تنبؤية بلغت **97.91%** في دراسة على شركات مدرجة في البورصة المصرية. هذا الأداء فاق بشكل كبير النماذج الفردية التي تراوحت دقتها بين **91%** و **96%**.
- نموذج **HUMC**: حقق دقة أعلى بلغت **86.25%** مقارنة بنماذج التصنيف الفردية مثل شجرة القرار (**85.50%**) و (**84.93%** Multilayer Perceptron).
- النماذج الهجينة التي تدمج المؤشرات النصية: أظهرت تحسينات في دقة التعرف على الأزمات، حيث أظهرت نماذج التعلم الجماعي تحسناً متوسطاً بنسبة **1.75%** بعد إدخال الميزات النصية.

تُشير هذه النتائج إلى أن النماذج الهجينة قادرة على تحقيق دقة أعلى بكثير من مكوناتها الفردية، وذلك بفضل قدرتها على استغلال نقاط القوة المتكاملة للمنهجيات المختلفة.

## 7. التحليل المقارن والنموذج الأفضل

## 7.1. مقارنة الأداء عبر النماذج

لقد أحدثت النماذج الحديثة ثورة في مجال التنبؤ بالأزمات المالية، متجاوزة بشكل كبير قدرات النماذج الاقتصادية القياسية التقليدية.

نوع النموذج	أمثلة على الخوارزميات	متوسط الدقة AUC	المزايا الرئيسية	القيود الرئيسية
أنظمة الإنذار المبكر (EWS)	الانحدار اللوجستي، فجوة الائتمان إلى الناتج المحلي الإجمالي، نسبة خدمة الدين	70-80% دقة، AUC 0.822 (الانحدار اللوجستي)	تحديد نقاط الضعف، قابلية التفسير، مؤشرات واضحة للسياسات	قد تفوت العلاقات غير الخطية، مشكلة "الاصندوق الأسود" (في البعض نماذج التعلم الآلي)، تحديات البيانات
التعلم الآلي (ML)	الغابات العشوائية، آلات المتجهات الداعمة، الشبكات العصبية، XGBoost	الغابات العشوائية : AUC 0.870، دقة 80%؛ XGBoost: دقة 94%	التقاط العلاقات غير الخطية، أداء تنبؤي فائق، التعامل مع البيانات الضخمة	"الاصندوق الأسود" (قابلية التفسير)، التجهيز الزائد، تحيز البيانات، التعقيد الحسابي
التعلم العميق (DL)	LSTM، RNN، CNN، Transformer-based (BERT)	RNN: 99.2%؛ LSTM: 98.5%؛ Transformer: 89.2%	دقة عالية جدًا، قدرة فائقة على معالجة البيانات المعقدة وغير المهيكلة، التقاط التبعيات الزمنية	"الاصندوق الأسود" (قابلية التفسير)، متطلبات حسابية هائلة، الحاجة إلى بيانات ضخمة عالية الجودة
تحليل النصوص (Textual Analysis)	تحليل المشاعر، استخراج الأحداث، التحليل الدلالي	تحسين الدقة 1.75% (للمنماذج الجماعية مع ميزات نصية)؛ AUC (0.91 القناة النصية)	الاستفادة من البيانات غير المهيكلة، الكشف عن معنويات السوق، تقليل الإيجابيات/السلبات الكاذبة	تعقيد البيانات، تحيز المصادر غير الرسمية، التكلفة الحسابية، قابلية التفسير
النماذج الهجينة (Hybrid Models)	Altman Z-score + ML، ARIMA + CNN، SVM/LSTM + LSTM	97.91%؛ 86.25% (HUMC)؛ 98%	تجمع بين نقاط القوة، دقة فائقة، قابلية تفسير محسنة (مع المكونات الكلاسيكية)، تعامل شامل مع البيانات	زيادة التعقيد، متطلبات بيانات متعددة، خطر التجهيز الزائد (إذا لم يتم تصميمها بعناية)

ملاحظات على الأداء:

- **التعلم الآلي مقابل النماذج التقليدية:** تتفوق نماذج التعلم الآلي بشكل عام على النماذج الاقتصادية القياسية التقليدية (مثل الانحدار اللوجستي) في التنبؤات خارج العينة والتنبؤ بالأزمات، خاصة فيما يتعلق بالعلاقات غير الخطية.
- **التعلم العميق:** تُظهر نماذج التعلم العميق (RNN، LSTM، النماذج القائمة على المحولات) دقة عالية جدًا (على سبيل المثال، LSTM 99.2%، RNN 98.5%، LSTM 89.2% Transformer) وتتفوق على نماذج التعلم الآلي التقليدية.
- **تحليل النصوص:** يُحسن تحليل النصوص الدقة، خاصة عند دمجها مع بيانات أخرى (على سبيل المثال، تحسن متوسط بنسبة 1.75% للتعلم الآلي الجماعي مع الميزات النصية). يمكن للقناة النصية أن تلعب دورًا أكثر أهمية من البيانات الرقمية (AUC 0.91 مقابل 0.808).
- **النماذج الهجينة:** تُظهر النماذج الهجينة باستمرار أعلى دقة (على سبيل المثال، 97.91%، 98% ML + Altman Z-score، 86.25% HUMC).

## 7.2. معالجة سؤال النموذج الأفضل

لا يوجد نموذج واحد يُعد "الأفضل" بشكل مطلق للتنبؤ بالأزمات المالية؛ بل إن النموذج الأمثل غالبًا ما يكون مزيجًا من المنهجيات أو يعتمد على السياق المحدد. تُظهر النماذج الهجينة بشكل متكرر أداءً فائقًا من خلال الجمع بين نقاط القوة في الأساليب المختلفة والتخفيف من نقاط ضعفها.

يعتمد اختيار النموذج "الأفضل" على عدة عوامل:

- **توافر البيانات وجودتها:** تتطلب النماذج الأكثر تعقيدًا، لا سيما نماذج التعلم العميق، كميات هائلة من البيانات عالية الجودة. قد لا يكون هذا متاحًا دائمًا، خاصة بالنسبة للبيانات التاريخية للأزمات النادرة.
- **قابلية التفسير:** في حين أن نماذج التعلم الآلي والتعلم العميق تتفوق في الدقة، فإن طبيعتها "الصندوق الأسود" يمكن أن تكون عائقًا أمام صناع السياسات والجهات التنظيمية الذين يحتاجون إلى فهم الأسباب الكامنة وراء التنبؤات. هنا، قد تكون النماذج التقليدية أو النماذج الهجينة التي تتضمن مكونات قابلة للتفسير أكثر ملاءمة.
- **الموارد الحسابية:** تتطلب النماذج المتطورة قوة حاسوبية كبيرة، مما قد يحد من تطبيقها العملي في المؤسسات الأصغر.

- أنواع الأزمات المحددة: قد يكون بعض النماذج أكثر ملاءمة لأنواع معينة من الأزمات (على سبيل المثال، أزمات الائتمان مقابل أزمات العملة).

إن أهمية مصادر البيانات المتنوعة (المالية الكلية، النصية، البيانات البديلة) هي سمة متكررة في البحث. هذا يشير إلى أن النهج الأكثر فعالية هو الذي يجمع بين أنواع متعددة من البيانات والمنهجيات.

### 7.3. التغلب على التحديات للتطبيق العملي

لتحقيق أقصى استفادة من هذه النماذج المتقدمة في التطبيق العملي، يجب معالجة التحديات الرئيسية:

- **قابلية التفسير:** على الرغم من طبيعة "الصندوق الأسود" لنماذج التعلم الآلي المعقدة، يمكن تعزيز قابليتها للتفسير باستخدام تقنيات الذكاء الاصطناعي القابلة للتفسير (XAI) مثل قيم Shapley ومخططات ALE (Accumulated Local Effects). توفر هذه الأدوات رؤى حول المتغيرات التي تدفع التنبؤات، مما يساعد صناع السياسات على فهم الأساس المنطقي وراء الإشارات.
- **قيود البيانات:** بينما تعالج البيانات الضخمة مشكلة حجم البيانات، لا تزال جودتها وتحيزها يمثلان تحديات. يتطلب هذا استثمارات في جمع البيانات وتنظيفها وتوحيدها.
- **الطبيعة الديناميكية للأزمات:** تتطلب الطبيعة المتغيرة للأسواق المالية والأزمات نماذج قابلة للتكيف يمكنها التعلم والتطور باستمرار. يجب إعادة تدريب النماذج بانتظام وتعديلها لتناسب الظروف الاقتصادية الجديدة والمخاطر الناشئة.
- **التعاون بين الإنسان والذكاء الاصطناعي:** يجب التأكيد على دور الحكم البشري كـ "صمام أمان". لا ينبغي أن يحل الذكاء الاصطناعي محل الخبراء البشريين، بل يجب أن يعزز قدرتهم على اتخاذ القرارات من خلال توفير تحليل بيانات متقدم وإشارات مبكرة.

## 8. الاستنتاجات

لقد أحدثت النماذج القياسية الحديثة في التنبؤ بالأزمات المالية، بما في ذلك أنظمة الإنذار المبكر المتقدمة، والتعلم الآلي، والبيانات الضخمة، وتحليل النصوص، والنهج الهجينة، قفزة نوعية كبيرة مقارنة بالأساليب التقليدية. تُظهر هذه النماذج قدرة متزايدة على التقاط العلاقات غير

الخطية، ومعالجة مجموعات البيانات الضخمة والمعقدة، وتقديم تنبؤات أكثر دقة وفي الوقت المناسب.

بناءً على التحليل الشامل، يمكن استخلاص الاستنتاجات التالية:

- **النماذج الهجينة هي الأفضل عمومًا:** تُظهر النماذج الهجينة باستمرار الأداء الأكثر تفوقًا في التنبؤ بالأزمات المالية. يرجع ذلك إلى قدرتها على دمج نقاط القوة في المنهجيات المختلفة، مثل قابلية تفسير المقاييس المالية التقليدية مع قوة التعرف على الأنماط في التعلم الآلي والتعلم العميق، وإثراء البيانات من تحليل النصوص. إنها توفر تنبؤات قوية ودقيقة للغاية، وغالبًا ما تتجاوز أداء مكوناتها الفردية.
- **"الأفضل" يعتمد على السياق:** لا يوجد نموذج واحد يناسب الجميع. يعتمد النموذج "الأفضل" على عوامل مثل توافر البيانات، واحتياجات قابلية التفسير، والموارد الحسابية، ونوع الأزمة المالية المحددة التي يتم التنبؤ بها. ومع ذلك، فإن الاتجاه العام يشير إلى أن النهج المتعدد الأوجه الذي يدمج مصادر بيانات متنوعة وتقنيات تحليلية متعددة هو الأكثر فعالية.
- **الاستفادة من البيانات المتنوعة أمر بالغ الأهمية:** تُظهر الأبحاث أن دمج مصادر البيانات غير التقليدية، مثل البيانات النصية (أخبار، وسائل التواصل الاجتماعي، تقارير الشركات) والبيانات الضخمة، يعزز بشكل كبير دقة النماذج. يمكن أن توفر هذه المصادر رؤى حول معنويات السوق، والأحداث، والأنماط الشاذة التي قد لا تكون واضحة في البيانات المالية التقليدية.

## 9. التوصيات:

1. **اعتماد الأطر الهجينة:** يجب على المؤسسات المالية وصناع السياسات إعطاء الأولوية لتطوير وتنفيذ النماذج الهجينة التي تجمع بين قابلية تفسير المقاييس المالية التقليدية مع القوة التنبؤية لتقنيات التعلم الآلي والتعلم العميق المتقدمة، والاستفادة من ثراء البيانات الضخمة ومصادر النصوص.
2. **الاستثمار في البنية التحتية للبيانات:** من الضروري التركيز على قدرات جمع البيانات القوية وتنظيفها ومعالجتها في الوقت الفعلي لأنواع البيانات المتنوعة، بما في ذلك النصوص غير المهيكلة. سيضمن ذلك أن النماذج لديها إمداد مستمر ببيانات عالية الجودة ودقيقة.

3. إعطاء الأولوية للذكاء الاصطناعي القابل للتفسير (XAI): يجب دمج أدوات الذكاء الاصطناعي القابلة للتفسير لتعزيز شفافية نماذج التعلم الآلي المعقدة. سيؤدي هذا إلى بناء الثقة بين صناع السياسات والجهات التنظيمية، وتمكينهم من فهم الأساس المنطقي وراء التنبؤات، وبالتالي اتخاذ قرارات سياسية مستنيرة وموجهة.
4. تعزيز التعاون بين الإنسان والذكاء الاصطناعي: يجب الاعتراف بأن الذكاء الاصطناعي أداة قوية لتعزيز الخبرة والحكم البشري، وليس استبدالها. يجب أن يعمل الخبراء البشريون جنباً إلى جنب مع أنظمة الذكاء الاصطناعي، باستخدام رؤى الذكاء الاصطناعي كمدخلات لقراراتهم، مع توفير الإشراف والقدرة على التكيف في مواجهة الأحداث غير المتوقعة.
5. التكيف المستمر: نظراً للطبيعة الديناميكية للأسواق المالية والمخاطر المتطورة، يجب أن تكون نماذج التنبؤ بالأزمات المالية قابلة للتكيف باستمرار. يتطلب هذا إعادة تدريب منتظمة للنماذج، والتحقق من صحتها، وتعديلها لتتناسب الحقائق الاقتصادية الجديدة والمخاطر الناشئة، مما يضمن بقائها فعالة بمرور الوقت.

#### المصادر:

1. Erindi Allaj and Simona Sanfelici, Early Warning Systems for identifying financial instability, International Journal of Forecasting, 39(4), 1777-1803, 2024,
2. Guangju Li, Financial Early Warning System Model Combining Hybrid Semantic Hierarchy with Group Method of Data Handling Neural Network for Detection of Banks' Risks, Hindawi Discrete Dynamics in Nature and Society, Article ID 8607667, 2021.
3. Despo Malikkidou and others, A new approach to Early Warning Systems for smaller European, European Banking Authority, 2021.
4. Mathias Drehmann and Mikael Juselius, Evaluating early warning indicators of banking crises: Satisfying policy requirements, International Journal of Forecasting Volume 30, Issue 3, July–September 2014.
5. Iñaki Aldasoro and others, Predicting financial market stress with machine learning, BIS Working Papers No 1250, 2025.
6. Simon NusinovicYih Chung Tham, Logistic regression was as good as machine learning for predicting major chronic diseases, Journal of Clinical Epidemiology, issue 122, March 2020.
7. G. ShobanaK. Umamaheswari, Forecasting by Machine Learning Techniques and Econometrics: A Review, International Conference on Inventive Computation Technologies (ICICT), January 2021.
8. F. O. Chernenkov, O. A. O. Mustafa, Benefits of Big Data in the Financial Sector and Financial Stability Risks, Scientific and Educational Initiative, September 2024.

9. Marinko SKARE, Małgorzata PORADA-ROCHON, FORECASTING FINANCIAL CYCLES: CAN BIG DATA HELP?, Technological and Economic Development of Economy, April 2020.
10. Adetoyese Omoosebi and others, Natural language processing (NLP) for sentiment analysis in financial Markets, University of Technology Department of Ecotourism and Wildlife Management, November 2023,.
11. Mary Chen and others, Identifying Financial Crises Using Machine Learning on Textual Data, Journal of Risk and Financial Management, issue 16, 2023.
12. Dominik Stempie', and Robert Slepaczuk, Hybrid Models for Financial Forecasting: Combining Econometric, Machine Learning, and Deep Learning Models, Cornelliens university magazine, valium 1, Mon, 26 May 2025.