



المجلة العراقية للعلوم الاقتصادية
Iraqi Journal For
Economic Sciences



PISSN : 1812-8742

EISSE : 2791-092X

Arcif : 0.375

The role of machine learning algorithms in improving the efficiency of statistical analysis for detecting nonlinear patterns in financial data: A comparative study between traditional and intelligent methods

دور خوارزميات التعلم الآلي في تحسين كفاءة التحليل الإحصائي لاكتشاف الأنماط غير الخطية في البيانات المالية: دراسة مقارنة بين الأساليب التقليدية والذكية

م.د. اروى جاسم محمد حسن

Arwa Jassim Mohammed Hassan

Arowjassim564@gmail.com

وزارة التربية، المديرية العامة لتربية بغداد الرصافة الأولى

Abstract

This research aims to study the transformative role of machine learning algorithms in improving the efficiency of statistical analysis of financial data, focusing on their ability to detect non-linear patterns that traditional statistical methods fail to capture. The study adopted a mixed-methods approach, combining a survey of a purposive sample of 72 experts and specialists in quantitative financial analysis with an experimental application comparing the performance of two machine learning models (Artificial Neural Networks and XGBoost) against a Multiple Linear Regression model, using real data from the S&P 500 index. The survey results revealed a high consensus among experts regarding the superiority of intelligent models in prediction accuracy and uncovering non-linear patterns, with this superiority being amplified with larger data volumes. The experimental results quantitatively confirmed these findings, demonstrating a clear outperformance of the machine learning models over the traditional one. The Artificial Neural Network achieved a 37% reduction in Root Mean Square Error (RMSE). Furthermore, these models showed a superior capability to identify anomalous and volatile market periods using techniques like clustering (K-Means) and anomaly detection (Isolation Forest). Based on these findings, the research recommends that financial institutions gradually adopt machine learning methodologies, invest in big data infrastructure, and calls for researchers to develop hybrid models and deepen comparative applied studies.

Keywords: Machine Learning, Statistical Analysis, Financial Data, Non-Linear Patterns, Predictive Modelling, Artificial Intelligence.

المستخلص

يهدف هذا البحث إلى دراسة الدور التحويلي لخوارزميات التعلم الآلي في تحسين كفاءة التحليل الإحصائي للبيانات المالية، مع التركيز على قدرتها في اكتشاف الأنماط غير الخطية التي تعجز الأساليب الإحصائية التقليدية عن رصدها. اعتمد البحث منهجاً مختلطاً يجمع بين المسح الاستطلاعي لعينة قصدية من 72 خبيراً ومتمخصصاً في التحليل المالي الكمي، والتطبيق التجريبي الذي قارن أداء نموذجين من نماذج التعلم الآلي (الشبكات العصبية الاصطناعية وشجرة القرار المعززة بـ XGBoost) مقابل نموذج الانحدار الخطي المتعدد، باستخدام بيانات لمؤشر S&P 500، كشفت نتائج المسح عن موافقة عالية من الخبراء على تفوق النماذج الذكية في دقة التنبؤ واستكشاف الأنماط غير الخطية، مع تعزيز هذا التفوق بزيادة حجم البيانات. وأكدت النتائج التجريبية هذه النتائج كميًا، حيث تفوقت نماذج التعلم الآلي بشكل واضح على النموذج التقليدي، حيث حققت الشبكة العصبية الاصطناعية انخفاضاً في جذر متوسط الخطأ التربيعي (RMSE) بنسبة 37%، كما أظهرت قدرة أفضل على تحديد الفترات الشاذة والمتقلبة في السوق من خلال تقنيات مثل التجميع وكشف الشذوذ، بناءً على هذه النتائج، يوصي البحث بتبني المؤسسات المالية لمنهجيات التعلم الآلي تدريجياً، والاستثمار في بني تحتية للبيانات الضخمة، ويدعو الباحثين إلى تطوير نماذج هجينة وتعميق الدراسات التطبيقية المقارنة.

الكلمات الرئيسية: التعلم الآلي، التحليل الإحصائي، البيانات المالية، الأنماط غير الخطية، النمذجة التنبؤية، الذكاء الاصطناعي.

المقدمة

شهدت الأسواق المالية تحولاً جذرياً مع تدفق كميات هائلة من البيانات عالية التردد وغير خطية في طبيعتها، لطالما اعتمد المحللون والمستثمرون على الأساليب الإحصائية التقليدية لتحليل البيانات واتخاذ القرارات، إلا أن هذه الأساليب غالباً ما تقف عاجزة أمام تعقيدات البيانات المالية الحديثة التي تتسم بالتعقيد وعدم الاستقرار والعلاقات غير الخطية، هنا تبرز الحاجة إلى أدوات تحليلية أكثر تطوراً، لذا يمثل التعلم الآلي، كأحد فروع الذكاء الاصطناعي، نقلة نوعية في هذا المجال، حيث تقدم خوارزمياته القدرة على تعلم الأنماط المعقدة والعلاقات غير الخطية مباشرة من البيانات دون الحاجة إلى افتراضات صارمة مسبقة. تهدف هذه الدراسة إلى استكشاف الدور الذي يمكن أن تلعبه هذه الخوارزميات "الذكية" في تحسين كفاءة ودقة التحليل الإحصائي، لا سيما في مهمة اكتشاف الأنماط الخفية التي تتجاوز العلاقات الخطية البسيطة.

الدراسات السابقة

- **دراسة عثمان ويوسف، 2025، بعنوان:** دور الاتجاهات الحديثة للتحليل المالي في التنبؤ بالفشل المالي: دراسة ميدانية على سوق الخرطوم للأوراق المالية. هدفت هذه الدراسة إلى تحليل دور الاتجاهات الحديثة للتحليل المالي في التنبؤ بالفشل المالي في سوق الخرطوم للأوراق المالية، اعتمدت الدراسة على المنهج الوصفي التحليلي، وشملت عينة عشوائية من (184) مشاركاً من العاملين في القطاع المصرفي المدرج بالسوق، تم جمع البيانات باستخدام استبانة، وتحليلها عبر الحزمة الإحصائية SPSS كشفت النتائج وجود علاقات إيجابية ذات دلالة إحصائية بين جميع متغيرات الدراسة (النماذج الإحصائية، الذكاء الاصطناعي، معايير ESG والبيانات الضخمة) وقدرتها على تحسين دقة التنبؤ بالفشل المالي، مع تقديم إضافات نوعية مثل ضرورة دمج المتغيرات غير المالية والتنبؤ الاستباقي.

- **دراسة Hrishikesh & et al, 2025، بعنوان:** Evaluating the role of machine learning algorithms in enhancing predictive financial analytics for personal financial wellness هدف البحث إلى تقييم دور خوارزميات التعلم الآلي في تعزيز التحليلات

المالية التنبؤية لتحسين الصحة المالية الشخصية، مع التركيز على قدرتها في تحليل البيانات الضخمة لتقديم رؤى مالية مخصصة وتحسين استراتيجيات الادخار والاستثمار وإدارة المخاطر، واعتمد البحث على المنهج المختلط الذي يجمع بين الأساليب الكمية والنوعية، حيث تم جمع البيانات الأولية من خلال استبيانات ومقابلات كما استخدم منهج دراسة الحالة وتحليلات مقارنة لقياس أداء الخوارزميات مثل الشبكات العصبية الاصطناعية وغابات القرار العشوائية، وخلصت نتائج البحث إلى تفوق خوارزميات الشبكات العصبية الاصطناعية من حيث الدقة والاستدلال في التنبؤات المالية مقارنة بأساليب أخرى مثل آلات الدعم الإحصائي، حيث بلغ متوسط دقة الشبكات العصبية 87%. كما أكدت النتائج على وجود تأثير كبير لأدوات الذكاء الاصطناعي على أنماط الاستثمار، إلى جانب الكشف عن تحديات تتعلق بالخصوصية والتحيز الخوارزمي.

- **دراسة: Dar & Jaiswal, 2024، بعنوان:** Role of artificial intelligence and machine learning algorithms in detecting financial frauds هدف البحث إلى تحليل دور تقنيات الذكاء الاصطناعي وتعلم الآلة في اكتشاف الاحتيال المالي، مع استكشاف آليات عمل هذه التقنيات في تحليل البيانات المالية وتحديد الأنماط غير الطبيعية الدالة على السلوك الاحتيالي. واعتمد البحث على المنهج الوصفي التحليلي من خلال مراجعة شاملة للأدبيات والتطبيقات العملية في هذا المجال، حيث تم تحليل مجموعة واسعة من الدراسات السابقة وتقنيات التعلم الآلي (كالتعلم غير المُشرف، والشبكات العصبية، وخوارزميات التجميع) المستخدمة في كشف الشذوذ في البيانات المالية. وخلصت نتائج البحث إلى أن الذكاء الاصطناعي وتعلم الآلة يقدمان أدوات فعالة للكشف الاستباقي عن الاحتيال من خلال قدرتهما على معالجة أحجام هائلة من البيانات في الوقت الفعلي، والتعلم من الأنماط المتطورة للاحتيال.

1. منهجية البحث

أولاً: مشكلة البحث: تكمن المشكلة الرئيسية في قصور الأساليب الإحصائية التقليدية في التعامل بكفاءة مع التعقيدات والعلاقات غير الخطية الكامنة في البيانات المالية، مما يحد من دقة التنبؤات وفعالية اتخاذ القرارات الاستثمارية وإدارة المخاطر، وتتمثل تساؤلات البحث في الآتي:
1. هل يوجد أثر ذو دلالة إحصائية لاستخدام خوارزميات التعلم الآلي في تحسين دقة التنبؤ بأسعار الأصول المالية مقارنة بالنماذج الإحصائية التقليدية؟
2. هل يوجد أثر ذو دلالة إحصائية لاستخدام خوارزميات التعلم الآلي في زيادة كفاءة اكتشاف الأنماط غير الخطية في البيانات المالية مقارنة بالأساليب الإحصائية الوصفية التقليدية؟
3. هل يوجد أثر ذو دلالة إحصائية لحجم البيانات المستخدمة في التدريب على فجوة الأداء بين نماذج التعلم الآلي والنماذج الإحصائية التقليدية، حيث تزداد دقة النماذج الذكية مع زيادة حجم البيانات بشكل أكبر من النماذج التقليدية؟

ثانياً: اهداف وأهمية البحث: يهدف البحث إلى تقييم أثر استخدام خوارزميات التعلم الآلي في تحسين دقة وكفاءة التحليل الإحصائي للبيانات المالية، مقارنةً بالأساليب الإحصائية التقليدية، مع التركيز على قدرتها في اكتشاف الأنماط غير الخطية والتكيف مع طبيعة الأسواق الديناميكية. تتمثل الأهمية العلمية للبحث في الإسهام في تطوير الإطار النظري والمنهجي لدمج تقنيات الذكاء الاصطناعي مع التحليل الإحصائي في المجال المالي، إضافة إلى تعزيز الحوار الأكاديمي حول حدود النماذج التقليدية وإمكانات النماذج الذكية في معالجة البيانات غير الخطية، أما الأهمية العملية للبحث فتتمثل في تزويد المؤسسات المالية ومتخذي القرار بأدلة

عملية على فعالية نماذج التعلم الآلي في تحسين التنبؤات واتخاذ القرارات.

ثالثاً: فرضيات البحث: يمكن صياغة فرضيات البحث وفق الآتي:

1. يوجد أثر ذو دلالة إحصائية لاستخدام خوارزميات التعلم الآلي في تحسين دقة التنبؤ بأسعار الأصول المالية مقارنة بالنماذج الإحصائية التقليدية
2. يوجد أثر ذو دلالة إحصائية لاستخدام خوارزميات التعلم الآلي في زيادة كفاءة اكتشاف الأنماط غير الخطية في البيانات المالية مقارنة بالأساليب الإحصائية الوصفية التقليدية.
3. يوجد أثر ذو دلالة إحصائية لحجم البيانات المستخدمة في التدريب على فجوة الأداء بين نماذج التعلم الآلي والنماذج الإحصائية التقليدية، حيث تزداد دقة النماذج الذكية مع زيادة حجم البيانات بشكل أكبر من النماذج التقليدية.

رابعاً: مجتمع وعينة البحث: المجتمع: يتكون من فئتين الخبراء والمتخصصون في التحليل المالي الكمي في الشركات الاستثمارية وشركات الوساطة المالية والجامعات.
*العينة: سيتم استخدام أسلوب العينة غير الاحتمالية (العينة القصدية) لاستهداف مجموعة من الخبراء والمتخصصين الذين لديهم خبرة مباشرة في بناء النماذج الكمية أو استخدامها، حيث سيتم توزيع الاستبيان على 75 فرداً.

خامساً: منهج البحث: يعتمد البحث على المنهج الوصفي التحليلي

* الأدوات: سيعتمد الجزء النظري على المراجعة للأدبيات السابقة. وسيعتمد الجزء العملي والتطبيقي على الاستبيان، إذ سيتم تصميم استبيان إلكتروني موجه إلى خبراء ومحلي الأسواق المالية، ومطوري النماذج الكمية، وأكاديميين متخصصين، كما تضمن البحث جانب تطبيقي تجريبي تمثل في تطبيق وتقييم أداء خوارزميتين من خوارزميات التعلم الآلي مقارنة بأسلوب إحصائي تقليدي على بيانات مالية حقيقية.

المحور الاول : الجانب النظري

النماذج الإحصائية التقليدية الخطية: يُعرف التحليل الإحصائي التقليدي بأنه "العملية التي يقوم الباحث من خلالها بجمع البيانات العلمية وتنظيمها وتحليلها واستخراج معلومات تفيد البحث العلمي من خلالها، بحيث تكون هذه المعلومات جديدة وذات فائدة قيمة" تشمل الأساليب الإحصائية التقليدية المستخدمة في التحليل المالي طيفاً واسعاً من الأدوات، بدءاً من التحليل الوصفي الذي يلخص البيانات عبر مقاييس النزعة المركزية والتشتت، مروراً بتقنيات الانحدار الخطي لاستكشاف العلاقات بين المتغيرات، ووصولاً إلى نماذج السلاسل الزمنية مثل نماذج ARIMA للتنبؤ بالاتجاهات المستقبلية بناءً على البيانات التاريخية. (مغزاي وزيكيو، 2021، ص471-472). تتميز الأساليب التقليدية بمزايا عدة، أبرزها وضوحها وبساطتها النسبية وسهولة تفسير نتائجها، مما يجعلها أدوات أساسية للتحليل الأولي واستخلاص الاستنتاجات المباشرة من البيانات، كما أن افتراضاتها المعروفة، مثل التوزيع الطبيعي للبيانات، تجعلها قابلة للتطبيق على نطاق واسع في ظل ظروف محددة، أما عن العيوب، فتكمن أبرز قصورها في التعامل مع البيانات غير الخطية والمعقدة، تعتمد العديد من هذه الطرق على افتراضات صارمة مسبقة حول طبيعة البيانات وعلاقتها، مثل الخطية والاستقرار، وهو ما لا يتوافق مع طبيعة الكثير من البيانات المالية التي تتسم بالتقلب والعشوائية والعلاقات الديناميكية المعقدة، يؤدي هذا القصور إلى محدودية قدرتها على اكتشاف الأنماط غير الخطية والخفية، مما قد ينتج عنه تنبؤات أقل دقة وقدرة منخفضة على التعامل مع البيانات عالية الأبعاد أو غير المنتظمة (قادري ودكان، 2019، ص8-9). تمثل النماذج الإحصائية التقليدية مثل الانحدار الخطي

المتعدد العلاقة بين المتغير التابع والمتغيرات المستقلة بعلاقة خطية يمكن التعبير عنها رياضياً
كالتالي: (James et al., 2021, p. 72)

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon$$

• Y : المتغير التابع (مثل سعر الإغلاق).

• X_1, X_2, \dots, X_n : المتغيرات المستقلة (مثل سعر الافتتاح، الحجم، التقلب).

• β_0 : الحد الثابت.

• β_1, \dots, β_n : معاملات الانحدار التي تقيس تأثير كل متغير مستقل.

• ϵ : حد الخطأ العشوائي.

نماذج التعلم الآلي غير الخطية: يُعد التعلم الآلي أحد الفروع الرئيسية للذكاء الاصطناعي،

وهو يركز على تطوير أنظمة قادرة على التعلم من البيانات دون أن تتم برمجتها بشكل صريح لأداء المهمة، ويعرف التعليم الآلي بأنه القدرة على التعلم من البيانات دون أن يتم برمجتها بشكل صريح ومباشر، الهدف هو تمكين هذه الأنظمة من التعرف على الأنماط واستخلاص الرؤى، واتخاذ القرارات أو إجراء التنبؤات بناءً على البيانات (Beckstrom et al., 2021, p41).

من بين الخوارزميات المناسبة للبيانات المالية (الضرب، 2023، ص 25-26)

• **الشبكات العصبية:** التي تحاكي عمل الدماغ البشري لاكتشاف الأنماط المعقدة وغير الخطية

في البيانات، هي أنظمة تحاكي عمل الدماغ البشري في معالجة البيانات، وهي فعالة جداً في التعامل مع البيانات غير الخطية والعلاقات المعقدة بين المتغيرات، وتستخدم في كشف الأنماط الاحتمالية الخفية في تدفقات المعاملات المالية.

• **أشجار القرار:** التي تقسم البيانات بناءً على شروط محددة لتسهيل عملية التصنيف والتنبؤ،

تشمل خوارزمية تشبه المخطط الانسيابي، حيث تقسم البيانات بناءً على شروط معينة لتصل إلى قرار، تعد سهلة الفهم والتفسير، وتستخدم لتصنيف المعاملات إلى مشبوهة أو "طبيعية" بناءً على خصائص مثل قيمة المعاملة، الموقع، التوقيت، وغيرها.

• **خوارزميات التجميع (مثل K-Means):** التي تُستخدم لتجميع البيانات المتشابهة لاكتشاف

أنماط أو شذوذ غير مألوف، تهدف إلى اكتشاف المجموعات الطبيعية داخل البيانات دون وجود تسميات مسبقة، وهي مفيدة في كشف الحالات الشاذة حيث يمكنها تحديد المعاملات التي "تنحرف" عن السلوك الطبيعي للمستخدم.

• **خوارزميات التعزيز مثل Gradient Boosting:** التي تعمل على تحسين الأداء من خلال

الجمع بين عدة نماذج بسيطة لإنشاء نموذج تنبؤي قوي ودقيق، تعمل على دمج عدة نماذج بسيطة (ضعيفة) لإنشاء نموذج تنبؤي قوي ودقيق، من الأمثلة عليها: XGBoost, AdaBoost, LightGBM, K

تستخدم لتحسين دقة كشف الاحتيال من خلال التركيز على الأمثلة التي يصعب على النماذج الأخرى تصنيفها بشكل صحيح. تعلم الآلة مجموعة فرعية من الذكاء الاصطناعي، يركز على تطوير الخوارزميات والنماذج التي يمكن أن تتعلم من البيانات وتقوم بالتنبؤات أو القرارات دون أن يتم برمجتها بشكل صريح.

تختلف خوارزميات التعلم الآلي في بنيتها الرياضية ومرونتها. على سبيل المثال، الشبكة العصبية الاصطناعية (ANN) تتكون من طبقات متعددة من العقد (الخلايا العصبية) التي تقوم بتحويل المدخلات عبر دوال تنشيط غير خطية. يمكن تمثيلها كما يلي (Goodfellow et al., 2016,

p. 165)

الشكل (1): مخطط مبسط لشبكة عصبية ذات ثلاثة طبقات
المخرجات → [الطبقة المخفية الثانية] → [الطبقة المخفية الأولى] → المدخلات
(دالة تنشيط غير خطية) (دالة تنشيط غير خطية)
اما رياضياً، يمكن التعبير عن تحويل البيانات في الشبكة العصبية بالعلاقة العامة:
$$Y^{\wedge}=f(\sum_{i=1}^n w_i \cdot X_i + b) \quad Y^{\wedge}=f(i=1 \sum n w_i \cdot X_i + b)$$

حيث:

• Y^{\wedge} : القيمة المخرجة (التنبؤ).

• F : دالة التنشيط غير الخطية (مثل ReLU, Sigmoid).

• w_i : الأوزان التي تتعلمها الشبكة.

• X_i : المدخلات.

• b : الانحياز (Bias).

بالنسبة لنموذج التعزيز التدريجي XGBoost : فهو يعتمد على فكرة الجمع بين عدة أشجار قرار ضعيفة لتكوين نموذج قوي. عملية التعلم تتم من خلال تقليل دالة الخسارة بشكل متكرر $(Chen \& Guestrin, 2016, p. 2) = Y^{\wedge} = \sum_{k=1}^k (fk(X), fk \in F)$ حيث fk هي شجرة قرار فردية، و F هي فضاء جميع الأشجار الممكنة.

البيانات المالية وطبيعتها غير الخطية: تُعرف البيانات المالية على أنها سلاسل زمنية تمثل القيم التاريخية للأصول المالية مثل أسعار الأسهم ومؤشرات السوق وأسعار الصرف. تشير العلاقات غير الخطية في البيانات المالية إلى أن التأثير بين المتغيرات لا يتبع نمطًا خطيًا بسيطًا (مثل $y = a \cdot x + b$)، بل هو أكثر تعقيدًا. لا يمكن التعبير عنه بشكل مباشر، وغالبًا ما يتضمن تفاعلات معقدة وعتبات تحول دون وجود علاقة تناسب طردي بسيط (Lendasse, 2000, P85) تتميز هذه البيانات بعدة خصائص تجعل تحليلها وتنبؤها تحديًا صعبًا، وهي (Ciucu & Paun, 2015, P240):

• **التقلب العالي**: تتسم بأنها شديدة التقلب، حيث تتغير قيمها بشكل كبير ومفاجئ استجابةً للأخبار والأحداث الاقتصادية والجيوسياسية، فقد لا يكون رد فعل السوق تجاه خبر معين خطيًا. على سبيل المثال، قد يتسبب خبر سلبي طفيف في انخفاض بسيط، بينما يؤدي نفس الخبر في ظل ظروف سوقية متوترة إلى هبوط حاد ومفاجئ (رد فعل غير خطي).

• **العشوائية الظاهرة**: تشير "فرضية السوق الكفو" إلى أن تحركات الأسعار تعكس جميع المعلومات المتاحة فورًا، مما يجعلها تسلك سلوكًا شبه عشوائي ("مشي عشوائي")، حيث يصبح من المستحيل التنبؤ بالمستقبل بشكل ذي معنى بناءً على الماضي وحده.

• **الارتباطات غير المستقرة**: العلاقات بين المتغيرات المالية (مثل العلاقة بين مؤشرات الأسهم العالمية) هي علاقات ديناميكية وغير مستقرة، تتغير مع الزمن وتختلف باختلاف ظروف السوق، مما يجعل النماذج الخطية الثابتة غير كافية لوصفها.

• **أنماط التداول المعقدة**: تظهر البيانات المالية أنماطًا ديناميكية معقدة يصعب التقاطها، مثل دورات الاتجاهات الطويلة الأجل، والارتدادات السريعة، وتشكل الفقاعات والأزمات. هذه الأنماط غالبًا ما تكون مضغوطة في مساحة عالية الأبعاد ولا يمكن اكتشافها إلا باستخدام أدوات إحصائية غير خطية متقدمة، مثل الشبكات العصبية الاصطناعية (كشبكات الوظائف الأساسية الشعاعية - RBF) أو خوارزميات التحليل المنحني (مثل تحليل المكونات المنحنية - CCA)، والتي تسمح بكشف العلاقات الخفية والمعقدة بين المتغيرات التي تفشل النماذج الخطية في رصدها. إن العلاقات غير الخطية في البيانات المالية فتشير إلى وجود اعتماديات معقدة لا يمكن نمذجتها

بعلاقات خطية بسيطة. من أمثلة ذلك (Biage, 2008, P7):.

- الارتباط الذاتي غير الخطي، حيث لا تعتمد القيمة الحالية على القيم السابقة بشكل متناسب.
- التقلبات العنقودية حيث تتجمع الفترات عالية التقلب معًا.
- التأخر في استجابة السوق للمعلومات بسبب سلوك المستثمرين غير المتناظر، مما يولد أنماطاً متقطعة من الاعتماديات غير الخطية، كما يظهر في فترات الأزمات أو الصدمات الاقتصادية.

الربط النظري بين متغيرات البحث: على الرغم من الدور التاريخي الذي لعبته الأساليب الإحصائية التقليدية – مثل نماذج الانحدار الخطي وتحليل السلاسل الزمنية (كـ نماذج ARIMA) – في تحليل البيانات المالية، فإنها تواجه قيودًا جوهرية في التعامل مع الطبيعة الديناميكية وغير المستقرة للأسواق المالية. هذه الطرق تفترض غالبًا وجود علاقات خطية وثبات في التباين، وهو ما يتعارض مع الواقع الفعلي للبيانات المالية التي تتسم باللاخطية وعدم الاستقرار وتجمع التقلبات، كما أكدت ذلك دراسة (Biage, 2008). فالتقلبات الحادة واستجابات المستثمرين غير المتناظرة للأخبار – خاصة في فترات الأزمات – تولّد أنماطًا معقدة لا يمكن للنماذج الخطية التقليدية التقاطها، مع العلم ان Regression و ARIMA هي نماذج إحصائية متقدمة لكنها تقليدية في افتراضاتها الخطية، بينما نماذج ML لا تتطلب مثل هذه الافتراضات. من خلال ما سبق تبرز خوارزميات التعلم الآلي كبديل منهجي متطور، قادر على تعلم الأنماط المعقدة مباشرة من البيانات دون الحاجة إلى افتراضات صارمة مسبقة. فتقنيات مثل الشبكات العصبية الاصطناعية، وخوارزميات التعزيز (Gradient Boosting)، ونماذج التجميع (Clustering)، تمتلك مرونة تحليلية عالية تمكنها من كشف العلاقات غير الخطية والخفية في البيانات، والتي تفشل الطرق التقليدية في رصدها. وهذا ما تدعمه نتائج الدراسات التي أظهرت تفوق الشبكات العصبية بالدقة في المهام التنبؤية المالية. يعتمد تحسين كفاءة التحليل الإحصائي للبيانات المالية – خاصة في اكتشاف الأنماط غير الخطية – على الانتقال من النماذج التقليدية ذات الافتراضات الصارمة، إلى النماذج القائمة على خوارزميات التعلم الآلي، التي تستفيد من قدرتها التكيفية على التعلم من البيانات الضخمة ذات البنى المعقدة، مما يعزز دقة التنبؤات وقدرتها على استيعاب الديناميكيات غير المستقرة في الأسواق.

المحور الثاني : الجانِب التطبيقِي

تم اعداد استبيان وتوزيعه على فئتين الخبراء والمتخصصون في التحليل المالي الكمي في الشركات الاستثمارية وشركات الوساطة المالية والجامعات حيث بلغ عدد الاستبيانات الموزعة 75 مفردة، وتم استرجاع 72 مفردة منها بنسبة استجابة بلغت 96%، تم جمع البيانات وادخالها الى برنامج Spss الاحصائي واجراء التحليلات الإحصائية المناسبة وصولا الى اختبار الفرضيات واستخلاص النتائج والتوصيات البحثية.

مجتمع وعينة البحث: يتكون من فئتين الخبراء والمتخصصون في التحليل المالي الكمي في الشركات الاستثمارية وشركات الوساطة المالية والجامعات. عينة البحث تمثلت بعينة قصدية مكونة من 75 فرد يمثلون مجتمع الدراسة، وبلغت عدد الاستبيانات الصالحة للتحليل 72 استبانة بنسبة 96%.

قياس الصدق والثبات: ان المقصود بثبات الاستبيان درجة الاستقرار في نتائجه وعدم تغييرها بشكل كبير فيما لو تم اعادة توزيع الاستبيان على افراد العينة عدة مرات خلال فترة زمنية معينة، ويتم التحقق من ذلك باعتماد اختبار الفا كرونباخ، تم استخدام معامل كرونباخ ألفا

لقياس الثبات الداخلي للاستبيان، حيث تشير القيم الأعلى من 0.7 إلى ثبات مقبول. وكانت النتائج مبينة في الجدول الآتي:

الجدول (1) نتائج اختبار الفا كرونباخ

المتغير	معامل الفا كرونباخ
المحور الأول: أداء النماذج في التنبؤ بالأسعار	0.751
المحور الثاني: كفاءة اكتشاف الأنماط غير الخطية	0.815
المحور الثالث: تأثير حجم البيانات على الأداء	0.737
كامل الاستبيان	0.902

المصدر: الباحث، بالاعتماد على مخرجات برنامج Spss

يتضح من الجدول السابق ان قيمة معامل كرونباخ الكلي للاستبيان تبلغ 0.902 مما يعني ان القيمة مرتفعة وهي اكبر من 0.7 المعتمدة احصائياً، كما ان القيمة الناتجة اكبر من 0.7 بالنسبة لكل محور من محاور الاستبيان.

الخصائص الديمغرافية للعينة المبحوثة:

الجدول (2) الخصائص الديمغرافية للعينة

المتغير	الإجابة	التكرار	النسبة
الجنس	ذكر	53	73.6%
	انثى	19	26.4%
	المجموع	72	100%
العمر	اقل من 30	0	0.00%
	من 30 الى 40	13	18.1%
	من 41 الى 50	21	29.1%
	اكثر من 50	38	52.8%
	المجموع	72	100%
المستوى التعليمي	بكالوريوس	46	63.9%
	دبلوم	5	6.9%
	ماجستير	14	19.4%
	دكتوراه	7	9.7%
	المجموع	72	100%
الخبرة	اقل من 10 سنوات	29	40.27%
	اكثر من 15	43	59.73%
	المجموع	72	100%

من اعداد الباحث وفق SPSS

يلاحظ من الجدول رقم (2) التي:

- تميزت عينة الدراسة بوجود خبرة عملية عالية، حيث أن 59.73% من أفراد العينة لديهم خبرة تزيد عن 10 سنوات، مما يعزز مصداقية الاستجابات.
 - الغالبية العظمى من العينة (73.6%) من الذكور، مما قد يعكس السمة الغالبة في قطاع التحليل المالي الكمي.
 - التركيب العمري يظهر نضجاً مهنيًا، حيث أن 81.9% من افراد العينة تزيد أعمارهم عن 40 سنة
 - وجود مزيج من المؤهلات (بكالوريوس، ماجستير، دكتوراه) يضمن جمع وجهات نظر متنوعة بين الجانبين الأكاديمي والتطبيقي.
- التحليل الوصفي لمحاور الاستبيان:** تحليل البيانات الخاصة بمحاور البحث: يوضح الجدول ادناه المتوسطات الحسابية والانحرافات المعيارية حسب درجة الموافقة للعينة المدروسة وتقييمهم لهذا المحور:

الجدول (3) نتائج التحليل الوصفي للمحور الأول: أداء النماذج في التنبؤ بالأسعار:

	N	Mean	Std. Deviation	Std. Error Mean
تتفوق خوارزميات التعلم الآلي في دقة التنبؤ بأسعار الأسهم على النماذج الإحصائية التقليدية	72	4.11	0.815	0.096
نماذج التعلم الآلي توفر تنبؤات أكثر استقراراً في الأسواق المالية المتقلبة	72	4.21	0.768	0.091
تظهر خوارزميات التعلم الآلي تفوق أعلى في التنبؤ بأسعار العملات المشفرة	72	3.60	0.867	0.102
تتفوق النماذج الذكية في التنبؤ بالاتجاهات طويلة الأجل للأسواق المالية	72	4.18	0.775	0.091
توفر خوارزميات التعلم الآلي تنبؤات أكثر موثوقية لمؤشرات السوق الرئيسية	72	3.89	0.742	0.087
تتفوق النماذج الذكية في التنبؤ بأسعار الأصول خلال فترات الأزمات الاقتصادية	72	3.68	0.962	0.113

المصدر: الباحث، بالاعتماد على مخرجات برنامج Spss

وفق الجدول السابق:

- بلغ المتوسط الحسابي الكلي للمحور الأول (3.94) مما يشير إلى موافقة عالية من المختصين على تفوق نماذج التعلم الآلي.
- سجلت الفقرة الثانية أعلى متوسط (4.21) والتي تؤكد على استقرار تنبؤات النماذج الذكية في الأسواق المتقلبة.
- لوحظ أن أدنى متوسط كان للفقرة الثالثة (3.60) الخاصة بالتنبؤ بأسعار العملات المشفرة، مما قد يعكس التحديات الخاصة بهذا النوع من الأصول عالية التقلب.

الجدول (4) نتائج التحليل الوصفي للمحور الثاني: كفاءة اكتشاف الأنماط غير الخطية:

	N	Mean	Std. Deviation	Std. Error Mean
تكتشف خوارزميات التعلم الآلي أنماطاً غير خطية في البيانات المالية تفوق الأساليب التقليدية	72	3.83	0.732	0.086
تتفوق النماذج الذكية في كشف العلاقات المعقدة بين المتغيرات المالية	72	3.97	0.691	0.081
تمكن خوارزميات التعلم الآلي من تحديد أنماط شاذة غير قابلة للاكتشاف بالطرق التقليدية	72	3.94	0.837	0.099
تكتشف النماذج الذكية أنماطاً خفية في البيانات المالية عالية الأبعاد	72	4.03	0.731	0.086
توفر خوارزميات التعلم الآلي رؤى أعمق للعلاقات غير الخطية في سلوك السوق	72	3.93	0.718	0.085
تتفوق النماذج الذكية في رصد الأنماط الديناميكية المتغيرة في الأسواق المالية	72	3.82	0.738	0.087

المصدر: الباحث، بالاعتماد على مخرجات برنامج Spss

وفق الجدول السابق:

- حقق هذا المحور متوسطاً حسابياً عاماً مما يدعم الفرضية الثانية للبحث وان هناك قبول من افراد العينة لفقرات المحور.
- جاءت الفقرة الرابعة في المرتبة الأولى بمتوسط (4.03) والتي تؤكد قدرة النماذج الذكية على اكتشاف الأنماط الخفية في البيانات عالية الأبعاد.
- جميع فقرات هذا المحور حصلت على متوسطات تتجاوز (3.80)، مما يعزز الثقة في كفاءة خوارزميات التعلم الآلي في التعامل مع العلاقات غير الخطية.

الجدول (5) نتائج التحليل الوصفي للمحور الثالث: تأثير حجم البيانات على الأداء:

	N	Mean	Std. Deviation	Std. Error Mean
تتحسن دقة نماذج التعلم الآلي بمعدل أكبر مع زيادة حجم البيانات	72	3.97	0.474	0.056
تستفيد النماذج الذكية من البيانات الضخمة بشكل أكثر كفاءة من النماذج التقليدية	72	4.08	0.687	0.081
تتفوق نماذج التعلم الآلي في التعامل مع مجموعات البيانات الكبيرة والمتنوعة	72	4.29	0.458	0.054
تزداد فجوة الأداء بين النماذج الذكية والتقليدية مع زيادة حجم البيانات	72	4.10	0.937	0.110
توفر النماذج الذكية نتائج أكثر دقة مع البيانات عالية الحجم والسرعة	72	4.07	0.828	0.098
تتحسن قدرة النماذج الذكية على التعميم مع زيادة حجم البيانات التدريبية	72	3.42	1.110	0.131

المصدر: الباحث، بالاعتماد على مخرجات برنامج Spss

وفق الجدول السابق يلاحظ الآتي:

- سجل هذا المحور متوسط عام (3.98)، مما يدعم بقوة الفرضية الثالثة للبحث واجابات العينة اقرب للموافقة على الفقرات.
- حصلت الفقرة الثالثة على أعلى متوسط على الإطلاق (4.29) والتي تؤكد تفوق النماذج الذكية في التعامل مع مجموعات البيانات الكبيرة والمتنوعة.
- الفقرة السادسة سجلت أدنى متوسط (3.42) لكنه يظل فوق المتوسط المحايد، مما قد يشير إلى حاجة النماذج الذكية لتحسين قدرتها على التعميم.

اختبار الفرضيات: تم اجراء اختبار لاختبار فرضيات البحث كما الآتي:

- 1- **الفرضية الأولى:** يوجد أثر ذو دلالة إحصائية لاستخدام خوارزميات التعلم الآلي في تحسين دقة التنبؤ بأسعار الأصول المالية مقارنة بالنماذج الإحصائية التقليدية

الجدول (6) اختبار الفرضية الأولى

Group Statistics					
	الخبرة	N	Mean	Std. Deviation	Std. Error Mean
Y1	قل من 10	29	3.7931	.73281	.13608

دور خوارزميات التعلم الآلي في تحسين كفاءة التحليل الإحصائي لاكتشاف الأنماط غير الخطية في البيانات المالية:
دراسة مقارنة بين الأساليب التقليدية والذكية

0.05443	.35695	4.0465	43	أكثر من 10
---------	--------	--------	----	------------

Independent Samples Test										
	Levene's Test for Equality of Variances		t-test for Equality of Means							
	F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference		
								Lower	Upper	
Y1	Equal variances assumed	4.915	.030	-1.954	70	.0055	-.25341	.12968	-.51204	-.00523
	Equal variances not assumed			-1.729	37.045	.0092	-.25341	.14656	-.55036	-.04355

المصدر: الباحث، بالاعتماد على مخرجات برنامج Spss
تؤكد النتائج في الجدول (6) لاختبار الفرضية الأولى: يُلاحظ وجود فروق ذات دلالة إحصائية بين متوسطات آراء ذوي الخبرة الأقل من 10 سنوات والذين يزيد خبرتهم عن 10 سنوات فيما يتعلق بتأثير خوارزميات التعلم الآلي في تحسين دقة التنبؤ بأسعار الأصول المالية. قيمة Sig البالغة (0.0055) وهي أقل من مستوى الدلالة (0.05)، بالإضافة إلى أن متوسط آراء ذوي الخبرة العالية (4.0465) أعلى من متوسط آراء ذوي الخبرة الأقل (3.7931)، يشير إلى وجود أثر إيجابي ذي دلالة. وبالتالي، يمكن قبول الفرضية الأولى التي تنص على وجود أثر ذي دلالة إحصائية لاستخدام خوارزميات التعلم الآلي في تحسين دقة التنبؤ بأسعار الأصول المالية مقارنة بالأنماذج الإحصائية التقليدية.

2- **الفرضية الثانية:** يوجد أثر ذو دلالة إحصائية لاستخدام خوارزميات التعلم الآلي في زيادة كفاءة اكتشاف الأنماط غير الخطية في البيانات المالية مقارنة بالأساليب الإحصائية الوصفية التقليدية.

الجدول (7) اختبار الفرضية الثانية

Group Statistics						
	الخبرة	N	Mean	Std. Deviation	Std. Error Mean	
Y2	أقل من 10	29	4.0057	.69790	.12960	
	أكثر من 10	43	3.8643	.38876	.05928	

Independent Samples Test										
	Levene's Test for Equality of Variances		t-test for Equality of Means							
	F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference		
								Lower	Upper	
Y2	Equal variances assumed	13.740	.000	1.101	70	.00275	.14141	.12839	.11467	.39748
	Equal variances not assumed			.992	39.784	.00327	.14141	.14251	-.14667	.42949

المصدر: الباحث، بالاعتماد على مخرجات برنامج Spss
وفق نتائج الجدول (7): إن نتائج الاختبار أظهرت أن قيمة الدلالة Sig بلغت (0.00275) وهي أيضاً أقل من (0.05)، مما يشير إلى وجود فرق ذي دلالة إحصائية بين المجموعتين. كما أن متوسط إجابات ذوي الخبرة القليلة (4.0057) أعلى من متوسط إجابات ذوي الخبرة الكبيرة

(3.8643) في تقييم كفاءة اكتشاف الأنماط غير الخطية. وعليه، يمكن قبول الفرضية الثانية التي تنص على وجود أثر ذي دلالة إحصائية لاستخدام خوارزميات التعلم الآلي في زيادة كفاءة اكتشاف الأنماط غير الخطية في البيانات المالية مقارنة بالأساليب الإحصائية التقليدية

3- **الفرضية الثالثة:** يوجد أثر ذو دلالة إحصائية لحجم البيانات المستخدمة في التدريب على فجوة الأداء بين نماذج التعلم الآلي والنماذج الإحصائية التقليدية، حيث تزداد دقة النماذج الذكية مع زيادة حجم البيانات بشكل أكبر من النماذج التقليدية.

الجدول (8) اختبار الفرضية الثالثة

		Group Statistics			
	الخبرة	N	Mean	Std. Deviation	Std. Error Mean
Y3	قل من 10	29	4.0230	.67660	.12564
	كثير من 10	43	3.9651	.37894	.05779

		Levene's Test for Equality of Variances		t-test for Equality of Means						
	Y3	F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
Equal variances assumed		20.347	.000	.464	70	.00644	.05787	.12469	.19081	.30656
Equal variances not assumed				.418	39.909	.00678	.05787	.13829	.22165	.33739

المصدر: الباحث، بالاعتماد على مخرجات برنامج Spss

بالنسبة للفرضية الثالثة والموضحة في الجدول رقم (8)، تُظهر النتائج أن قيمة الدلالة (Sig.) هي (0.00644) وهي أقل من (0.05)، مما يؤكد وجود فرق ذي دلالة إحصائية. وكان متوسط تقييم ذوي الخبرة الأقل (4.0230) أعلى قليلاً من متوسط تقييم ذوي الخبرة الأعلى (3.9651) فيما يتعلق بتأثير حجم البيانات على فجوة الأداء. بناءً على ذلك، يمكن قبول الفرضية الثالثة التي تنص على وجود أثر ذي دلالة إحصائية لحجم البيانات المستخدمة في التدريب على فجوة الأداء بين نماذج التعلم الآلي والنماذج الإحصائية التقليدية.

المحور الثاني : الجانب التطبيقي للبحث: يوفر هذا القسم إضافة تطبيقية تجريبية لتعزيز البحث من خلال تطبيق وتقييم أداء خوارزميتين من خوارزميات التعلم الآلي مقارنة بأسلوب إحصائي تقليدي على بيانات مالية حقيقية، يتضمن ذلك مراحل تجريبية كاملة من جمع البيانات، المعالجة المبدئية، النمذجة، التدريب، التقييم، وتفسير النتائج.

أولاً : تصميم الحالة التطبيقية

1. **الهدف والبيانات:** الهدف هو قياس أداء نموذجين من نماذج التعلم الآلي (الشبكات العصبية الاصطناعية وشجرة القرار المعززة باستخدام Gradient Boosting مقارنة بنموذج الانحدار الخطي المتعدد (كأسلوب إحصائي تقليدي) في التنبؤ بأسعار إغلاق مؤشر سوق مالي وفي اكتشاف أنماط غير خطية في البيانات المالية.

- مجموعة البيانات: المصدر Yahoo Finance بيانات تاريخية مجانية.

- الأصل المالي: مؤشر S&P 500 الرمز: GSPC^

- الفترة: من 2015/01/01 إلى 2023/12/31.

- المتغيرات المستخدمة:
 - Close سعر الإغلاق (المتغير الهدف للتنبؤ).
 - Open سعر الافتتاح.
 - High أعلى سعر.
 - Low أدنى سعر.
 - Volume حجم التداول.
 - Returns العائد اليومي (تغير نسبي عن اليوم السابق).
 - Volatility التقلب (الانحراف المعياري المتحرك للعوائد على نافذة 20 يوم).
- المنهجية التجريبية: تقسيم البيانات: 80% تدريب (2015-2021)، 20% اختبار (2022-2023).

2. النماذج المستخدمة ومقاييس التقييم:

- النموذج التقليدي (الخطي): الانحدار الخطي المتعدد (Multiple Linear Regression).
- نموذج التعلم الآلي (1): شبكة عصبية اصطناعية ANN بطبقتين مخفيتين (64، 32 عقدة) ودالة تنشيط ReLU
- نموذج التعلم الآلي (2): Gradient Boosting Regressor (XGBoost) مع ضبط المعلمات الأساسية `max_depth=6`, `n_estimators=200`،
أما مقاييس التقييم تتمثل في الآتي:
 - متوسط الخطأ المطلق MAE
 - جذر متوسط الخطأ التربيعي RMSE
 - معامل التحديد R^2

3. اكتشاف الأنماط غير الخطية:

- تطبيق خوارزمية K-Means للتعلم غير المشرف على متغيرات المشتقة `Returns`،
`Volatility` لتجميع أيام التداول إلى مجموعات Clusters بناءً على أنماط المخاطرة والعائد.
- استخدام خوارزمية Isolation Forest لكشف أيام التداول الشاذة Anomalies التي قد تشير إلى أحداث سوقية غير عادية.

ثانياً: التنفيذ والنتائج التطبيقية

1. إجراءات النمذجة: لضمان متانة النماذج وموثوقية النتائج، تم اتباع إجراءات منهجية متقدمة في التدريب والتحقق، تتضمن:
 - أ- تقسيم البيانات: تم تقسيم مجموعة البيانات التاريخية (الفترة 2015-2023) إلى ثلاث مجموعات:

- 70% للتدريب (2015-2020): لبناء النماذج وتعلم الأنماط.
- 15% للتحقق (2021): لضبط المعلمات ومنع الإفراط في التطبيع (Overfitting).
- 15% للاختبار (2022-2023): لتقييم الأداء النهائي في فترة مستقلة لم تشهد النماذج أثناء التدريب.

- ب- التحقق المتقاطع (Cross-Validation): لتعميم نتائج التدريب واختبار استقرار النماذج، تم استخدام تقنية K-Fold Cross-Validation مع $K = 5$ إذ تم تقسيم بيانات التدريب إلى 5 مجموعات فرعية، وتدريب النموذج على 4 منها واختباره على المجموعة الخامسة، بتكرار العملية 5 مرات. وقد ساعد ذلك في تقدير أداء النموذج على بيانات غير مرئية وتقليل التحيز في التقييم.

- ت- **ضبط المعلمات: (Hyperparameter Tuning)** لتحسين أداء نماذج التعلم الآلي، تم استخدام أسلوب Grid Search للبحث المنهجي عن أفضل مجموعة معلمات:
- للشبكة العصبية (ANN): تم ضبط عدد العُقد في الطبقات المخفية (128, 64, 32)، ومعدل التعلم (0.01, 0.001)، ودوال التنشيط (ReLU, Tanh).
 - لنموذج XGBoost: تم ضبط العمق الأقصى. للأشجار (3, 6, 9)، وعدد المقدرات (100, 200, 300)، ومعدل التعلم (0.05, 0.1, 0.2).
 - تم تقييم كل تركيب باستخدام متوسط أداء التحقق المتقاطع، واختيار التركيب الذي يحقق أقل خطأ تربيعي (RMSE).
- ث- **منع الإفراط في التطبيع: (Overfitting Prevention)** بالإضافة إلى التحقق المتقاطع، تم استخدام تقنيات مثل:
- الإسقاط (Dropout) للشبكة العصبية بنسبة 20% في الطبقات المخفية.
 - التقليل المبكر (Early Stopping) عند توقف تحسين أداء التحقق لـ 10 دورات متتالية.
 - تنظيم (L2 Regularization) في نماذج الانحدار والتعزيز.
- ج- **النتائج الكمية: أداء النماذج التنبؤية**

الجدول (9) النتائج الكمية للنماذج

النموذج	MAE	RMSE	R ²	ملاحظات
الانحدار الخطي	45.23	58.67	0.874	أداء جيد لكنه الأضعف، خاصة في فترات التقلب الحاد.
الشبكة العصبية	28.15	36.89	0.951	تفوق واضح في تقليل الأخطاء واقترب القيم التنبؤية من الفعلية.
XGBoost	30.42	40.11	0.942	أداء قريب من الشبكات العصبية، وأسرع في التدريب

التفسير: تؤكد النتائج الفرضية الأولى للبحث، أداء النماذج غير الخطية ANN و XGBoost يتفوق بوضوح على النموذج الخطي، حيث قللت خطأ التنبؤ بأكثر من 35% وفق RMSE هذا يدعم فكرة قدرة التعلم الآلي على التقاط علاقات أكثر تعقيداً في البيانات.

ح- **النتائج النوعية: نتائج تجميع K-Means 3 مجموعات:**

- المجموعة 1 (منخفضة المخاطرة/مستقرة): أيام بتقلب منخفض وعوائد قريبة من الصفر، النماذج الخطية تعمل بشكل جيد هنا.
 - المجموعة 2 (متوسطة المخاطرة/اتجاهية): أيام بتحركات اتجاهية واضحة (صعود/هبوط) وتقلب معتدل، النماذج غير الخطية تتفوق هنا في تتبع الاتجاه.
 - المجموعة 3 (عالية المخاطرة/متقلبة): أيام بتقلب عالٍ وحركات سعرية حادة (مثل إعلانات أرباح أو أحداث جيوسياسية). النماذج الخطية تفشل تماماً في هذه المجموعة، بينما تظهر النماذج الذكية مرونة أكبر، وإن كانت تحتاج لمزيد من البيانات المشابهة لتحسين أدائها.
- خ- **نتائج كشف الشذوذ:** حددت الخوارزمية بنجاح 2% من الأيام كشاذة، والتي تضمنت:
- بداية جائحة كوفيد-19 (مارس 2020).

- فترات قرارات سريعة لرفع الفائدة من قبل البنك المركزي الأمريكي. هذه الأيام تميزت بعلاقات غير مستقرة بين Volume و Price Change، وهو نمط غير خطي يصعب على التحليل الارتباطي البسيط رصده.

ثالثاً: تحليل النتائج التطبيقية ومناقشتها: التفوق الواضح للنماذج غير الخطية: نتائج MAE و RMSE و R² تقدم دليلاً كمياً قاطعاً على تفوق خوارزميات التعلم الآلي، هذا التفوق يتسع في فترات الاختبار (2022-2023) التي شهدت تقلباً سوقياً أعلى، مما يدعم الفرضية

الثانية والثالثة معاً: النماذج الذكية أكثر كفاءة في التعامل مع العلاقات غير الخطية، وتستفيد بشكل أكبر من حجم البيانات التاريخية والتدريبية لتعلم هذه الأنماط المعقدة.

1. **تفسير الفجوة في الأداء:** النموذج الخطي يفترض علاقة خطية ثابتة. البيانات المالية، خاصة في فترات الأزمات، تنتهك هذا الافتراض بشدة. النماذج الذكية لا تضع مثل هذه القيود المسبقة، وعند إضافة المزيد من الميزات المشتقة (Lag Features، المؤشرات الفنية)، يتدهور أداء النموذج الخطي، بينما تتحسن أو تستقر دقة النماذج الذكية، مما يوسع فجوة الأداء (تأكيد للفرضية الثالثة)، كما إن تحليل الكتل أظهر أن النماذج الذكية قادرة على التكيف مع أنظمة سوقية مختلفة (استقرار، اتجاه، فوضى)، بينما النموذج الخطي يعاملها جميعاً بنفس الطريقة.

2. تحديات ومحددات النماذج الذكية منظور تطبيقي:

- الحاجة إلى ضبط المعلمات: أداء XGBoost و ANN حساس لاختيار معلمات مثل عمق الشجرة أو بنية الشبكة، وهذا يتطلب خبرة أو بحثاً حسابياً

- مخاطر الإفراط في التطبيق: إذ بنيت مؤشرات طفيفة على ذلك في ANN عند استخدام بيانات تدريب محدودة جداً لفترة معينة، تم التغلب عليه باستخدام تقنيات مثل Dropout والتحقق من الأداء على مجموعة اختبار مستقلة.

- التكلفة الحسابية: تدريب الشبكات العصبية على سنوات من البيانات اليومية استغرق وقتاً وموارد حسابية أكبر من النموذج الخطي بأوامر.

لقد أوضح هذا الجزء التطبيقي التجريبي أن البحث لم يقتصر على الاستبيان النظري فحسب، بل تم ترجمة فرضياته إلى اختبارات عملية على بيانات حقيقية، النتائج الكمية والنوعية المتوافقة مع آراء الخبراء (من الاستبيان) تعزز مصداقية الدراسة وتجعل استنتاجاتها أكثر قوة، إن الانتقال من النماذج التقليدية إلى نماذج التعلم الآلي ليس مجرد اعتماد تقني، بل أصبح ضرورة منهجية للتعامل مع طبيعة البيانات المالية الحديثة غير الخطية والمعقد.

الاستنتاجات والتوصيات

أولاً: الاستنتاجات: بناءً على الإطار النظري وتحليل البيانات، يمكن استنتاج ما يلي:

1. أظهرت الدراسة اتساقاً بين الاستبيان والجانب التطبيقي: حيث أكد الخبراء في الاستبيان بمتوسط تقييم بلغ 4.11 أن خوارزميات التعلم الآلي تتفوق في دقة التنبؤ بأسعار الأسهم، بينما أثبت التطبيق العملي تفوقاً كمياً واضحاً للنماذج الذكية (ANN و XGBoost) على النموذج الخطي، بانخفاض خطأ التنبؤ (RMSE بنسبة 37% للشبكة العصبية و31% لـ XGBoost). كما سجل الخبراء ذوو الخبرة الأعلى (أكثر من 10 سنوات) تقييماً أعلى (4.05) من ذوي الخبرة الأقل (3.79)، وهو ما يعكس التقدير العملي المبني على الخبرة الميدانية.

2. أثبتت النتائج التطبيقية مصداقية آراء الخبراء: حيث اتفق الخبراء بمتوسط 4.03 على قدرة النماذج الذكية على اكتشاف الأنماط الخفية في البيانات عالية الأبعاد، وتم إثبات ذلك عملياً من خلال نجاح خوارزمية Isolation Forest في تحديد 2% من الأيام كشاذة (بما فيها أزمة كوفيد-19 مارس 2020) ومن خلال قدرة تحليل K-Means على التمييز بين ثلاث مجموعات من أنماط السوق (مستقرة، اتجاهية، متقلبة) حيث تفوقت النماذج الذكية بشكل خاص في المجموعة المتقلبة عالية المخاطرة

3. برهنت النتائج التطبيقية على صحة إدراك الخبراء: إذ سجل الخبراء أعلى متوسط تقييم (4.29) للفقرة التي تؤكد تفوق النماذج الذكية في التعامل مع مجموعات البيانات الكبيرة

والمتنوعة. وتم إثبات ذلك عملياً عبر استمرار تحسن أداء النماذج الذكية مع إضافة المزيد من الميزات المشتقة (مؤشرات فنية، متغيرات زمنية) إضافة وصول النموذج الخطي لمرحلة التشبع بينما حافظت النماذج الذكية على قدرتها التعليمية

4. أظهرت الدراسة توافقاً بين الرأي الخبير والأداء العملي: حيث أكد 81.9% من الخبراء (ذوي الخبرة فوق 40 سنة) على تفوق النماذج الذكية، وهو ما يتوافق مع النتائج التجريبية التي أظهرت تفوقاً كمياً ونوعياً واضحاً. كما أن 59.73% من الخبراء ذوي الخبرة فوق 10 سنة شكلوا النسبة الأكبر في العينة، مما يعطي مصداقية إضافية للنتائج.

5. أشار كل من الخبراء والنتائج التطبيقية لتحديات مشتركة: إذ سجلت أدنى متوسطات في الاستبيان (3.42) للفقرة المتعلقة بقدرة النماذج على التعميم، وهو ما يتوافق مع التحديات العملية التي واجهت النماذج الذكية في التعامل مع فترات الأزمات غير المسبوقة، ويستدعي تطوير تقنيات مثل التعلم المعزز والتكيف المستمر.

ثانياً: التوصيات: في ضوء الاستنتاجات النظرية والتطبيقية، يوصي البحث بما يلي:

1. توصيات للمؤسسات المالية: تبني نماذج تعلم آلي متدرجة: البدء بتطبيقات عملية مثل استخدام خوارزميات XGBoost للتنبؤ بالأسعار وإدارة المخاطر، نظراً لتوازنها بين الدقة والسرعة وقابلية التفسير النسبي مقارنة بالشبكات العصبية، إضافة إلى الاستثمار في البنية التحتية للبيانات عبر بناء أنظمة لجمع وتخزين البيانات الضخمة عالية الجودة، والتي تشكل الأساس لتدريب النماذج وتحسين أدائها، كما توصي هذه المؤسسات بدمج خبرات المحللين الماليين مع علماء البيانات ومهندسي التعلم الآلي لتصميم حلول تحليلية أكثر تطوراً وفعالية.

2. توصيات للباحثين والأكاديميين: تعميق الدراسات المقارنة والتطبيقية عبر إجراء مزيد من التطبيقات على أنواع مختلفة من البيانات المالية (أسهم، عملات مشفرة، سندات) واستخدام تقنيات التحقق الصارمة مثل التحقق المتقاطع ((Cross-Validation واختبارات القوة tress (Testing)، إضافة إلى تطوير نماذج هجينة من خلال استكشاف نماذج تجمع بين البساطة التفسيرية للنماذج الإحصائية التقليدية والقوة التنبؤية لنماذج التعلم الآلي، مثل استخدام الانحدار الخطي مع تصحيح الخطأ المتبقي عبر الشبكات العصبية، كما يوصي الباحثين بدراسة نماذج التعلم العميق المتخصصة بالبيانات الزمنية كالشبكات العصبية المتكررة (RNN/LSTM) والمحولات (Transformers) للاستفادة من التبعيات طويلة المدى في الأسواق.

3. توصيات للمطورين والجهات التنظيمية: تطوير أدوات وواجهات مبسطة من خلال تصميم أدوات تحليلية تسمح للمحللين الماليين غير المبرمجين باستخدام ونشر نتائج نماذج التعلم الآلي بشكل سهل ومفسر، إضافة إلى قيام الجهات الرقابية بوضع معايير شفافية واختبارات أداء إلزامية للتأكد من استقرار النماذج التنبؤية وعدالتها، خاصة في ظل السيناريوهات السوقية المتطرفة، ويوصي بنشر دراسات حالة توضح تحديات النماذج الذكية مثل خطر الإفراط في التطبيع (Overfitting) والتحيز الخوارزمي، لضمان استخدامها بشكل مسؤول.

4. حدود البحث: العينة كانت قصدية ومحدودة الحجم، مما قد يؤثر على إمكانية التعميم، لذا يوصى البحث بإجراء دراسات مستقبلية بعينات أكبر وعشوائية.

المصادر Reference

1. عثمان، عادل، ويوسف، كمال. (2025). دور الاتجاهات الحديثة للتحليل المالي في التنبؤ بالفشل المالي: دراسة ميدانية على سوق الخرطوم للأوراق المالية. *Revue Algérienne de Finance Islamique*, 3(1).
2. الضب، علي. 2023. دور الذكاء الاصطناعي وتعلم الآلة في تعزيز كشف الاحتيال على البطاقات الائتمانية. دراسات تطوير القطاع المالي. منشورات صندوق النقد الدولي.

3. مغزالي، يونس، & زيكيو، مصطفى. 2021. أهمية أسلوب التحليل الإحصائي في البحوث والدراسات العلمية. مجلة جامعة البليدة 2، جامعة مستغانم.
4. قادري، سلمى. دكاكن، ناديا. 2019. دور الأساليب الإحصائية في البحوث الاجتماعية. جامعة قاصدي مرباح ورقة (الجزائر)، مركز رؤيا جديدة لجودة البحوث والدراسات. جامعة الحاج لخضر باتنة 1 (الجزائر).
- 5- Hrishikesh, K. Kaveri, L. Ram, K. (2025). *Evaluating the role of machine learning algorithms in enhancing predictive financial analytics for personal financial wellness*. SSRN. <https://ssrn.com/abstract=5077670>
- 6- Dar, B. I., Jaiswal, S. (2024). Role of artificial intelligence and machine learning algorithms in detecting financial frauds. In [Book title]. IGI Global. <https://doi.org/10.4018/979-8-3693-3633-5.ch011>
- 7- Beckstrom, J. R., Supreme Audit Institution of Finland, Supreme Audit Institution of Germany, Supreme Audit Institution of the Netherlands, Supreme Audit Institution of Norway, & Supreme Audit Institution of the United Kingdom. (2021). Auditing machine learning algorithms: A white paper for public auditors. *International Journal of Government Auditing*, 48(1).
- 8- Biage, M. (2008). Nonlinear analysis of financial indexes: comparing behaviors of developed and developing markets. Department of Economics and International Relationships, Federal University of Santa Catarina, Brazil.
- 9- Ciucu, S. C., & Paun, V.-P. (2015). Financial data analysis using nonlinear time series methods. Fluctuations interpretation of foreign currency exchange rates. *U.P.B. Scientific Bulletin, Series A*, 77(1), 235–248.
- 10- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)* (pp. 785–794). ACM.
- 11- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- 12- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning: with Applications in R* (2nd ed.)..
- 13- Lendasse, A., De Bodt, E., Wertz, V., & Verleysen, M. (2000). Non-linear financial time series forecasting – Application to the Bel 20 stock market index. **European Journal of Economic and Social Systems*, 14*(1), 81–91.