

أثر تطبيق خوارزميات التعلم الآلي على التنبؤ باتجاه أسعار الأسهم:
دراسة تطبيقية على الشركات المدرجة في سوق الأوراق المالية بمصر

**The impact of applying machine learning algorithms on predicting the
direction of stock prices:**

An applied study on companies listed in the Egyptian Stock Exchange

إعداد

د/ صافيناز محمود محمد محمود صالح

مدرس المحاسبة والمراجعة

المعهد العالي للعلوم الإدارية بجناكليس - البحيرة

مجلة البحوث الإدارية والمالية والكمية

كلية التجارة – جامعة السويس

المجلد الخامس – العدد الثاني

يونيو 2025

رابط المجلة: <https://safq.journals.ekb.eg>

أثر تطبيق خوارزميات التعلم الآلي على التنبؤ باتجاه أسعار الأسهم: دراسة تطبيقية على الشركات المدرجة في سوق الأوراق المالية بمصر

الملخص:

غرض الدراسة: هدفت الدراسة الى تحليل أثر تطبيق خوارزميات التعلم الآلي في التنبؤ باتجاه أسعار الأسهم من خلال تطبيق هذه الخوارزميات على الشركات المدرجة بسوق الأوراق المالية المصري.

التصميم والمنهجية: اعتمدت الدراسة على استخدام المنهج الوصفي التحليلي لوصف وتحليل البيانات المالية والتنبؤ باتجاه أسعار الأسهم باستخدام خوارزميات التعلم الآلي، كما اعتمدت على المنهج التحليلي الكمي للبيانات المجمعة بهدف تحديد العلاقات والأنماط الرئيسية في البيانات، وذلك لعينة عشوائية طبقية مكونة من 10 شركات مقيدة بالبورصة المصرية خلال الفترة من عام 2019م حتى عام 2023م.

النتائج والتوصيات: أثبتت النتائج وجود أثر ذو دلالة احصائية لتطبيق خوارزميات التعلم الآلي متمثلة في (خوارزمية آلة ناقلات الدعم، خوارزمية الانحدار الخطي، خوارزمية الغابات العشوائية، خوارزمية الذاكرة الطويلة والقصيرة المدى) في تحسين دقة التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية المصرية، حيث حققت خوارزمية الذاكرة الطويلة والقصيرة المدى نتائج أكثر دقة للتنبؤ بأسعار الاسهم مقارنة بالخوارزميات الأخرى، اذ بلغ متوسط الخطأ المطلق (MAE) 0.20 وجذر متوسط الخطأ التربيعي (RMSE) 0.30، بناءً على هذه النتائج، توصي الدراسة بتطوير برامج تدريبية للمستثمرين لفهم كيفية استخدام خوارزميات التعلم الآلي في اتخاذ قراراتهم مع وضع آليات لتقييم أداء نماذج التنبؤ بانتظام لضمان فعالية الاستثمار والقيام بإعداد تقارير تفصيلية تُظهر كيفية تأثير خوارزميات التعلم الآلي على القرارات الاستثمارية.

الاصالة والاضافة: تمثل هذه الدراسة إسهاماً هاماً في فهم تأثير تطبيق خوارزميات التعلم الآلي على التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية بمصر، حيث اعتمدت الدراسة على استخدام خوارزميات التعلم الآلي المتقدمة مثل الذاكرة طويلة وقصيرة المدى وآلة ناقلات الدعم والغابات العشوائية والتي لم تستخدم بشكل موسع مما يوفر نهجاً اصيلاً وحديثاً للتنبؤ باتجاه اسعار الاسهم، كما يحدث تحولاً في اتخاذ القرارات الاستثمارية في سوق الأوراق المالية بمصر ويقلل من مخاطر تقلبات السوق.

الكلمات المفتاحية: خوارزميات التعلم الآلي- خوارزمية الانحدار الخطي- خوارزمية آلة ناقلات الدعم- خوارزمية الذاكرة طويلة وقصيرة المدى- خوارزمية الغابات العشوائية- أسعار الأسهم- سوق الأوراق المالية.

Abstract:

Purpose of the study: The study aimed to analyze the impact of applying machine learning algorithms in predicting stock price trends by applying these algorithms to companies listed on the Egyptian Stock Exchange.

Design and methodology: The study relied on a descriptive-analytical approach to describe and analyze financial data and predict stock price trends using machine learning algorithms. It also utilized a quantitative analytical approach for the collected data to identify the main relationships and patterns in the data. The sample consisted of a stratified random sample of 10 companies listed on the Egyptian Stock Exchange during the period from 2019 to 2023.

Results and recommendations: The results demonstrated a statistically significant impact of applying machine learning algorithms, including Support Vector Machine, Linear Regression, Random Forest, and Long Short-Term Memory (LSTM), in improving the accuracy of predicting stock price trends in the Egyptian Stock Market. Among these,

the Long Short-Term Memory algorithm yielded the most accurate results for predicting stock prices compared to the other algorithms, as the mean absolute error (MAE) reached 0.20 and the root mean square error (RMSE) reached 0.30. Based on these results, the study recommends developing training programs for investors to understand how to use machine learning algorithms in making investment decisions. Additionally, it suggests establishing mechanisms to regularly evaluate the performance of prediction models to ensure investment effectiveness and preparing detailed reports that demonstrate how machine learning algorithms impact investment decisions.

Originality and addition: This study provides a significant contribution to understanding the impact of applying machine learning algorithms to predict stock price trends in the Egyptian stock market. The study used advanced machine learning algorithms, such as Long Short-Term Memory, Support Vector Machine, and Random Forest, which have not been widely used, offering a novel and modern approach for predicting stock price trends. This contributes to a shift in investment decision-making in the Egyptian Stock Market and helps reduce the risks of market volatility.

Keywords: Machine Learning Algorithms, Linear Regression Algorithm, Support Vector Machine (SVM) Algorithm, Long Short-Term Memory (LSTM) Algorithm, Random Forest Algorithm, Stock Prices, Stock Market.

القسم الأول: الإطار العلمي للدراسة

أولاً: المقدمة:

أصبح التعلم الآلي (ML) أداة قوية وفعالة في تحليل مجموعات البيانات الضخمة، خاصة في مجال النمذجة التنبؤية (Miyo et.al,2025:2)، حيث تتميز خوارزميات التعلم الآلي بقدرتها على اكتشاف الأنماط والعلاقات المعقدة ضمن البيانات المالية الضخمة، مما يجعلها مثالية في التنبؤ باتجاهات الاسواق المالية (Sarker et.al,2024:383)، ولقد طور الباحثون العديد من الخوارزميات التي تساهم في التنبؤ بحركة أسعار الأسهم، مما يساعد المستثمرين في اتخاذ قرارات استثمارية مستنيرة (Prasad & Seetharaman,2021:209). يعتبر التنبؤ بأسعار الأسهم في سوق الأوراق المالية من أكثر التحديات التي يواجهها المستثمرون (Patra et.al,2024:348)، إذ يعد تحديد اتجاهات حركة الأسعار أمراً بالغ الأهمية لتوجيه المشاركين في السوق نحو اتخاذ قرارات استثمارية أفضل، في هذا السياق، تُعد خوارزميات التعلم الآلي من الأدوات الناشئة الواعدة التي يمكن أن تساهم بشكل كبير في تحسين دقة التنبؤات، نظراً لقدرتها على تحليل كميات ضخمة من البيانات واكتشاف الأنماط الخفية (Ismail et.al,2020:1) من خلال تطبيق خوارزميات التعلم الآلي، تمكن المحللون من تطوير نماذج قادرة على التنبؤ بأسعار الأسهم بشكل أكثر دقة، حيث تعتمد هذه النماذج على المعلومات التاريخية للسوق وتستخدم لتوقع الاتجاهات المستقبلية (Bhardwaj & Ansari,2019:5994)، علاوة على ذلك، فإن التعلم الآلي يمكن أن يساهم في بناء نماذج جديدة تستفيد من الأنماط والعلاقات المعقدة في البيانات المالية، مما يساهم في تقليل المخاطر وتحقيق عوائد مالية أعلى (Jejenywa et.al, 2024:1031).

يمثل سوق الأوراق المالية جزءاً حيوياً من النظام الاقتصادي، ويُعد أحد المؤشرات الأساسية على صحة الاقتصاد العام، إذ يتيح للمستثمرين والتجار فرصة زيادة ثرواتهم عبر الاستثمار في الأسهم ومع ذلك، قد يعترض المشاركون في السوق تحديات عديدة نتيجة لتقلبات السوق والمخاطر التي قد تؤثر على قيمة استثماراتهم، من هنا، تبرز أهمية التنبؤ باتجاه حركة أسعار الأسهم لتوفير توجيه استثماري فعال يساعد في اتخاذ قرارات استراتيجية محكمة، مما يساهم في التحوط ضد المخاطر السوقية وتحقيق عوائد مستقرة، يشكل التنبؤ بحركة أسعار الأسهم أحد أكبر التحديات في تحليل السلاسل الزمنية، نظراً لتقلبات سلوكيات السوق المستمرة والتي تتأثر بعدد من العوامل مثل حركة أسعار الأسهم

الأخرى، الأحداث السياسية، الظروف الاقتصادية، والسياسات الحكومية، بالإضافة إلى توقعات المستثمرين والتأثيرات الناتجة عن الكوارث أو الحروب (Ismail et.al,2020: 2).

في هذا السياق، يواصل الباحثون بحثهم عن طرق جديدة لتحسين دقة التنبؤ بأسعار الأسهم، حيث تُعد خوارزميات التعلم الآلي من الأدوات الأساسية التي تسهم بشكل كبير في هذا المجال، مما يتيح إمكانية تحقيق فوائد كبيرة في التنبؤ بحركة السوق المستقبلية (Hossen et.al, 2024:497)، من خلال هذه الأدوات المتقدمة يمكن للمستثمرين الحصول على إرشادات قيمة تساعدهم في اتخاذ قرارات استثمارية مدروسة، وبالتالي تعزيز القدرة على تحقيق عوائد مالية عالية وتقليل المخاطر المرتبطة بتقلبات السوق (Ismail et.al, 2024:2).

ثانياً مشكلة الدراسة:

يعد سوق الأوراق المالية منصة يتم من خلالها شراء وبيع الأسهم، حيث تؤدي كل معاملة بين المشتري والبائع إلى توليد بيانات معاملات تؤثر في ديناميكية أسعار الأسهم بشكل مستمر، كما يتسبب التفاعل المستمر بين تقلبات العرض والطلب على الأسهم في تغييرات مستمرة في الأسعار (Thirumalaisamy et.al,2024:546)، ولما كانت الأسواق المالية تعتمد بشكل كبير على التداول اليومي للأسهم، فمن الضروري وجود نظام قادر على اكتشاف الأنماط في أسعار الأسهم استناداً إلى التأثيرات الاقتصادية، بالإضافة إلى قياس مشاعر السوق تجاه بعض الشركات (Shastri et.al, 2019:1).

إن التنبؤ باتجاه أسعار الأسهم يُعد من الأمور الحاسمة، حيث يمكن أن يسهم التنبؤ الدقيق في تمكين المستثمرين من تحقيق الأرباح وتجنب المخاطر (Al-Amri et.al, 2024:118) على الرغم من التحديات المرتبطة بسوق الأوراق المالية، بسبب تعقيداته وتقلباته، فإنه يعد جزءاً أساسياً من استراتيجيات المستثمرين لبناء استثمارات ناجحة (Oyewole et.al,2024:655)، بتقلباته وصعوبة التنبؤ بحركته المستقبلية، يبذل الباحثون جهوداً كبيرة لدراسة بيانات السلاسل الزمنية في محاولة لتحسين دقة التنبؤات بقيم الأسهم المستقبلية (Whig et al., 2024:271).

وبالتالي، يُعتبر التنبؤ بسعر السهم إحدى المهام الرئيسية للمستثمرين (Kim et al., 2020:111660) وبناءً على ذلك، يتمثل التحدي البحثي في إيجاد نهج فعال لتوضيح وتصور التنبؤات في أسواق الأوراق المالية، مما يساعد الأفراد على اتخاذ قرارات استثمارية مدروسة تهدف إلى تحقيق أقصى قدر من الأرباح (Bhardwaj & Ansari, 2019:5994).

ففي الماضي كان التنبؤ بأسواق الأوراق المالية يعتمد بشكل رئيسي على الأساليب التقليدية التي تركز على التحليل الأساسي والفني. ومع ذلك، تطور هذا المجال بشكل كبير في العقود الأخيرة ليصبح مجالاً مهماً للبحث (Raghunathan & Krishnamoorthi, 2025:1) وقد شهدت أساليب التنبؤ بأسعار الأسهم تحولاً من الأساليب التقليدية إلى خوارزميات التعلم الآلي، التي أسهمت في تحسين دقة التنبؤات بشكل كبير (Nti et al., 2020:153) حيث تتمكن هذه الخوارزميات من استخلاص الأنماط الدقيقة من البيانات التاريخية واستغلالها للتنبؤ بحركات السوق المستقبلية (Al-Amri et.al, 2024:118).

مع تطور تقنيات التعلم الآلي، أصبح التنبؤ بأسعار الأسهم أكثر دقة وسهولة (Mintarya et al., 2023:96) ومع ذلك، يعكس تقلب أسعار الأسهم بيئة الاقتصاد العالمي المتغيرة، مما يؤثر شوكاً لدى بعض المستثمرين بشأن قدرة تقنيات التعلم الآلي الحديثة على التنبؤ بدقة، نظراً للطبيعة المعقدة للسوق وكثرة العوامل المؤثرة فيه (Chen, 2022:488) ورغم هذه التحديات، يظل التعلم الآلي أداة قوية وفعالة للتنبؤ بأسعار الأسهم (Arowoogun et.al,2024:1813).

يُعتبر استخدام خوارزميات التعلم الآلي للتنبؤ بأسعار الأسهم أمراً بالغ الأهمية، حيث تتعرض أسعار الأسهم لتقلبات شديدة نتيجة لعدد من العوامل الخارجية، لذا، يصبح التنبؤ الدقيق في هذه الحالة أمراً حيوياً لتحسين ربحية المستثمرين في سوق الأوراق المالية، وتُعد خوارزميات التعلم الآلي من الأدوات المثالية لهذه المهمة، لأنها تتمتع بقدرة على معالجة كميات ضخمة من البيانات التاريخية واكتشاف الأنماط التي قد يغفل عنها الإدراك البشري الفوري (Sharma et.al, 2024:1).

وبناءً على ذلك، تكمن المشكلة البحثية في تقييم فعالية وموثوقية نماذج التعلم الآلي في التنبؤ باتجاه أسعار الأسهم، وبالتالي يمكن استنتاج التساؤل الرئيسي التالي:

ما هو تأثير تطبيق خوارزميات التعلم الآلي على التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية بمصر؟
ويتفرع عنه التساؤلات الفرعية التالية:

1. ما هو تأثير خوارزمية الانحدار الخطي (Linear Regression(LR) في التنبؤ باتجاه اسعار الأسهم في سوق الأوراق المالية بمصر؟
2. ما هو تأثير خوارزمية الذاكرة الطويلة والقصيرة المدى (Long short-term memory (LSTM) في التنبؤ باتجاه اسعار الأسهم في سوق الأوراق المالية بمصر؟
3. ما هو تأثير خوارزمية آلة ناقلات الدعم (Support Vector Machine(SVM) في التنبؤ باتجاه اسعار الأسهم في سوق الأوراق المالية بمصر؟
4. ما هو تأثير خوارزمية الغابات العشوائية (Random Forest(RF) في التنبؤ باتجاه اسعار الأسهم في سوق الأوراق المالية بمصر؟

ثالثاً: أهداف الدراسة:

يتمثل الهدف الرئيسي للدراسة في بيان مدى تأثير تطبيق خوارزميات التعلم الآلي على التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية بمصر ويتفرع عنه الاهداف الفرعية التالية:

1. بيان مدى تأثير خوارزمية الانحدار الخطي (Linear Regression(LR) في التنبؤ باتجاه اسعار الأسهم في سوق الأوراق المالية بمصر.
2. بيان مدى تأثير خوارزمية الذاكرة الطويلة والقصيرة المدى (Long short-term memory (LSTM) في التنبؤ باتجاه اسعار الأسهم في سوق الأوراق المالية بمصر.
3. بيان مدى تأثير خوارزمية آلة ناقلات الدعم (Support Vector Machine(SVM) في التنبؤ باتجاه اسعار الأسهم في سوق الأوراق المالية بمصر.
4. بيان مدى تأثير خوارزمية الغابات العشوائية (Random Forest(RF) في التنبؤ باتجاه اسعار الأسهم في سوق الأوراق المالية بمصر.

رابعاً: أهمية الدراسة:

1- الأهمية العلمية:

- أ. تقدم الدراسة مساهمة علمية متميزة عبر تحليل أثر خوارزميات التعلم الآلي المتقدمة مثل LSTM، SVM، Random Forest في التنبؤ باتجاه أسعار الأسهم، هذا الإثراء يساهم في سد الفجوة البحثية المتعلقة بقلة الدراسات التي تتناول خوارزميات التعلم الآلي في الأسواق الناشئة مثل السوق المصري.
- ب. تقدم الدراسة نموذجاً متكاملًا يجمع بين التحليل الفني، التحليل الأساسي، واستخدام خوارزميات التعلم الآلي، مما يُعزز من كفاءة النماذج التنبؤية، ويوفر مرجعاً علمياً للباحثين لتطوير أدوات تنبؤ أكثر دقة ومرونة.
- ج. ان معظم الأبحاث في هذا المجال ركزت على الأسواق المالية المتقدمة، مثل أسواق الولايات المتحدة و أوروبا، لذا فإن تطبيق خوارزميات التعلم الآلي على سوق الأوراق المالية المصري مما يفتح المجال لإجراء المزيد من الأبحاث التي تستكشف كفاءة هذه الأدوات في أسواق مشابهة من حيث التقلبات والعوامل المؤثرة، كما يُمكن من تقديم رؤى جديدة حول كيفية التنبؤ باتجاه اسعار الاسهم وتحسين إدارة المخاطر.

2- الأهمية العملية :

- أ. توفر الدراسة نماذج دقيقة للتنبؤ باتجاه أسعار الأسهم، مما يساعد المستثمرين على فهم توجهات السوق واتخاذ قرارات استثمارية مدروسة، وبالتالي تقليل المخاطر وتعظيم العوائد.
- ب. تطبيق الخوارزميات التنبؤية بشكل فعال يمكن أن يساهم في تحسين استقرار السوق المصري من خلال توفير توقعات دقيقة تقلل من تقلبات الأسعار المفاجئة الناتجة عن قرارات غير مدروسة، مما يساهم في تحسين فعالية الاستراتيجيات الاستثمارية ويعزز من كفاءة عمليات التداول.

ج. قد تساعد نتائج الدراسة الحالية الجهات التنظيمية وصناع السياسات في فهم ديناميكيات السوق المصري بشكل أفضل، وتوفير رؤية واضحة عن القطاعات الواعدة في السوق المصري، مما يشجع الشركات والمؤسسات المالية على توجيه استثماراتها نحو هذه القطاعات، وبالتالي تحقيق نمو اقتصادي مستدام.

القسم الثاني: الدراسات السابقة

أولاً: الدراسات المتعلقة بأثر استخدام خوارزمية الانحدار الخطي في التنبؤ باتجاه أسعار الاسهم:
هدفت دراسة (Emioma & Edeki (2021) إلى التنبؤ بسعر الإغلاق المستقبلي لسهم بنك أمريكا باستخدام خوارزمية الانحدار الخطي من خلال تقسيم البيانات إلى مجموعات تدريب، ومن ثم حساب الأخطاء باستخدام معايير مثل معدل الخطأ المتوسط المطلق (MAPE) وجذر متوسط الخطأ التربيعي (RMSE) وتوصلت الدراسة إلى أن النموذج الذي تم تطويره نجح في التنبؤ بأسعار الإغلاق بدقة عالية، حيث حقق معدل خطأ مطلق متوسط قدره 1.367% وجذر متوسط الخطأ التربيعي 0.512، وهذا يشير إلى قدرة النموذج على التنبؤ بشكل جيد بالأداء المستقبلي لسهم بنك أمريكا بناءً على البيانات التاريخية، وأوصت الدراسة باستخدام النموذج للتنبؤات المستقبل في نطاق زمني يومي، مع تحديث مستمر للبيانات لضمان أعلى دقة في التنبؤات، كما أوصت الدراسة بإمكانية تعديل النموذج لاستخدامه في أسواق أسهم أخرى في دول مختلفة.

كما بحثت دراسة (Halawa & Hermawan(2022) أهمية إنشاء نموذج لتحليل البيانات باستخدام خوارزمية الانحدار الخطي، قادر على التنبؤ بأسعار إغلاق الأسهم اليومية، وذلك لتقديم المعلومات التي تدعم المستثمرين في اتخاذ قراراتهم بشأن معاملات الأسهم، حيث تم استخدام بيانات تاريخية لأسعار الأسهم اليومية لـ 10 شركات على مدار 8 سنوات (من 25 فبراير 2013 إلى 25 فبراير 2021)، وتم تطبيق طريقة المتوسط المتحرك لتحضير البيانات بهدف تطوير نموذج لتحليل البيانات باستخدام الانحدار الخطي لتوليد تنبؤات دقيقة بأسعار الأسهم، وتوصلت الدراسة إلى أن النموذج المطور يمكن أن يكون أداة فعالة في مساعدة المستثمرين على اتخاذ قرارات شراء أو بيع الأسهم، من خلال تحليل التنبؤات، تم تحديد فترات صعود الأسعار كفرص شراء وفترات هبوط الأسعار كفرص بيع، كما أظهرت نتائج التقييم باستخدام مؤشر RMSE (0.898) وقيمة الارتباط (0.612) أن النموذج يقدم توقعات موثوقة يمكن أن تساعد المستثمرين في اتخاذ قرارات استثمارية مدروسة، وأوصت الدراسة باستخدام النموذج للتنبؤ بأسعار الأسهم المستقبلية، وتطبيقه كأداة لتوجيه المستثمرين في اتخاذ قرارات شراء أو بيع الأسهم استناداً إلى الاتجاهات المستقبلية للأسعار، كما أوصت الدراسة بتقييم النتائج بشكل دوري باستخدام مؤشرات الأداء مثل RMSE لتحديث النموذج وضمان دقته، وأشارت إلى أهمية توسيع التطبيق ليشمل أسواق أسهم أخرى في المستقبل لتعزيز فاعلية النموذج في مختلف الأسواق.

وسعت دراسة (Eka et.al(2024) إلى بيان أثر استخدام خوارزمية الانحدار الخطي في التنبؤ بأسعار الأسهم المستقبلية لأفضل 10 جهات إصدار في مؤشر LQ45، تم اختيار هذه الشركات بناءً على استقرارها وسمعتها الجيدة في السوق، حيث تمثل شركات مستقرة وذلك خلال الفترة من عام 2010 إلى 2023، تم تطبيق الانحدار الخطي لفهم العلاقات بين المتغيرات المستقلة (مثل بيانات السوق التاريخية) والمتغيرات التابعة (أسعار الأسهم) بغرض التنبؤ بالقيم المستقبلية، توصلت الدراسة إلى أن الانحدار الخطي أظهر فعالية في التنبؤ بأسعار الأسهم في سوق الأوراق المالية الإندونيسية، حيث يساعد على اكتشاف العلاقات الخطية بين المتغيرات وتوفير نتائج قابلة للقياس، كما تم استخدام معايير دقيقة مثل خطأ الجذر التربيعي المتوسط (RMSE) لتقييم دقة النموذج، وأظهرت النتائج أن التنبؤات باستخدام الانحدار الخطي كانت دقيقة للغاية، مما يمكن المستثمرين من اتخاذ قرارات استثمارية مدروسة في السوق، وأوصت الدراسة باستخدام الانحدار الخطي كأداة فعالة لتنبؤ أسعار الأسهم في أسواق رأس المال، خاصة للمستثمرين الذين ليس لديهم خبرة في التحليل الأساسي، كما أوصت بتطبيقه على مجموعة واسعة من الشركات المدرجة في مؤشرات أخرى في أسواق مالية مختلفة، كما أوصت الدراسة بضرورة تحديث البيانات بانتظام لضمان دقة التنبؤات، مشيرة إلى أن هذا النموذج يمكن أن يساهم في تحسين القرارات الاستثمارية من خلال توجيه المستثمرين نحو الأسهم التي من المتوقع أن تحقق أداءً جيدًا في المستقبل.

كما قارنت دراسة Purnama et.al(2023) خوارزميات الانحدار الخطي (LR) وآلة ناقلات الدعم (SVM) في التنبؤ بأسعار الأسهم لشركة PT. Vale Indonesia ، بهدف تحديد الخوارزمية الأفضل من حيث دقة التنبؤ لمساعدة المستثمرين في اتخاذ قرارات استثمارية، و توصلت الدراسة إلى أن خوارزمية الانحدار الخطي (LR) أفضل من خوارزمية آلة ناقلات الدعم (SVM) في التنبؤ بأسعار الأسهم للشركة المبحوثة، حيث حقق نموذج الانحدار الخطي (LR) دقة جيدة في التنبؤ، حيث تم تقسيم البيانات إلى 90% بيانات تدريب و 10% بيانات اختبار، مما أسفر عن جذر متوسط مربعات الخطأ (RMSE) قدره 42.82، كما حصل نموذج آلة ناقلات الدعم (SVM) حصل على RMSE قدره 64.32، مما يعني أن النموذج ليس جيداً في التنبؤ بسبب عدم اقتراب النتائج من الصفر، واوصت الدراسة باستخدام خوارزمية الانحدار الخطي (LR) باعتبارها الأنسب للتنبؤ بأسعار الأسهم في الشركة المبحوثة نظراً لدقتها، كما اوصت بإجراء المزيد من الأبحاث لاختبار خوارزميات أخرى وتحسين النماذج الحالية بهدف زيادة دقة التنبؤ في أسواق الأسهم.

ثانياً: الدراسات المتعلقة بأثر استخدام خوارزمية آلة ناقلات الدعم في التنبؤ باتجاه اسعار الاسهم:

اتجهت دراسة Ayyildiz & Iskenderoglu (2024) إلى مقارنة أداء الخوارزميات من خلال التنبؤ باتجاهات حركة مؤشرات أسواق الأسهم في البلدان المتقدمة من خلال استخدام خوارزميات التعلم الآلي (MLMs) وتحديد أفضل خوارزمية التقدير، حيث تم تحديد اتجاهات حركة المؤشرات مثل NYSE 100 (الولايات المتحدة الأمريكية)، NIKKEI 225 (اليابان)، FTSE 100 (المملكة المتحدة)، CAC 40 (فرنسا)، DAX 30 (ألمانيا)، FTSE MIB (إيطاليا)، و TSX (كندا) تم تقديرها من خلال استخدام شجرة القرار، والجار الأقرب KNN، والغابات العشوائية، وخوارزمية Naive Bayes، والانحدار اللوجستي، وآلة ناقلات الدعم، وخوارزميات الشبكة العصبية الاصطناعية، وتوصلت النتائج إلى أن الشبكات العصبية الاصطناعية هي أفضل خوارزمية لمؤشرات NYSE 100 و FTSE 100 و DAX 30 و FTSE MIB، في حين تم تحديد الانحدار اللوجستي ليكون أفضل خوارزمية لمؤشرات NIKKEI 225 و CAC 40 و مؤشرات TSX تم تحديد الشبكات العصبية الاصطناعية، التي أظهرت أعلى متوسط أداء تنبؤي، كأفضل خوارزمية تنبؤ لمؤشرات أسواق الأسهم في البلدان المتقدمة، ولوحظ أيضاً أن الشبكات العصبية الاصطناعية والانحدار اللوجستي وخوارزميات آلة ناقلات الدعم كانت قادرة على التنبؤ باتجاه الحركة لجميع المؤشرات بمعدل دقة يزيد عن 70%.

كما استهدفت دراسة Jakhar et.al(2024) التنبؤ بالسعر المرتفع لسهم TCS على أساس يومي تتضمن هذه الدراسة استخدام بيانات تاريخية قائمة على الوقت لمدة 15 عاماً، من عام 2009 إلى عام 2023 (12 عاماً من البيانات لأغراض التدريب و 3 سنوات من البيانات لأغراض الاختبار مصنفة بشكل كبير)، تم التنبؤ بأسعار مرتفعة على أساس يومي بشكل كبير باستخدام أسعار الافتتاح والأسعار المنخفضة وأسعار الإغلاق، تتضمن هذه الدراسة استخدام الانحدار الخطي المتعدد MLR وآلة ناقلات الدعم (SVM) للوصول إلى دقة النتائج من نماذج مختلفة، تم أيضاً حساب متوسط الخطأ المطلق (MAE) وجذر متوسط الخطأ التربيعي (RMSE) وتوصلت الدراسة إلى أن نموذج الانحدار الخطي المتعدد (MLR) أظهر نتائج أكثر دقة للتنبؤ بالأسعار المرتفعة على مدار اليوم مقارنة بالخوارزميات الأخرى، كما توصلت إلى أن متوسط الخطأ المطلق (MAE) وجذر متوسط الخطأ التربيعي (RMSE) لـ MLR 11.57 و 14.69 على التوالي، وهو الأقل من بين جميع الخوارزميات، ولذلك فإن أدوات الانحدار التقليدية ليست فعالة مثل خوارزميات التعلم الآلي لأنها توفر نتائج أكثر دقة وتحديدًا لخدمة مصالح المستثمرين.

وسعت دراسة Nurrimah & Rustam(2020) إلى اقتراح طريقة للتنبؤ باتجاهات أسعار الأسهم باستخدام خوارزمية آلة ناقلات الدعم (SVM) مع اختيار الخصائص باستخدام مقياس فيشر (Fisher Score)، وذلك لتحسين دقة التنبؤ من خلال اختيار مجموعة الخصائص الأكثر تأثيراً في التنبؤ، وتوصلت الدراسة إلى أن استخدام خوارزمية SVM مع مقياس فيشر (Fisher Score) كطريقة لاختيار الخصائص كان فعالاً في التنبؤ باتجاهات أسعار الأسهم، حيث كان أفضل نموذج تم الحصول عليه كان باستخدام بيانات PT Bank Mandiri (Persero) Tbk حيث تم استخدام 11 من أصل 15 مؤشراً فنياً و 70% من بيانات التدريب، مع $\sigma = 0.01$ ، مما أدى إلى دقة تنبؤ بلغت 99.66%، أن النموذج أظهر نتائج عالية الأداء، حيث كانت دقة التنبؤ لجميع بيانات الأسهم المدروسة أكثر من 95%، مما يدل على فعالية النموذج في التنبؤ باتجاهات الأسعار، وأوصت الدراسة باستخدام خوارزمية SVM مع

مقياس فيشر كأداة قوية للتنبؤ باتجاهات أسعار الأسهم، خصوصاً في الأسواق ذات الأنظمة غير الخطية والصعبة، كما أوصت الدراسة المستثمرين باتباع تلك الطريقة لتوقع تحركات الأسعار في الأسواق المالية، مما يساعد في تقليل مخاطر الخسائر وتحقيق استراتيجيات استثمارية أكثر دقة.

ثالثاً: الدراسات المتعلقة بأثر استخدام خوارزمية الذاكرة طويلة – قصيرة المدى (LSTM)، في التنبؤ باتجاه اسعار الاسهم:

هدفت (Elsegai et.al(2025) إلى التنبؤ بحركات أسعار أسهم لشركات مختارة في قطاع العقارات المدرجة في البورصة المصرية خلال الفترة من 2013 إلى 2022. استخدمت الدراسة مجموعة من خوارزميات التعلم الآلي مثل الغابة العشوائية (RF)، التعزيز التكراري (AdaBoost)، آلة ناقلات الدعم (SVM)، أقرب جيران (KNN) بالإضافة إلى تقنيات التعلم العميق مثل الشبكات العصبية الاصطناعية (ANNs)، الشبكات العصبية المتكررة (RNNs)، وشبكات الذاكرة طويلة المدى (LSTM) بهدف تقييم ومقارنة أداء هذه الأساليب من حيث الدقة التنبؤية وتقليل عدم اليقين المرتبط بتوقعات سوق الأوراق المالية، وتوصلت الدراسة إلى أن خوارزمية التعزيز التكراري (AdaBoost) حققت أعلى دقة بين خوارزميات التعلم الآلي المستخدمة، حيث بلغت دقة التنبؤ 99.5%. أما بالنسبة لنماذج التعلم العميق، فقد أظهرت شبكات الذاكرة طويلة المدى (LSTM) قدرة تنبؤية متفوقة، محققة أدنى معدل خطأ، تليها الشبكات العصبية المتكررة (RNN) بمعدل خطأ قدره 0.3%، تشير هذه النتائج إلى فعالية تقنيات التعلم الآلي المتقدمة ونماذج التعلم العميق في التنبؤ بأسعار الأسهم، مما يساهم في تعزيز عمليات اتخاذ القرارات في الأسواق المالية، وأوصت الدراسة بدمج منهجيات التعلم الآلي المتقدمة ونماذج التعلم العميق في عمليات تحليل التنبؤ بأسعار الأسهم لتقليل المخاطر وتعزيز قرارات الاستثمار، كما أوصت بضرورة تبني هذه الأدوات من قبل المستثمرين لتحسين نتائج استثماراتهم وتقليل المخاطر المرتبطة بتقلبات الأسواق المالية.

كما بحثت دراسة (Phuoc et.al (2024) التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية في الاقتصادات الناشئة. باستخدام خوارزمية الذاكرة طويلة – قصيرة المدى (LSTM)، ومؤشرات التحليل الفني المقابلة لكل رمز سهم تشمل: المتوسط المتحرك البسيط (SMA)، والمتوسط المتحرك للتقارب والتباعد (MACD)، ومؤشر القوة النسبية (RSI)؛ والبيانات الثانوية من أسهم VN-Index و VN-30، أظهرت نتائج البحث أن نموذج التنبؤ يتمتع بدقة عالية تصل إلى 93% لمعظم بيانات المخزون المستخدمة، مما يدل على ملائمة نموذج LSTM وبيانات مجموعة الاختبار، تستخدم لتقييم أداء النموذج. وأظهرت نتائج البحث أن نموذج التنبؤ يتمتع بدقة عالية تصل إلى 93% لمعظم بيانات الأسهم المستخدمة، مما يدل على مدى ملائمة نموذج LSTM في تحليل والتنبؤ بتحركات أسعار الأسهم على منصة التعلم الآلي.

كما اتجهت دراسة (Bansal & Choudhary(2022) إلى مناقشة خمس من الخوارزميات وهي K-Nearest Neighbors، والانحدار الخطي (LR)، وآلة ناقلات الدعم (SVM)، وانحدار شجرة القرار، والذاكرة الطويلة والقصيرة المدى (LSTM) في التنبؤ بأسعار أسهم 12 شركة رائدة في سوق الأوراق المالية الهندية، و بعد بحث شامل للجوانب المختلفة المتعلقة بتطبيق التعلم الآلي في سوق الأوراق المالية، تم جمع واستخدام مجموعة بيانات أسعار الأسهم لـ 12 شركة على مدى السنوات السبع الماضية، تم إجراء تحليل مقارنة مفصل لأداء الخوارزميات المذكورة أعلاه للتنبؤ بأسعار الأسهم مع عرض النتائج في شكل جدولي ورسومي واضح لتحليلها بشكل أفضل، وتوصلت الدراسة إلى أن خوارزمية التعلم الآلي تتفوق على جميع الخوارزميات الأخرى للتنبؤ بأسعار الأسهم وتوفر نتائج دقيقة.

رابعاً: الدراسات المتعلقة بأثر استخدام خوارزمية الغابات العشوائية (RF) في التنبؤ باتجاه اسعار الاسهم:

سعت دراسة (Dimingo et.al(2021) إلى التنبؤ باتجاه السوق في سوقيين متقدمين (الولايات المتحدة الأمريكية والمملكة المتحدة) وسوقيين ناشئين (جنوب إفريقيا والبرازيل) باستخدام خمس تقنيات للتعلم الآلي، وهي آلة ناقلات الدعم (SVM)، وأشجار القرار (DTs)، والغابات العشوائية (RF)، والجار الأقرب، وتحليل التمييز الخطي (LDA)، كما استخدمت خوارزمية LDA كمعيار لأنها الخوارزمية الوحيدة التي ترتبط ارتباطاً وثيقاً بنموذج الانحدار اللوجستي، وتوصلت النتائج إلى أن الغابات العشوائية (RF) هي أفضل نموذج للتنبؤ باتجاه السوق لجميع

الأسواق، المتقدمة أو الناشئة، و أن أسواق الأسهم في كل من الأسواق المتقدمة والناشئة يتم تحديدها من خلال سعر اليوم السابق وعائد توزيعات الأسهم .

كما استهدفت دراسة (Meher et.al (2024) تقييم فعالية نموذج الغابة العشوائية (Random Forest) في التنبؤ بأسعار أسهم أكبر أربع شركات للطاقة الشمسية في الهند، بناءً على القيمة السوقية، وذلك باستخدام البيانات اليومية لأسعار الأسهم الافتتاحية والعليا والمنخفضة والإغلاق خلال الفترة من 1 أكتوبر 2019 إلى 30 سبتمبر 2023، تم اختبار قدرة النموذج في التنبؤ بأسعار أسهم هذه الشركات وتحليل دقته، وتوصلت الدراسة إلى أن نموذج الغابة العشوائية أظهر قدرة عالية على التنبؤ بأسعار الأسهم، حيث كانت قيم معامل التحديد (R^2) لجميع الشركات تتراوح بين 0.9928 و 0.9939، مما يعكس قدرة النموذج على تفسير معظم التباين في الأسعار، ومع ذلك تم ملاحظة أن شركة Adani Green Energy Ltd شهدت قيم MSE و RMSE أعلى بشكل ملحوظ، مما يشير إلى تقلب أكبر في دقة التنبؤ مقارنة بالشركات الأخرى ، وفي المقابل أظهرت الشركات الأخرى قيماً منخفضة لمؤشر MAE، مما يعكس تنبؤات دقيقة نسبياً، وأوصت الدراسة بتحسين وتطوير نموذج الغابة العشوائية بشكل مستمر ليأخذ في الاعتبار العوامل غير المتوقعة التي قد تؤثر على أسعار الأسهم، مثل التغيرات الاقتصادية الكلية، كما أوصت بمتابعة وتعديل النموذج بشكل دوري لضمان استمرارية فعاليته في التنبؤ بأسعار أسهم شركات الطاقة الشمسية في الهند، وأنه يمكن للباحثين المستقبليين إدخال عوامل اقتصادية إضافية لتعزيز دقة النماذج وتحسين قدرتها على التنبؤ.

وبحثت دراسة (Humairah & Agustina (2024) التنبؤ بأسعار الأسهم في مؤشر جاكارتا الإسلامي JII باستخدام خوارزمية الغابة العشوائية (RF) وتوصلت الدراسة إلى أن تطبيق خوارزمية الغابات العشوائية RF في التنبؤ بأسعار الأسهم قد أظهر نتائج جيدة جداً، حيث كانت قيم متوسط الخطأ المطلق النسبي (MAPE) في نطاق 0% - 10%، مع تحقيق دقة عالية بلغت 97.48% لأسهم ACES ، 98.77% لأسهم ICBP ، و 99.24% لأسهم INDF، أوصت الدراسة بتطوير أبحاث مستقبلية من خلال إضافة ميزات أكثر شمولاً، بما في ذلك العوامل الخارجية التي قد تؤثر على تحركات أسعار الأسهم.

بناءً على الدراسات السابقة يمكن ملاحظة أوجه التشابه والاختلاف بين الدراسات السابقة والدراسة الحالية ومن ثم التعرف على الفجوة البحثية وذلك على النحو التالي:

أوجه التشابه:

1. معظم الدراسات السابقة تتفق على أن خوارزميات التعلم الآلي مثل IR و LSTM و SVM و Random Forest تقدم أدوات قوية لتحليل البيانات الضخمة والتنبؤ باتجاه أسعار الأسهم هذا الاتفاق يعكس التحول العام في الأبحاث نحو تبني التقنيات الحديثة بدلاً من الأساليب التقليدية كالتحليل الفني والأساسي.
2. استخدمت الدراسة الحالية نماذج متطورة مثل الانحدار الخطي ، والذاكرة الطويلة والقصيرة المدى وآلة ناقلات الدعم، والغابات العشوائية، وهو ما يتوافق مع معظم الدراسات السابقة إذ انها استخدمت مجموعة من الخوارزميات في التنبؤ بأسعار الاسهم مما يبرز كفاءة هذه الخوارزميات في تحسين دقة التنبؤات مقارنة بالأساليب التقليدية.
3. ركزت معظم الدراسات السابقة والدراسة الحالية على البيانات التاريخية لأسعار الأسهم والمعلومات الفنية مثل المؤشرات الفنية، لتحسين التنبؤات، وهذا يشير إلى إجماع الباحثين على أن الماضي يمثل مفتاحاً لفهم وتحليل الأنماط المستقبلية كما يشير الى اتفاق واسع النطاق في أن الدمج بين التحليل الفني والخوارزميات المتقدمة يعمل على تعزيز الثقة في التنبؤ ، مما يمكن المستثمرين من اتخاذ قرارات مستنيرة.
4. تتفق معظم الدراسات على ان مساعدة المستثمرين على اتخاذ قرارات استثمارية مدروسة يقلل من المخاطر ويعظم من العوائد، مما يعكس الأهمية العملية لهذه الدراسات في السياق المالي.

أوجه الاختلاف:

1. اختلفت الخوارزميات المستخدمة في الدراسات السابقة، حيث تركز بعضها على الانحدار الخطي، بينما استخدمت أخرى خوارزميات مثل الغابات العشوائية أو KNN، مما يعكس تنوع المنهج التحليلي، بينما الدراسة الحالية استخدمت عدة خوارزميات متمثلة في الانحدار الخطي والذاكرة طويلة وقصيرة المدى وآلة ناقلات الدعم و الغابات العشوائية.

2. شملت الدراسات السابقة أسواقاً مالية متنوعة، حيث تركز بعضها على الأسواق المتقدمة مثل دراسة Ayyildiz (2024) & Iskenderoglu التي تناولت مؤشرات في الولايات المتحدة وأوروبا، في المقابل ركزت دراسة Nurrimah & Rustam (2020) على السوق الإندونيسي، بينما ركزت دراسة Dimingo et al. (2021) على الأسواق الأمريكية والبرازيلية، وتسلط الدراسة الحالية الضوء على تطبيق الخوارزميات في سوق ناشئ مثل السوق المصري، مما يظهر اختلافاً في السياق الاقتصادي.
3. بعض الدراسات السابقة أخذت في الاعتبار التحليل الأساسي بما يتضمن العوامل الاقتصادية والسياسية والاجتماعية التي قد تؤثر على حركة الأسعار، بينما ركزت بعض الدراسات السابقة على التحليل الفني فقط مثل دراسة Jakhar et al. (2024)، مما يبرز اختلاف المنهجيات.
4. تم التركيز في الدراسة الحالية على عشر شركات متنوعة عبر قطاعات اقتصادية متعددة، وهو ما يعكس مقارنة تحليلية شاملة تأخذ في الاعتبار تباين العوامل الاقتصادية التي قد تؤثر على حركة أسعار الأسهم، بينما معظم الدراسات السابقة ركزت على نوع معين من الشركات أو القطاع، مما يحد من تعميم نتائجها عبر أسواق أو قطاعات اقتصادية متنوعة.

الفجوة البحثية:

على الرغم من التقدم الكبير في تطبيق خوارزميات التعلم الآلي في التنبؤ بأسعار الاسهم، فإن هناك فجوة بحثية بارزة وهي:

1. ندرة الدراسات التي تتناول تأثير هذه الخوارزميات بشكل خاص في سياق سوق الأوراق المالية المصري وهذا ما حدا بالباحثة لاستكشاف كيفية تكيف خوارزميات التعلم الآلي مع الخصائص الفريدة للسوق المصري، مما يساهم في تعزيز دقة التنبؤات وفهم المستثمرين لتوجهات السوق بشكل أفضل.
2. تتناول الدراسة الحالية قطاعات متعددة داخل الاقتصاد المصري، مما يمثل فرصة بحثية قيمة لتعزيز دقة التنبؤ عبر مجموعة متنوعة من الشركات في قطاعات مختلفة.
3. تستخدم الدراسة مزيجاً من الخوارزميات مثل الانحدار الخطي LR، آلة ناقلات الدعم SVM، الذاكرة الطويلة والقصيرة المدى LSTM، و الغابات العشوائية RF، مما يوفر تحليلاً شاملاً لفعالية هذه النماذج في سياق السوق المصري هذه المقاربة تجمع بين دقة النماذج وتنوعها لتناسب مختلف السيناريوهات الاقتصادية، مما يؤدي لتطوير نماذج أكثر فعالية تتناسب مع التحديات المحلية، وتفتح آفاقاً جديدة أمام المستثمرين وصناع القرار في السوق المصري.

القسم الثالث: الإطار النظري للدراسة

أولاً: ماهية التعلم الآلي:

في عام 1990، بدأت الطرق المعتمدة على البيانات تتراجع لصالح تقنيات التعلم الآلي، مع تحول التركيز تجاه البحث في معالجة اللغة الطبيعية واسترجاع المعلومات، كما تم اختبار الشبكات العصبية لأول مرة في عام 1957م باستخدام أول أجهزة كمبيوتر تعتمد على هذه التقنية، ثم عادت للظهور مجدداً في عام 2005م، ويُعد التعلم الآلي من التقنيات التي حققت نجاحات كبرى، ورغم بعض التحديات التي واجهتها، إلا أن هناك توقعات كبرى بانتشارها بشكل موسع في المستقبل القريب (خلال 2 إلى 5 سنوات)، وللتكيف مع هذا النمو في مجال التعلم الآلي، من الضروري تعزيز العوامل المؤثرة فيه، مثل تحسين البنية التحتية وزيادة القدرات التقنية (Bharadiya,2023:26).

يُعد التعلم الآلي في جوهره "علم تشغيل أجهزة الكمبيوتر دون الحاجة إلى برمجتها بشكل صريح" (Zhang et al.,2020:110462). تستطيع أنظمة تعلم الآلي التعرف على الأنماط داخل مجموعات البيانات الضخمة وتطوير نماذج إحصائية تُعزز من قدرتها على تقديم تنبؤات دقيقة وقابلة للتكرار بشأن الأحداث المستقبلية (Ucoglu, 2020: 2)، تُستخدم ثلاثة أساليب رئيسية لتدريب نماذج تعلم الآلي، وهي: الأمثلة المصنفة (التعلم الخاضع للإشراف)، وهياكل البيانات المتأصلة (التعلم غير الخاضع للإشراف)، والتغذية الراجعة عن طريق التجربة والخطأ (CPA (Canada & AICPA, 2019, 10-11)، وبغض النظر عن التقنية المتبعة، تعتمد جميع أنظمة تعلم الآلة على نماذج إحصائية لاستخلاص رؤى من مجموعات البيانات الكبيرة بهدف التنبؤ بالنتائج المستقبلية. ولكن القدرة التنبؤية

الفعالة لنموذج التعلم الآلي لا تعتمد فقط على البيانات الأساسية النظيفة والدقيقة، بل أيضاً على جودة خوارزميات الذكاء الاصطناعي المستخدمة، تعمل الخوارزميات على الإجابة عن الأسئلة وحل المشكلات باستخدام بيانات جديدة، والتي قد تشمل نماذج الانحدار أو التحليل التصنيفي، وهذا يعزز من أهمية فهم تقنيات تعلم الآلة لتقييم نتائج الذكاء الاصطناعي واكتشاف التحيزات المحتملة، تعتبر أنظمة التعلم العميق والشبكات العصبية الاصطناعية من أبرز الأمثلة على أنظمة تعلم الآلة المعقدة (Mitan, 2024:5).

يشير التعلم الآلي إلى دراسة الخوارزميات والنماذج الإحصائية التي تمكن أجهزة الكمبيوتر من التعلم من البيانات وأداء المهام دون الحاجة إلى تعليمات مفصلة، يُعد التعلم الآلي أحد فروع الذكاء الاصطناعي، حيث يعتمد بشكل أساسي على البيانات المستخدمة في عملية التدريب بدلاً من الاعتماد على القواعد البرمجية التقليدية (Emioma & Edeki, 2021:1)، يتضمن التعلم الآلي تدريب الأنظمة لتكون قادرة على أداء مهام معينة بشكل تلقائي، باستخدام كميات ضخمة من البيانات، من خلال هذه العملية يمكن للآلة أن تطور "قدرات عقلية" خاصة بها، مما يمكنها من معالجة البيانات التي لم تواجهها من قبل، يُعتبر التعلم العميق والتحليلات التنبؤية من أبرز أمثلة التعلم الآلي، حيث تقوم خوارزميات التعلم العميق باستخراج تمثيلات معقدة وعالية المستوى للبيانات من خلال عملية تعلم هرمية. يتم ذلك عبر تدريب الخوارزميات على كميات هائلة من البيانات، مما يمكنها من "تعلم" الأنماط، وبالتالي تحسين القدرة على تحليل واستخراج البيانات (Yebi & Cudjoe, 2022:12).

يسمح التعلم الآلي للأنظمة بالتعلم وتحسين أدائها تلقائياً من خلال التجربة، دون الحاجة إلى برمجة محددة، يعتمد ذلك على استخدام خوارزميات حسابية قادرة على التعلم من مجموعة متنوعة من البيانات المتاحة، بهدف التعرف على الأنماط الموجودة فيها، وبذلك يكتسب النظام القدرة على اتخاذ القرارات وتقديم التوصيات بشكل تلقائي (Pinuji, 2024:672)، كما يُسهّم التعلم الآلي في أتمتة المهام الروتينية مثل تصنيف المعاملات، والتنبؤات، والتعرف على الأنماط في البيانات، مما يتيح اتخاذ القرارات بأقل قدر من التدخل البشري. هذا يُحسن الكفاءة في معالجة البيانات المالية. ومن خلال خوارزميات التعلم الآلي التي تستمر في التعلم من البيانات، يمكن لأنظمة المعلومات المحاسبية أن تصبح أكثر تقدماً في معالجة التحديات المحاسبية المعقدة. يعد التعلم الآلي جزءاً من الذكاء الاصطناعي ويسهم بشكل إيجابي في تميز نظم المعلومات المحاسبية من خلال تعزيز كفاءة هذه الأنظمة (Pinuji, 2024:673).

يسهم التعلم الآلي (ML) بشكل كبير في التحليل المالي، حيث يساعد المحاسبين في الاستفادة من تقنيات الذكاء الاصطناعي لتوليد رؤى مستندة إلى البيانات، مما يعزز عملية اتخاذ القرارات ويطور القدرات التحليلية للمتخصصين في المجال المالي في ظل التحديات التي تفرضها كميات البيانات المالية الكبيرة والمعقدة في بيئة الأعمال المعاصرة، تصبح الحاجة إلى أدوات تحليلية متقدمة أمراً بالغ الأهمية، ويتميز التعلم الآلي في هذا السياق بقدرته على معالجة كميات ضخمة من البيانات واكتشاف الأنماط المعقدة التي قد تكون غير واضحة أو يصعب اكتشافها باستخدام التحليل البشري التقليدي، من خلال خوارزميات مثل التجميع والتصنيف، يمكن التعرف على الارتباطات والاتجاهات المخفية في البيانات المالية، مثل تحديد أنماط الإنفاق الاستهلاكي أو تقلبات السوق أو الكفاءات التشغيلية، وهذا لا يعزز دقة التحليل المالي فحسب، بل يوفر أيضاً فهماً أعمق للعوامل المؤثرة في الأداء المالي، مع قدرة الخوارزميات على التكيف والتطور استجابة للبيانات الجديدة التي يتم جمعها (Jejenywa et al, 2024:1035).

يشير التعلم الآلي (ML) إلى استخدام الخوارزميات المتقدمة والنماذج الإحصائية التي تمكن الأنظمة من التعلم من البيانات وتحسين أدائها بمرور الوقت دون الحاجة إلى برمجة محددة، ففي مجال المراجعة المالية، يسهم التعلم الآلي في تحليل كميات ضخمة من البيانات المالية واكتشاف الأنماط والاتجاهات التي تساعد في تحديد المخاطر المحتملة والحالات الشاذة، كما يمكن تدريب الخوارزميات لاكتشاف الأنشطة الاحتيالية، مما يعزز قدرة المراجعين على تحديد المخالفات والحد من المخاطر، يعتمد التعلم الآلي أيضاً على البيانات التاريخية للتنبؤ بالاتجاهات المستقبلية، مما يسمح بتخصيص الموارد بشكل أكثر فعالية ويعزز المراقبة المستمرة للبيانات المالية في الوقت الفعلي، هذا النهج الاستباقي يمكن المراجعين من اكتشاف المشكلات ومعالجتها فوراً، مما يعزز فعالية عملية المراجعة ويؤدي إلى نتائج أكثر دقة وقوة في تقييم المخاطر والأنشطة المالية (Oluwagbade et.al, 2024:34).

ومما سبق ترى الباحثة أن استخدام خوارزميات التعلم الآلي في الأسواق المالية يمثل ثورة حقيقية في تحليل البيانات الضخمة، حيث يمكن تقديم تنبؤات دقيقة بشأن الاتجاهات المستقبلية وتحليل المخاطر المالية بشكل استباقي، فإن تطور هذا المجال يبشر بمستقبل واعد، مما يجعل التعلم الآلي جزءاً أساسياً من استراتيجيات التحليل المالي الحديثة.

ثانياً: التنبؤ باتجاه أسعار الأسهم:

تُعد الأسهم من أبرز الأدوات المالية لبناء الثروات، وتشكل أساساً لأي محفظة استثمارية ناجحة، ومع التقدم التكنولوجي في مجال التداول، أصبح بإمكان أي شخص تقريباً الاستثمار في الأسهم بسهولة، ومع تقلبات الأسواق المالية، أصبح من الضروري وجود تنبؤات دقيقة للاتجاهات المستقبلية لضمان اتخاذ قرارات استثمارية مدروسة (Ghania et.al,2019:97)، يُشار إلى سعر السهم على أنه سعر سهم واحد من أسهم الشركة المتداولة علناً، وهو ليس ثابتاً ويتغير وفقاً لظروف السوق، وهو أعلى مبلغ يرغب شخص ما في دفعه مقابل السهم، أو أقل مبلغ يمكن شراؤه به، لذلك، فإن التنبؤ بأسعار الأسهم مهم للمساعدة في اتخاذ القرار وفهم اتجاهات السوق (Emmanuel & Tolulope, 2024:1)، ويُعرف التنبؤ باتجاه أسعار الأسهم بمحاولة تحديد قيمة السهم وتقديم تصور دقيق يساعد الأفراد على فهم السوق بشكل أفضل، تُعد القدرة على التنبؤ بتأثيرات الأحداث الأخيرة مهارة قيمة للمستثمرين، وقد تشمل هذه الأحداث عوامل مثل النمو الاقتصادي، معدلات الفائدة، والأخبار، التي تؤثر بدورها على أرباح الشركات وتوجهات السوق، ومع ذلك، من الصعب للغاية على معظم المستثمرين التنبؤ بهذه العوامل بشكل دقيق ومتسق، مما يجعل التنبؤ بأسعار الأسهم مهمة صعبة (Emioma & Edeki,2021:2)، حيث يواجه المستثمرون والشركات وصناديق الاستثمار تحديات كبيرة في تقدير الأرباح المستقبلية، حيث تتأثر أسعار الأسهم بعدد من العوامل المتنوعة مثل السياسات الاقتصادية، وقرارات سوق الأوراق المالية، وتدفقات رأس المال، والتغيرات في ملكية الشركات، مما يجعلها نظاماً غير خطي وغير مستقر، هذه العوامل تُصعب التنبؤ الدقيق بأسعار الأسهم، كما أن عدم الاستقرار المتكرر يؤدي إلى تغييرات في خصائصها الإحصائية مثل المتوسط والتباين، مما يجعل تقنيات تحليل السلاسل الزمنية التقليدية غير فعالة، لذا تبرز الحاجة لاستراتيجيات قادرة على التعامل مع هذه التحديات وتقديم نتائج موثوقة، وعلى مر السنوات تم تطوير تقنيات عدة للتنبؤ بالنتائج في مجالات متنوعة، بما في ذلك التحليل الإحصائي، والتعلم الآلي، والشبكات العصبية، والتعلم العميق، مما مكن من تحقيق تنبؤات دقيقة في العديد من التطبيقات (Ge,2025:2).

في الماضي، كانت الطريقتان الرئيسيتان للتنبؤ بأسعار الأسهم تقتصران على التحليل الفني والتحليل الأساسي، في الماضي اعتمد التنبؤ باتجاه أسعار الأسهم على الأساليب التقليدية التي تركز على التحليل الأساسي والفني، إذ يتعامل التحليل الأساسي مع تقدير القيمة الجوهرية للشركة من خلال تحليل البيانات المالية وظروف الصناعة والمؤشرات الاقتصادية، ويحاول المستثمرين من خلال هذا النهج تحديد ما إذا كان السهم مبالغاً في قيمته أو أقل من قيمته الحقيقية بناءً على صحته الأساسية، بينما يركز التحليل الفني على بيانات الأسعار والحجم التاريخية، باستخدام الرسوم البيانية والمؤشرات لتحديد الأنماط التي قد تشير إلى تحركات الأسعار المستقبلية، ويفترض أن جميع المعلومات تنعكس بالفعل في أسعار الأسهم، وأن الاتجاهات التاريخية يمكن أن تكون مؤشراً للأداء المستقبلي (Rahman et.al,2025:46).

وفي الوقت الحاضر في ضوء ضخامة البيانات وتعقدها في أسواق الأسهم، أصبح من الضروري استخدام نماذج قادرة على اكتشاف الأنماط المخفية والعلاقات المعقدة في هذه البيانات، وقد أثبتت تقنيات التعلم الآلي قدرتها على تحسين الكفاءة بنسبة تتراوح بين 60% - 86% في هذا المجال (Vijh et.al,2020:599)، وبالنسبة للمستثمرين يعد التنبؤ باتجاه سعر الأسهم أمراً بالغ الأهمية، حيث يمكن أن يساعد في اتخاذ قرارات مالية حكيمة، إذ أن تقليل خطأ التنبؤ يُساهم بشكل كبير في تقليل المخاطر المرتبطة بالاستثمار في سوق الأوراق المالية (Ampomah et.al,2020:1).

ومما سبق ترى الباحثة أن التنبؤ بأسعار الأسهم يعد أمراً هاماً للمستثمرين، حيث يساعدهم على اتخاذ قرارات مالية مدروسة ويقلل من المخاطر المرتبطة بالاستثمار في الأسواق المتقلبة، لذا فإن الدمج بين التحليل الفني وخوارزميات التعلم الآلي يمكن أن يعزز من دقة التنبؤ، حيث يعمل التحليل الفني على استنباط الأنماط بينما تضيف الخوارزميات قدرات استشرافية أكثر تطوراً.

يُحدث التعلم الآلي تحولات في التنبؤ بأسعار الأسهم بفضل قدرته على استخلاص الأفكار والأنماط من مجموعات البيانات الضخمة، ومن بين العديد من الخوارزميات المتاحة، تبرز نماذج أساسية معينة بسبب كفاءتها وقدرتها الفائقة (Zhou, 2024:737)، وقد حظيت عملية التنبؤ بالاتجاهات المستقبلية لمؤشرات الأسهم باهتمام واسع من قبل الباحثين والمستثمرين، حيث يشكل تعقيد البيانات تحديًا كبيرًا في التنبؤ بسلوك أسعار سوق الأسهم في المستقبل (Özdemir & Uluyol, 2025:147)، وبالتالي، يمكن عرض خوارزميات التعلم الآلي كما يلي:

1. خوارزمية الانحدار الخطي (LR) Linear regression :

تعد إحدى التقنيات المستخدمة للتنبؤ ووصف العلاقة بين متغيرين أو أكثر، حيث تشمل رسم خط مستقيم، وتعرف الطريقة بالانحدار الخطي البسيط إذا كان النموذج يحتوي على متغير مستقل واحد، بينما يستخدم الانحدار الخطي المتعدد إذا كان النموذج يحتوي على عدة متغيرات مستقلة (Eka et.al, 2024:553)، وهي من أبسط وأشهر الخوارزميات المستخدمة في التنبؤ بأسعار الأسهم، يمكن تطبيق هذه الخوارزمية لنمذجة العلاقة بين مجموعة من المدخلات المختلفة، مثل البيانات التاريخية للأسعار والمؤشرات الاقتصادية والعوامل ذات الصلة، وبين المتغير المستهدف الذي يتمثل في سعر السهم في وقت محدد، تتلائم خوارزمية الانحدار الخطي مع البيانات بهدف تقليل مجموع الأخطاء التربيعية بين القيم المتوقعة والفعالية (Kabir et.al, 2023:948).

تتمثل عملية الانحدار الخطي في البحث عن الخط المستقيم الذي يمثل أفضل تطابق مع نقاط البيانات المدخلة، ويُعتبر هذا الخط هو "خط الانحدار"، الذي يحقق أفضل تمثيل للبيانات، أما القيم التي تبعد عن هذا الخط بعد نمذجتها فتُسمى القيم المتطرفة، التي قد تشير إلى وجود بيانات غير صحيحة أو أن النموذج غير مناسب للبيانات، تُعتبر القيم المتطرفة مسببًا رئيسيًا في تقليل دقة التنبؤات، إذ يمكن أن تغير بشكل كبير نتائج الانحدار الخطي. وبالرغم من أن الانحدار الخطي يفترض دائمًا وجود علاقة خطية بين المتغيرات المدخلة والنتائج المتوقعة، فإن هذا قد لا يكون واقع الحال في جميع الحالات (Sangeetha & Alfia, 2024:2).

على الرغم من أن الانحدار الخطي قد يُعتبر تقنية بسيطة، إلا أنه يظل قابلاً للتطبيق في العديد من المجالات، مثل التنبؤات بأسواق الأسهم، من خلال تحديد الأنماط الأساسية التي تؤثر على المتغيرات، على سبيل المثال، باستخدام المتغيرات المدخلة مثل سعر السهم، المؤشرات الاقتصادية، مؤشرات السوق، وحجم التداول، يمكن التنبؤ بقيمة معينة مثل حجم التداول بدقة معقولة، ومن ثم يعد الانحدار الخطي أداة فعالة في التنبؤات بأسواق الأسهم بفضل مزاياه مثل بساطته وكفاءته وسرعته، بالإضافة إلى كونه تقنية راسخة ومع ذلك، يواجه الانحدار الخطي بعض القيود التي قد تؤثر على أدائه، مثل حساسيته للقيم المتطرفة، وعدم قدرته على التعامل مع العلاقات غير الخطية، وفرضه لافتراضات وجود علاقة خطية، مما قد يحد من ملاءمته في بعض الحالات، رغم ذلك فإن هذه العيوب لا تؤثر بشكل كبير على فعالية التنبؤات بأسواق الأسهم (Li, 2024:854).

2. خوارزمية الجار الأقرب (K-Nearest Neighbors(KNN) :

تُعتبر خوارزمية الجار الأقرب نهجًا غير معياري يُستخدم للتصنيف والانحدار، حيث تقوم بتصنيف نقاط البيانات من خلال تحديد الفئة السائدة بين أقرب جيران K أو بتنبؤ القيمة المتوسطة لأقرب جيران K في حالة الانحدار، وتعد هذه الخوارزمية سهلة التطبيق ولا تفترض وجود توزيع معين للبيانات الأساسية، ومع ذلك قد تنخفض فعاليتها عندما تتعامل مع بيانات عالية الأبعاد أو مجموعات بيانات كبيرة، نظرًا للتعقيد الحسابي المرتبط بها (Bouasabah, 2024:4)، تعتمد تقنية KNN على مبدأ بسيط يتمثل في العثور على أقرب K نقاط بيانات في مجموعة التدريب التي تتشابه بشكل كبير مع النقطة الجديدة المدخلة، وبناءً عليه يتم استخدام مؤشرات تشابه معينة لتحديد هذه النقاط المماثلة، مما يساهم في تحسين دقة التنبؤ بالقيم الرقمية بناءً على هذا التشابه (Prasad et.al, 2024:2).

3. خوارزمية الشبكة العصبية الاصطناعية (ANN) Artificial neural networks :

تم تقديم الشبكات العصبية الاصطناعية لأول مرة بواسطة McCulloch و Pitts كخوارزمية تحاكي الخلايا العصبية في الدماغ، لاحقًا، أصبحت الشبكات العصبية الاصطناعية خوارزمية تعلم آلي مستخدمة على نطاق واسع في مجالات مختلفة، وتتكون الشبكة العصبية الاصطناعية الأساسية من مجموعة من المدخلات التي تمر عبر طبقات مخفية ثم تنتقل إلى المخرجات، إحدى التحديات الأساسية في الشبكات العصبية هي عملية التدريب، التي تتمثل في

تحسين معلمات الإدخال لضمان دقة التنبؤات (Khoa & Huynh, 2022: 6627) ، تمثل الشبكات العصبية الاصطناعية نماذج حسابية تحاكي الشبكات العصبية البيولوجية، حيث يتم تنظيم مجموعة من العقد في طبقات تبدأ من طبقة الإدخال وتنتهي بطبقة الإخراج، وخلال عملية التعلم، تُرسل الإشارات بين العقد المتصلة وتُعدل الأوزان المرتبطة بها بناءً على البيانات المدخلة، بهدف تقليل خطأ التنبؤ، ومن خلال هذه العملية، يعمل النظام على تحسين أدائه مع مرور الوقت عبر تكييف الأوزان بشكل مستمر، مما يُمكنه من التنبؤ بدقة أكبر (Strader et.al, 2020: 67)

4. خوارزمية نايف بايز (NB):

تعتمد خوارزمية بايز على نظرية بايز، مع افتراض استقلال المتغيرات (أو المتنبئين) عن بعضها البعض، توفر نظرية بايز طريقة لحساب الاحتمالات اللاحقة، مما يسمح بتصنيف البيانات بناءً على الاحتمالات المستخلصة من البيانات السابقة، يعتبر النموذج البايزي مناسباً بشكل خاص للمجموعات الكبيرة من البيانات، وعلى الرغم من بساطته، فإن المصنف البايزي غالباً ما يقدم أداءً متميزاً في كثير من الحالات، وغالباً ما يتفوق على طرق التصنيف الأكثر تعقيداً (Chen et al., 2019: 299) ، ولقد أثبتت مصنفات بايز فعاليتها في العديد من المواقف المعقدة في العالم الواقعي، حيث تقوم الخوارزمية بتصنيف الملاحظات إلى الفئة الأكثر احتمالاً عن طريق تقدير كثافة المتنبئين داخل كل فئة (Akyildirim et.al, 2022: 644).

5. خوارزمية الذاكرة الطويلة والقصيرة المدى (LSTM):

نموذج الذاكرة الطويلة الأمد (LSTM) هي نموذج متقدم لاستخراج البيانات مصمم لاكتشاف الاتجاهات الأساسية وتحليل الأنماط المعقدة في البيانات غير المنظمة (Jabed, 2024: 2) مما يجعله مثالياً للتنبؤ بأسعار الأسهم على المدى القصير، تستخدم LSTM آلية مميزة لتخصيص أوزان مختلفة للمعلومات مع تجاهل الذاكرة التي تُعتبر غير ذات صلة بالتنبؤ المستقبلي. وهذا يمكنها من التعامل مع تسلسلات بيانات طويلة، في حين أن الشبكات العصبية المتكررة التقليدية (RNN) عادة ما تواجه صعوبة في التعامل مع التسلسلات الطويلة، وتعد LSTM واحدة من أنجح أنواع الشبكات العصبية المتكررة، حيث توفر خلية ذاكرة تحل محل الخلايا العصبية التقليدية في الطبقة المخفية، مما يعزز قدرتها على ربط المدخلات والذكريات بشكل فعال، مما يسمح لها بالتعامل مع البيانات المرنة زمانياً، تُستخدم خوارزمية LSTM على نطاق واسع في التنبؤ بأسعار الأسهم على المدى القصير باستخدام التحليل الفني، حيث تعتمد على دمج تقنيات التعلم الآلي مع التحليل الفني لاكتشاف أنماط التقلبات التي قد تؤدي إلى عوائد للمستثمرين، مما يعزز من كفاءة اتخاذ قرارات الاستثمار (Phuoc et.al, 2024: 3).

كما تتمتع (LSTM) بقدرتها على تحليل البيانات الزمنية بشكل يتجاوز الشبكات العصبية المتكررة التقليدية، بفضل قدرتها على معالجة التلاشي والانفجار في التدرجات، وهي مشكلة غالباً ما تواجه الشبكات العصبية التقليدية ، بفضل هذه الخصائص، فإن LSTM قادرة على تمييز وتوقع الأنماط في بيانات السلاسل الزمنية، مما يجعلها مثالية للمهام التنبؤية مثل تحليل السلاسل الزمنية والنصوص والكلام (Chen et.al, 2024: 6) ، تتكون بنية شبكة LSTM من سلسلة من الخلايا العصبية التي تحتوي كل منها على بوابات للإدخال والإخراج ، مما يسمح لها بتنظيم تدفق المعلومات بشكل انتقائي. يمكن لهذه البوابات الحفاظ على التبعيات طويلة الأمد في بيانات الإدخال عن طريق نسيان أو حفظ المعلومات من خطوات زمنية سابقة (Kumar et.al, 2024: 759-760)، وفي مجال التنبؤ بأسعار الأسهم، توفر خوارزمية LSTM القدرة على اكتشاف الأنماط والعلاقات المعقدة في البيانات، مما يساعد في التنبؤ بأسعار الأسهم المستقبلية بدقة أعلى، حيث أن تسلسل وتوقيت الأحداث في الأسواق المالية من الأمور الحاسمة (Kong, 2024: 111).

ومما سبق ترى الباحثة أن خوارزمية LSTM تتميز بقدرتها على التعامل مع البيانات الزمنية طويلة المدى، مما يجعلها أداة مثالية لتحليل أسواق الأوراق المالية التي تعتمد على سلاسل زمنية معقدة.

6. خوارزمية الانحدار اللوجستي (Logistic regression(LR):

يمكن استخدام الانحدار اللوجستي كنموذج لتنبؤ أسعار الأسهم من خلال استخراج السمات ذات الصلة من قاعدة بيانات أسعار الأسهم التاريخية k يتيح هذا النموذج تصنيف الأسهم إلى فئتين، حيث يتم تحديد ما إذا كان من الأفضل شراء السهم (1) أو عدم شرائه (0) بناءً على الأنماط المعروفة في البيانات، ويتميز الانحدار اللوجستي بتقديم تقديرات احتمالية، مما يتيح الحصول على نتائج أكثر دقة للتنبؤ بالنتائج المتوقعة (Kayit & Tahir, 2024: 5) ، من خلال

تحليل مجموعة من بيانات الإدخال، يمكن لهذا النموذج التنبؤ بارتفاع أو انخفاض قيمة السهم باستخدام منحني لوجستي يتم تطبيقه على البيانات، علاوة على ذلك، يوفر الانحدار اللوجستي تقديرات احتمالية حول كيفية حدوث الأحداث المستقبلية المرتبطة بالأسواق المالية (Al-Amri et.al,2024:120).

7. خوارزمية آلة ناقلات الدعم (Support Vector Machine(SVM):

تستخدم خوارزمية آلة ناقلات الدعم (SVM) على نطاق واسع في تحليل الاتجاهات المالية والتوقعات، مثل التنبؤ بأسعار الأسهم والعوائد، كما أنها تعد أداة قوية للتنبؤ بالاتجاهات المستقبلية، أحجام التداول، وهوامش الربح، وغيرها من مؤشرات سوق الأوراق المالية، حيث تقدم دقة تنبؤ تفوق طرق السلاسل الزمنية التقليدية (Zhang et.al,2024:2)، قد اكتسبت آلة ناقلات الدعم شهرة كبيرة بفضل قدرتها على التنبؤ بتحركات سوق الأوراق المالية، وتحظى بالعديد من الفوائد التي تجعلها خيارًا مفضلًا في هذا المجال، ومن أبرز هذه الفوائد (Swamy et.al,2024:266):

- **دقة عالية في التنبؤ:** تتميز خوارزمية آلة ناقلات الدعم بقدرتها على التنبؤ بحركات أسعار الأسهم بدقة عالية، حيث تصل معدلات دقتها إلى 93.7% في كثير من الأحيان.
- **فعاليتها مع المشاكل عالية الأبعاد وغير الخطية:** تتفوق آلة ناقلات الدعم في التعامل مع مجموعات البيانات ذات الأبعاد العالية والأنماط المعقدة غير الخطية، وهي خصائص شائعة في بيانات سوق الأوراق المالية.
- **المتانة والتقارب السريع:** تشتهر آلة ناقلات الدعم بمتانتها وتقاربها السريع، مما يجعلها مناسبة بشكل خاص للتطبيقات المالية الحقيقية التي تتطلب نتائج دقيقة وفعالة في التنبؤ بأسعار الأسهم.
- **التنوع والتكيف:** يمكن تعزيز قوة التنبؤ لآلة ناقلات الدعم من خلال دمجها مع طرق تحسين أخرى مثل الخوارزميات الجينية، مما يزيد من تنوع وكفاءة النموذج في التنبؤ بأسواق الأوراق المالية.
- وعلى الرغم من الفوائد العديدة التي تقدمها آلة ناقلات الدعم في التنبؤ بسوق الأوراق المالية، إلا أنها تواجه بعض القيود، من أبرزها:
- **الإفراط في التجهيز:** قد تصبح آلة ناقلات الدعم معقدة للغاية إذا لم تتم إدارتها بشكل صحيح، مما يؤدي إلى الإفراط في التجهيز، حيث يعمل النموذج جيدًا على بيانات التدريب ولكنه يعاني من ضعف الأداء على البيانات غير المرئية.
- **صعوبات في ضبط المعلمات الفائقة:** يتطلب اختيار المعلمات الفائقة المثلى لآلة ناقلات الدعم تعديلات دقيقة لضمان استقرار النموذج وأدائه، ما قد يكون تحديًا في بعض الأحيان.
- **اختيار الميزات غير الفعالة:** تعتمد فعالية آلة ناقلات الدعم بشكل كبير على اختيار الميزات المناسبة، إذا كانت عملية اختيار الميزات غير دقيقة، فقد يؤثر ذلك سلبًا على دقة النموذج.
- **الحساسية للبيانات عالية الأبعاد الفوضوية:** قد تواجه آلة ناقلات الدعم صعوبة في التعامل مع مجموعات البيانات الفوضوية أو ذات الأبعاد العالية جدًا دون المعالجة المسبقة المناسبة أو تقنيات تقليل الأبعاد.

8. خوارزمية الغابات العشوائية (Random Forest(RF):

إحدى تقنيات التعلم الآلي التي تُستخدم لأداء مهام الانحدار والتصنيف، الغابة العشوائية هي خوارزمية تدمج كل من طرق التجميع وشجرة القرار المتعددة لإنتاج حلول فعالة (Priyatno et.al,2024:3)، وتعتمد فكرتها على دمج العديد من أشجار القرار لتحديد النتيجة النهائية بدلاً من الاعتماد على شجرة قرار واحدة، وذلك بهدف تقليل التباين في النموذج، من خلال هذه الخوارزمية يتم توفير متغيرات جديدة لتدريب كل شجرة قرار، والتي بدورها تحدد القرار عند عقد الشجرة، وعادة ما تكون بيانات سوق الأوراق المالية فوضوية بسبب حجمها الكبير، مما قد يؤدي إلى نمو الأشجار بطريقة تختلف تمامًا عن النمو المتوقع، وتهدف هذه الخوارزمية إلى تقليل خطأ التنبؤ عن طريق معالجة تحليل سوق الأوراق المالية كمسكلة تصنيف، وبناءً على متغيرات التدريب، يتم التنبؤ بسعر إغلاق اليوم التالي لسهم شركة معينة (Vijh et.al,2020:600-601)، يعتمد عمل الغابة العشوائية على جزئين أساسيين: الأول هو بناء أشجار القرار، والثاني هو إخراج نتائج التصويت، وأثناء بناء شجرة القرار يتم تقليل خطر التحيز المفرط للنموذج

عبر استخدام عينات عشوائية من البيانات واختيار الميزات بشكل عشوائي، وفي كل عقدة من الشجرة، يتم اختيار ميزة عشوائية للقيام بالانقسام، مما يعزز قدرة النموذج على التعميم. وعند إخراج نتائج التصويت، تقوم عدة أشجار قرار بإعطاء تصويتها لتحديد النتيجة النهائية للتنبؤ (Zhanga et.al, 2024:286)، علاوة على ذلك، تتمتع خوارزمية الغابات العشوائية بالقدرة على تحليل ميزات التصنيف المعقدة، مما يتيح لها قياس أهمية الميزات وتحديد المؤشرات الفنية الأكثر صلة بتوقع أسعار الأسهم (Zhang et.al, 2021:1239).

وفي هذا السياق، ترى الباحثة إلى أن كل خوارزمية من خوارزميات التعلم الآلي تحمل نقاط قوة وضعف، ويعتمد اختيار الخوارزمية المناسبة على الخصائص المحددة لمجموعة البيانات والأهداف المحددة للتنبؤ، حيث أظهرت خوارزمية الذاكرة الطويلة والقصيرة المدى LSTM تفوقاً في التعامل مع البيانات الزمنية وتحليل الأنماط طويلة الأمد، إلا أن تطبيقها يتطلب موارد حاسوبية مرتفعة، مما يبرز الحاجة للتوازن بين دقة النموذج وتكاليف التشغيل، كما أن خوارزمية الغابات العشوائية تمثل خياراً مرناً وقوياً للتعامل مع الأسواق الناشئة، حيث تقدم نتائج دقيقة مع تقليل تأثير القيم المتطرفة في البيانات.

ثالثاً: سوق الأوراق المالية:

هو المنصة التي يتم من خلالها تداول أسهم الشركات المدرجة، حيث يمكن لأي فرد شراء سهم أو أكثر من أسهم الشركات وبيعها بهدف تحقيق الربح أو تجنب الخسارة استناداً إلى تنبؤاته بحركة أسعار الأسهم، بينما قد يرى البعض أن هذه العمليات تشبه المقامرة، إلا أن التنبؤ الدقيق يمكن أن يؤدي إلى مكاسب مالية كبيرة إذا تم استخدام البنية التحتية والمعرفة المناسبة، ومع تقدم ثورة علم البيانات والتعلم الآلي والذكاء الاصطناعي، أصبحت مهمة التنبؤ بأسعار الأسهم أكثر سهولة وفعالية. يعد التنبؤ باتجاهات ونتائج مجموعات البيانات واحدة من أكبر التحديات في التعلم الآلي، حيث كان الإحصائيون سابقاً يعتمدون على تقنيات يدوية مثل الرسوم البيانية واستخدام النماذج الرياضية لتحديد الأنماط، قبل أن يتمكن الذكاء الاصطناعي والتعلم الآلي من تسريع هذه العمليات وتحقيق نتائج أكثر دقة وسرعة (Kumar et.al, 2024:758).

كما تستند توقعات سوق الأوراق المالية عادةً إلى تحليل البيانات التاريخية والذي يتضمن فحص المقاييس السابقة المتعلقة بالأسهم، مثل أسعار الافتتاح والإغلاق، الأسعار المرتفعة والمنخفضة، أسعار الإغلاق المعدلة، وحجم التداول (Gurung et al., 2024:158)، ومع ذلك يعد التنبؤ بالأنماط في سوق الأوراق المالية أمراً بالغ الأهمية ولكنه معقد، بسبب التقلبات المتأصلة والقوى النفسية التي تؤثر على سلوك السوق، وتركز الأساليب التقليدية في التنبؤ بشكل أساسي على البيانات الكمية، مثل الأسعار التاريخية، أحجام التداول، والمؤشرات الاقتصادية، وهي طرق تُستخدم لتحديد الاتجاهات المستقبلية بناءً على البيانات السابقة (Govindan et al., 2025:176).

يعد سوق الأوراق المالية أداة هامة في تعزيز هيكل رأس المال داخل البلدان، حيث يساهم في الحفاظ على تداول نشط وتحفيز سيولة الموارد، كما يساعد في تحريك الأسعار ودعم استقرار السوق، يوفر السوق منصة للمستثمرين والبائعين لإجراء معاملات عادلة وسريعة وشفافة (Singh & Mishra, 2023:50)، ويعتبر سوق الأوراق المالية خياراً استثمارياً شائعاً للمستثمرين نظراً للعوائد المرتفعة المتوقعة، مما يجعل التنبؤ بحركاته مهمة معقدة تتطلب الاستعانة بالذكاء الاصطناعي، وذلك لأن أسعار الأسهم تتأثر بالعديد من العوامل المتنوعة مثل الاتجاهات العامة في السوق والأخبار الاقتصادية، ففي السنوات الأخيرة، ظهرت العديد من النماذج والتقنيات المبتكرة التي تم تطبيقها لتحقيق تنبؤات دقيقة وفعالة بشأن سلوك سوق الأوراق المالية (Saini & Sharma, 2022:791).

يُعد سوق الأوراق المالية منصة حيوية للتداول حيث يقوم المستثمرون بشراء وبيع الأسهم، ويؤثر صعود وهبوط السوق بشكل مباشر على أرباح أصحاب المصلحة. عندما ترتفع أسعار الأسهم في السوق، يحقق المستثمرون أرباحاً من الأسهم التي اشتروها، بينما في حالة انخفاض الأسعار، يواجهون خسائر محتملة، يسعى المستثمرون لشراء الأسهم بأسعار منخفضة وبيعها بأسعار مرتفعة لتحقيق أقصى قدر من الأرباح، ويعمل سوق الأوراق المالية كحلقة وصل موثوقة بين البائعين والمشتريين، مما يساهم في تحقيق التوازن بين العرض والطلب، وتُستخدم خوارزميات التعلم الآلي لتدريب الآلات على اتخاذ قرارات استباقية بناءً على المعايير المحددة، وتُعتبر التنبؤات المستقبلية لسوق الأوراق المالية مفيدة جداً لرجال الأعمال والمستثمرين، حيث توفر هذه التنبؤات إشارات عن الاتجاهات المحتملة لأسعار الأسهم بناءً على البيانات التاريخية، إذا تمكن المستثمرون من الحصول على تنبؤات دقيقة، يمكنهم توجيه استثماراتهم

نحو تحقيق الربح، رغم أن هذه التنبؤات قد تكون صحيحة بنسبة 50% وخاطئة بنفس النسبة، فإنها تظل تمثل نوعاً من المخاطرة التجارية التي قد تؤدي إلى النجاح في جميع مجالات الحياة، ويتحمل الأفراد المخاطر بحثاً عن النجاح، وينطبق نفس الأمر على التنبؤات المتعلقة بأسواق الأوراق المالية، وبالتالي قبل تطبيق خوارزميات التعلم الآلي ML في التنبؤ بأسعار الأسهم، من الضروري فهم دور هذه الخوارزميات بشكل شامل واختيار الأنسب لتقديم تنبؤات دقيقة (Ghania et.al, 2019:97-98).

رابعاً: التنبؤ بأسعار الأسهم في الأسواق المالية على أساس خوارزميات التعلم الآلي:

يعد التنبؤ بأسعار الأسهم من الموضوعات التي تحظى باهتمام كبير في الأوساط الأكاديمية، حيث يتم التنبؤ بها من خلال أساليب متنوعة، من أبرز هذه الأساليب هو التحليل الفني الذي يعد أسلوباً لتقييم الأسهم من خلال تحليل البيانات المستخلصة من حركة السوق والقيم التاريخية وحجم التداول، يتضمن التحليل الفني جوانب هامة من تقلبات أسعار الأسهم مثل الأنماط والاتجاهات وأعلى وأدنى الأسعار، وغيرها من العوامل، وغالباً ما يعتمد التنبؤ بأسعار الأسهم على دراسة الأداء التاريخي للسهم والعوامل المرتبطة به، كما يقوم التحليل الفني بتحليل الأنماط والمؤشرات على مخططات الأسهم بهدف التنبؤ بأداء السهم في المستقبل (Punjabi & Faridi, 2024:2701).

وفي السنوات الأخيرة، مع ظهور الذكاء الاصطناعي، ازدادت فاعلية خوارزميات التعلم الآلي في التنبؤ بأسعار الأسهم. وقد أدت هذه الخوارزميات إلى تحول جذري في المجال بقدرتها الاستثنائية على معالجة كميات هائلة من البيانات، مما يساعد على التنبؤ بحركة سوق الأسهم بدقة أكبر (Tulsyan et.al, 2024: 350)، تتضمن الخوارزميات المستخدمة نماذج الانحدار، وآلة ناقلات الدعم، والغابات العشوائية، والشبكات العصبية، والتي تتيح تحليل العلاقات المعقدة والتكيف مع ديناميكيات السوق المتغيرة (Soni, 2022:1; Ghaffa & Setiawan, 2024:80).

وتعتبر خوارزميات التعلم الآلي، مثل الخوارزميات الخاضعة للإشراف وغير الخاضعة للإشراف، أدوات قوية في التنبؤ بأسواق الأسهم، ففي التعلم الخاضع للإشراف، يتم تدريب الخوارزميات باستخدام بيانات مدخلة مع علامات لتوليد مخرجات دقيقة، في حين يعتمد التعلم غير الخاضع للإشراف على بيانات غير مسماة للكشف عن الأنماط دون تدخل بشري، كما تتضمن التقنيات التطورية مثل الخوارزميات العصبية الجينية التي تحاكي عملية الانتقاء الطبيعي في الكائنات الحية لتحسين نتائج التنبؤ (Rouf et al., 2021:2).

لقد أثبتت الدراسات الحديثة أن التنبؤ بأسعار الأسهم باستخدام خوارزميات التعلم الآلي يمكن أن يحسن بشكل كبير من دقة التنبؤ مقارنة بالطرق التقليدية، إذ يساعد هذا التقدم المستثمرين في اتخاذ قرارات أكثر استنارة وتحقيق نتائج أفضل في ظل التقلبات والتغيرات المستمرة في الأسواق المالية (Kim et.al, 2020: 111662)، كذلك أظهرت الأبحاث أنه باستخدام خوارزميات مثل SVM و DT و LR و NN و KNN و ANN و CNN، يمكن تحسين الأداء في التنبؤ بأسعار الاسهم بشكل ملحوظ (Rath et.al, 2024:88).

في هذا السياق، يتم استخدام خوارزميات التعلم الآلي لتحقيق هدفين هما: التنبؤ بما إذا كانت قيمة السهم سترتفع أو تنخفض على المدى المتوسط (من 3 إلى 5 أشهر)، وتحديد الخوارزمية الأكثر دقة في التنبؤ بحركة السهم (Sarker et al., 2024:384)، وبفضل هذه التطورات، باتت تقنيات التعلم الآلي تمكّن المحللين والمستثمرين من اتخاذ قرارات مبنية على تحليل دقيق للبيانات، مما يساهم في تحسين استراتيجيات الاستثمار وتقليل المخاطر المالية في الأسواق المتقلبة (Ghaffa & Setiawan, 2024: 80).

ومما سبق ترى الباحثة أن التنبؤ بأسعار الأسهم باستخدام خوارزميات التعلم الآلي يمثل خطوة هامة نحو زيادة دقة التنبؤات وتقليل المخاطر المالية في الأسواق المتقلبة، كما أن التقدم المستمر في تقنيات الذكاء الاصطناعي يفتح آفاقاً جديدة للمستثمرين والمحللين لتحسين استراتيجياتهم وتفادي الخسائر المحتملة.

القسم الرابع : الإطار التطبيقي للدراسة

أولاً: منهج الدراسة:

تم استخدام المنهج الوصفي التحليلي لوصف وتحليل البيانات المالية والتنبؤ باتجاه أسعار الأسهم باستخدام خوارزميات التعلم الآلي، سيتضمن المنهج تحليلاً كمياً للبيانات المجمعة بهدف تحديد العلاقات والأنماط الرئيسية في البيانات.

ثانياً: مجتمع وعينة الدراسة:

1- مجتمع الدراسة:

تكون مجتمع الدراسة من جميع الشركات المدرجة في سوق الأوراق المالية بمصر خلال الفترة الزمنية الممتدة من عام 2019 حتى عام 2023. يشمل المجتمع الشركات من مختلف القطاعات الاقتصادية مثل القطاع المالي، القطاع الصناعي، قطاع الاتصالات، وقطاع الخدمات.

2- عينة الدراسة:

نظراً لأن سوق الأوراق المالية بمصر يضم عددًا كبيراً من الشركات، تم اختيار عينة عشوائية طبقية من هذه الشركات لتمثيل مختلف القطاعات الاقتصادية، يتكون حجم العينة من 10 شركات لضمان تغطية شاملة للقطاعات المتنوعة، مع مراعاة التوزيع النسبي لكل قطاع في السوق.

ومن معايير اختيار العينة:

1. التوافر المستمر للبيانات : بيانات الأسعار وأحجام التداول والبيانات المالية متاحة بشكل مستمر وكامل خلال الفترة من عام 2019 إلى 2023.
 2. التنوع القطاعي : اختيار شركات تمثل مختلف القطاعات الاقتصادية لضمان تمثيل واسع للسوق المصري.
 3. الحجم السوقي : تم تضمين شركات من مختلف الأحجام السوقية لضمان تنوع العينة.
 4. النشاط التداولي : تم اختيار الشركات ذات النشاط التداولي المستمر لضمان جودة البيانات المستخدمة في التحليل.
- و لإعداد عينة ممثلة ومتنوعة لتطبيق خوارزميات التعلم الآلي للتنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية المصري، تم اختيار 10 شركات من قطاعات مختلفة وفقاً للمعايير المحددة سابقاً كالتوافر المستمر للبيانات، التنوع القطاعي، الحجم السوقي، والنشاط التداولي، وفيما يلي قائمة بعشر شركات تم اختيارهم لتمثيل القطاعات المختلفة:

القطاع	اسم الشركة
المالي	البنك التجاري الدولي CIB يُعد من أكبر البنوك في مصر، وله نشاط تداولي مستمر، مما يوفر بيانات كافية لتحليل أسعار الأسهم.
العقاري	مجموعة طلعت مصطفى القابضة تعتبر من الشركات الكبرى في قطاع التطوير العقاري، وتتمتع ببيانات مالية متاحة ومستقرة.
الاتصالات	الشركة المصرية للاتصالات TE Data من أهم شركات الاتصالات في مصر، وتتمتع بنشاط تداولي كبير.
الصناعي	حديد عز من أبرز الشركات في صناعة الحديد والصلب، مما يُضيف بُعداً صناعياً للعينة.
المنتجات الاستهلاكية	الشرقية للدخان إسترن كومباني الشركة الرئيسية لإنتاج السجائر والتبغ في مصر، ولديها بيانات مالية مستقرة.
الإنشاءات	أوراسكوم للإنشاء والصناعة من الشركات الرائدة في مجال الإنشاءات والصناعات الهندسية، ولها وزن كبير في السوق.
الطاقة والبتروكيماويات	سيدي كرير للبتروكيماويات من شركات المعروفة في صناعة البتروكيماويات ولديها بيانات مالية موثوقة.
الأغذية والمشروبات	جھينة للصناعات الغذائية من الشركات المعروفة في مجال الصناعات الغذائية، وتُضيف تنوعاً إلى العينة.
الرعاية الصحية	مستشفى كليوباترا تمثل قطاع الرعاية الصحية، والذي يُعتبر قطاعاً مهماً ومتنامياً في مصر.
الخدمات المالية غير المصرفية	المجموعة المالية هيرميس من الشركات البارزة في تقديم الخدمات المالية، مما يُثري العينة ببيانات مالية متنوعة.

ثالثاً: مصادر البيانات:

- البيانات الأولية: تم الحصول على بيانات الأسهم المدرجة في البورصة المصرية من عام 2019 حتى عام 2023، بما في ذلك الأسعار اليومية الافتتاح، الإغلاق، أعلى وأدنى سعر وأحجام التداول.
- البيانات الثانوية: تشمل المعلومات المالية الأساسية للشركات مثل القوائم المالية، نسب الربحية، ونسب المديونية، والبيانات الاقتصادية الكلية مثل أسعار الفائدة، التضخم، أسعار الصرف.

رابعاً: فروض الدراسة:

1. بيان مدى تأثير خوارزمية الانحدار الخطي (Linear Regression (LR في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية بمصر.
2. بيان مدى تأثير خوارزمية الذاكرة الطويلة والقصيرة المدى (Long short-term memory (LSTM في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية بمصر.
3. بيان مدى تأثير خوارزمية آلة ناقلات الدعم (Support Vector Machine (SVM في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية بمصر.
4. بيان مدى تأثير خوارزمية الغابات العشوائية (Random Forest (RF في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية بمصر.

خامساً: التحليل المالي:

• تحليل الاتجاهات التاريخية

لإجراء الحسابات التي تخص تحليل الاتجاهات التاريخية لأسعار الأسهم وأحجام التداول للشركات العشر، يمكن استخدام المعادلات التالية لحساب المتوسطات والنسب المئوية والتغيرات السنوية:

1- حساب متوسط النمو السنوي للأسعار:

- متوسط النمو السنوي = سعر السهم في نهاية الفترة / سعر السهم في بداية الفترة $^{\wedge} 1$ / عدد السنوات - 1

يتم حساب النسبة المئوية للنمو لكل شركة من عام 2019 إلى 2023.

2- حساب نسبة التغير في الأسعار بين فترتين محددين:

- نسبة التغير = سعر السهم في الفترة الحالية - سعر السهم في الفترة السابقة / سعر السهم في الفترة السابقة $\times 100\%$

تُستخدم هذه المعادلة لحساب التغير في الأسعار خلال فترات معينة، مثل انخفاض الأسعار في بداية عام 2020 أو زيادتها في عام 2021.

3- حساب متوسط حجم التداول الشهري أو السنوي:

- متوسط حجم التداول = مجموع حجم التداول اليومي / عدد الأيام
- يمكن استخدام هذه المعادلة لحساب متوسط حجم التداول الشهري أو السنوي من خلال جمع أحجام التداول اليومية ثم تقسيمها على عدد الأيام.

4- حساب نسبة الزيادة في حجم التداول بين فترتين:

- نسبة الزيادة في حجم التداول = حجم التداول في الفترة الحالية - حجم التداول في الفترة السابقة / حجم التداول في الفترة السابقة $\times 100\%$

تُستخدم لحساب نسبة الزيادة في أحجام التداول خلال فترات مختلفة، مثل ارتفاع حجم التداول خلال النصف الثاني من عام 2021.

5- حساب المتوسط المتحرك:

- المتوسط المتحرك = مجموع أسعار الإغلاق لعدد معين من الأيام / عدد الأيام
- يُستخدم المتوسط المتحرك لفترة 50 أو 200 يوم لتحديد الاتجاهات الرئيسية في الأسعار.

6- حساب الانحراف المعياري للتقلبات السريعة:

- الانحراف المعياري = $\sqrt{\sum (X_i - \bar{X})^2 / N}$ - المتوسط اليومي
- تُستخدم هذه المعادلة لقياس مدى استقرار الأسعار وتحديد فترات التقلب العالي والمنخفض.

7- حساب التغير السنوي المركب: CAGR

$$CAGR = \frac{\text{القيمة النهائية} / \text{القيمة الأولية}}{1^{\text{عدد السنوات}} - 1}$$

تُستخدم لحساب معدل النمو السنوي المركب للأسعار أو حجم التداول خلال الفترة من 2019 إلى 2023.

8- حساب نسبة التداول إلى القيمة السوقية:

$$\text{نسبة التداول} = \frac{\text{إجمالي حجم التداول السنوي}}{\text{القيمة السوقية}} \times 100\%$$

يُستخدم هذا المؤشر لتحليل سيولة السهم خلال الفترة المحددة.

ويمكن تطبيقها على عينة الدراسة على النحو التالي:

اسم الشركة	الاتجاهات السعرية	أحجام التداول	التعليق
البنك التجاري الدولي	خلال عام 2019 إلى 2023، ارتفع سعر سهم البنك بنسب 25% في المتوسط سنوياً، مع تراجع ملحوظ في الربع الأول من عام 2020 نتيجة لجائحة كوفيد-19، وانخفض السهم بنسبة 18%، ثم تعافى تدريجياً.	ارتفع حجم التداول اليومي بنسبة 30% في عام 2021 مقارنة بعام 2020، مدفوعاً بالإعلان عن أرباح قياسية وتوزيعات الأرباح.	الاتجاه العام يشير إلى استقرار ونمو في الأداء المالي للبنك، مع تقلبات موسمية مرتبطة بالإعلانات السنوية للأرباح.
مجموعة طلعت مصطفى القابضة	شهد السهم ارتفاعاً بنسبة 15% في المتوسط السنوي، لكن مع انخفاض بنسبة 20% في بداية عام 2020. في عام 2023، ارتفع السهم بنسبة 10% نتيجة لمشاريع جديدة واستثمارات عقارية.	ارتفع حجم التداول خلال فترات الإطلاقات العقارية الجديدة بنسبة 25% مقارنة بالأشهر العادية.	الاتجاهات السعرية مرتبطة بشكل مباشر بأداء القطاع العقاري، مع ارتفاعات في الفترات التي يتم فيها الإعلان عن مشاريع جديدة.
الشركة المصرية للاتصالات	ارتفع السهم بنسبة 30% في المتوسط من عام 2021 إلى 2023 بعد إطلاق خدمات الجيل الخامس، مع ارتفاع طفيف بنسبة 5% سنوياً من عام 2019 إلى 2020.	شهدت أحجام التداول زيادة بنسبة 50% خلال النصف الثاني من عام 2021، بسبب الأخبار الإيجابية عن توسع الشبكات.	التحسن في الأسعار مرتبط بتوسعات الشركة في خدمات الإنترنت والاتصالات، مع استجابة واضحة لأخبار التطوير التكنولوجي.
حديد عز	شهد السهم تقلبات واضحة بسبب تغيرات أسعار الحديد العالمية، مع انخفاض بنسبة 30% في عام 2020 بسبب انخفاض الطلب العالمي، تلاه ارتفاع بنسبة 40% في عام 2021 مع تحسن الأسعار العالمية.	ارتفع حجم التداول بنسبة 35% خلال النصف الأول من 2021 بسبب زيادة الطلب المحلي على الحديد في قطاع الإنشاءات.	الاتجاهات السعرية وأحجام التداول تتأثر بشكل مباشر بأسعار السلع العالمية وأداء قطاع الإنشاءات المحلي.
الشرقية للدخان (إيسترن كومباتي)	استقرار نسبي في الأسعار مع متوسط نمو سنوي قدره 8%، وتراجع طفيف بنسبة 5% في عام 2020.	ارتفاع أحجام التداول بنسبة 20% خلال الفترات التي يتم فيها الإعلان عن زيادات في الأسعار أو تعديلات ضريبية.	الأسعار تميل للاستقرار، لكن أحجام التداول تتفاعل بشكل ملحوظ مع التغييرات في السياسات الضريبية.
أوراسكوم للإنشاء والصناعة	شهد السهم زيادة بنسبة 18% في المتوسط السنوي بعد انخفاض بنسبة 25% في عام 2020. التعافي مدعوم بتوقيع عقود إنشائية كبرى.	ارتفع حجم التداول بنسبة 40% خلال الأشهر التي تم فيها الإعلان عن مشاريع جديدة.	الاتجاهات مرتبطة بالأداء الإنشائي والعقود الكبيرة، مما يؤثر بشكل كبير على تحركات السهم.

سيدى كيرير للبروكيموايات	شهد السهم نموًا بنسبة 12% في المتوسط السنوي، مع تراجع بنسبة 15% في عام 2020 بسبب انخفاض أسعار النفط، ثم تعافى بنسبة 20% في 2021.	زادت أحجام التداول بنسبة 30% عند الإعلان عن نتائج مالية إيجابية.	السهم يتأثر بتقلبات أسعار النفط العالمية والتغيرات في الطلب على البتروكيماويات.
جهينة للصناعات الغذائية	نمو بنسبة 10% سنويًا، مع انخفاض بنسبة 12% في عام 2020 بسبب اضطرابات في سلاسل الإمداد.	ارتفاع أحجام التداول بنسبة 25% خلال الفترات التي تم فيها الإعلان عن توسعات جديدة في الإنتاج.	التوجهات السعرية ترتبط بأداء الشركة في زيادة الإنتاج واستجابة السوق للظروف الاقتصادية.
مستشفى كليوباترا	السهم شهد ارتفاعًا بنسبة 20% سنويًا نتيجة لتحسن الأداء المالي وزيادة الطلب على الخدمات الصحية.	ارتفعت أحجام التداول بنسبة 30% خلال فترة جائحة كوفيد-19 بسبب ارتفاع الاهتمام بالخدمات الصحية.	السهم يعكس زيادة الطلب على الخدمات الصحية، خاصة خلال فترات الأزمات الصحية.
المجموعة المالية هيرميس	ارتفاع بنسبة 25% سنويًا في المتوسط، مع زيادة بنسبة 30% في عام 2021 بعد إطلاق خدمات مالية جديدة.	تضاعفت أحجام التداول في فترات طرح المنتجات المالية الجديدة.	أداء السهم يتأثر بإطلاق المنتجات والخدمات المالية الجديدة في السوق.

ومما سبق تظهر النتائج أن معظم الشركات شهدت تقلبات ملحوظة في أسعار الأسهم وأحجام التداول، خاصة في الفترات المرتبطة بالأحداث الاقتصادية والمالية الكبرى مثل جائحة كوفيد-19 أو تغيرات في السياسات الاقتصادية، القطاعات المختلفة تظهر استجابات متباينة حسب طبيعة عملها، مما يوضح أهمية تحليل الأنماط التاريخية لكل قطاع على حدى.

- استخدام مؤشرات التحليل الفني مثل المتوسطات المتحركة، مؤشر القوة النسبية للتعرف على إشارات البيع والشراء.

1- المتوسطات المتحركة: Moving Averages

هو مؤشر يتتبع متوسط سعر السهم خلال فترة زمنية محددة، يمكن استخدام نوعين رئيسيين: المتوسط المتحرك البسيط SMA والمتوسط المتحرك الأسّي EMA ويمكن التعبير عنهم بالمعادلات الآتية:

○ المتوسط المتحرك البسيط SMA

SMA = مجموع أسعار الإغلاق لعدد معين من الأيام / عدد الأيام

○ المتوسط المتحرك الأسّي EMA

EMA = سعر الإغلاق الحالي × 2 / عدد الأيام + 1 + EMA السابق × 1 - 2 / عدد الأيام + 1

الأرقام المستخدمة:

■ عادةً ما تُستخدم فترات 50 و 200 يوم للمتوسطات المتحركة طويلة المدى لتحديد الاتجاهات الرئيسية.

■ يمكن استخدام فترات أقصر مثل 10 أو 20 يومًا للتعرف على إشارات قصيرة المدى.

• إشارات البيع والشراء:

○ إشارة شراء : تحدث عندما يتقاطع المتوسط المتحرك قصير المدى مثلاً 50 يومًا مع المتوسط المتحرك طويل المدى مثلاً 200 يوم من الأسفل إلى الأعلى، وهو ما يسمى "العبور الذهبي Golden Cross"

○ إشارة بيع : تحدث عندما يتقاطع المتوسط المتحرك قصير المدى مع المتوسط المتحرك طويل المدى من الأعلى إلى الأسفل، وهو ما يسمى "العبور الميت Death Cross"

تساعد المتوسطات المتحركة في تحديد الاتجاه العام للسوق والتعرف على انعكاسات الاتجاهات، تكون المتوسطات طويلة المدى أكثر استقرارًا وتناسب الاستثمار طويل الأجل، بينما تكون المتوسطات قصيرة المدى أكثر حساسية للتقلبات وتناسب التداول اليومي.

2- مؤشر القوة النسبية: Relative Strength Index - RSI

مؤشر القوة النسبية يقيس زخم الأسعار ويحدد مستويات الشراء المفرط Overbought أو البيع المفرط Oversold للأصل، ويمكن التعبير عنه بالمعادلة التالية:

$RSI = 100 - \frac{1}{1 + \text{متوسط المكاسب على عدد معين من الفترات} / \text{متوسط الخسائر على عدد معين من الفترات}}$

الأرقام المستخدمة:

- يتم حساب مؤشر RSI على فترة 14 يومًا، ولكن يمكن تعديلها حسب الحاجة 7 أو 21 يومًا.
 - القيم التقليدية لتحديد إشارات البيع والشراء هي:
 - إشارة شراء: إذا انخفض RSI إلى أقل من 30، مما يشير إلى أن السهم في حالة بيع مفرط.
 - إشارة بيع: إذا ارتفع RSI إلى أكثر من 70، مما يشير إلى أن السهم في حالة شراء مفرط.
- إن مؤشر RSI يساعد على تحديد نقاط الدخول والخروج من التداول. عندما يكون RSI في منطقة الشراء المفرط، فإنه قد يُشير إلى اقتراب انعكاس الأسعار نحو الانخفاض، والعكس صحيح في حالة البيع المفرط.

3- مؤشر التقارب والتباعد للمتوسط المتحرك: MACD

هو مؤشر زخم يتتبع الفرق بين متوسطين متحركين أسبوعيين مختلفين، وعادة ما يكون المتوسط الأسبوعي لفترة 12 و 26 يومًا، ويمكن التعبير عنه بالمعادلة التالية:

$MACD = EMA - EMA$ 12 يومًا - 26 يومًا.

الأرقام المستخدمة:

- يتم استخدام "خط الإشارة" الذي هو متوسط متحرك أسبوعي لـ MACD لفترة 9 أيام.
 - إشارة البيع والشراء: تحدث عندما يتقاطع MACD مع خط الإشارة.
 - إشارة شراء: إذا تقاطع MACD مع خط الإشارة من الأسفل إلى الأعلى.
 - إشارة بيع: إذا تقاطع MACD مع خط الإشارة من الأعلى إلى الأسفل.
- يساعد MACD في تحديد قوة الاتجاه والانعكاسات المحتملة. عندما يكون MACD في المنطقة الإيجابية، يكون الاتجاه صاعدًا والعكس صحيح.

4- مؤشر الستوكاستك: Stochastic Oscillator

يقيس هذا المؤشر موقع سعر الإغلاق الحالي بالنسبة إلى نطاق السعر خلال فترة زمنية معينة، عادة 14 يومًا. ويمكن التعبير عنه بالمعادلة التالية:

$K\% = \frac{\text{سعر الإغلاق الحالي} - \text{أقل سعر خلال 14 يومًا}}{\text{أعلى سعر خلال 14 يومًا} - \text{أقل سعر خلال 14 يومًا}} \times 100$

○ يتم حساب D% كمعدل متحرك لـ K% لفترة 3 أيام.

الأرقام المستخدمة:

- المستويات التقليدية لتحديد إشارات البيع والشراء هي:
 - إشارة شراء: عندما ينخفض K% إلى أقل من 20 ثم يرتفع فوق 20.
 - إشارة بيع: عندما يرتفع K% إلى أكثر من 80 ثم ينخفض تحت 80.
- يستخدم مؤشر الستوكاستك للتعرف على فترات الشراء المفرط أو البيع المفرط، ويكون مناسبًا بشكل خاص للتداول قصير الأجل.

اسم الشركة	سعر الإغلاق 2019	سعر الإغلاق 2020	سعر الإغلاق 2021	سعر الإغلاق 2022	سعر الإغلاق 2023
البنك التجاري الدولي (CIB)	10.00	9.50	11.00	12.00	15.00
مجموعة طلعت مصطفى القابضة	20.00	18.00	21.00	22.50	24.00
الشركة المصرية للاتصالات	30.00	32.00	34.00	31.00	36.00
حديد عز	25.00	24.00	26.00	28.00	30.00

15.00	14.00	16.00	17.50	20.00	الشرقية للدخان (إيسترن كومباني)
40.00	38.00	42.00	45.00	50.00	أوراسكوم للإنشاء والصناعة
35.00	36.00	38.00	39.00	45.00	سيدي كرير للبتروكيماويات
50.00	48.00	52.00	53.00	60.00	جھينة للصناعات الغذائية
10.00	9.00	11.00	12.00	14.00	مستشفى كليوباترا
15.00	14.00	16.00	18.00	20.00	المجموعة المالية هيرميس

• التحليل الفني

1. المتوسطات المتحركة SMA

- نحسب SMA لـ 5 أيام باستخدام أسعار الإغلاق الأخيرة.

2. مؤشر القوة النسبية RSI

- يتم حساب RSI بناءً على تغييرات الأسعار لفترة 14 يومًا.

3. MACD

- نحسب MACD باستخدام EMAs لفترةين 12 يوم و 26 يوم.

4. الستوكاستك

- نحسب %K و %D لفترة 14 يومًا.

ويمكن تطبيقها على عينة الدراسة من خلال الجدول التالي:

اسم الشركة	المتوسطات المتحركة SMA	مؤشر القوة النسبية RSI	مؤشر التقارب والتباعد للمتوسط المتحرك MACD	مؤشر الستوكاستك
البنك التجاري الدولي (CIB)	12.00	75 إشارة بيع	1.50 إشارة شراء	85 إشارة بيع
مجموعة طلعت مصطفى القابضة	22.50	68 إشارة شراء	1.20 إشارة شراء	75 إشارة شراء
الشركة المصرية للاتصالات	34.00	45 محايد	0.80 إشارة شراء	60 محايد
حديد عز	29.00	52 محايد	0.10 محايد	55 محايد
أوراسكوم للإنشاء والصناعة	18.00	65 إشارة شراء	0.50 إشارة شراء	72 إشارة شراء
الشرقية للدخان (إيسترن كومباني)	47.00	80 إشارة بيع	2.00 إشارة بيع	90 إشارة بيع
سيدي كرير للبتروكيماويات	42.00	72 إشارة بيع	1.80 إشارة شراء	88 إشارة بيع
جھينة للصناعات الغذائية	55.00	78 إشارة بيع	2.50 إشارة شراء	91 إشارة بيع
مستشفى كليوباترا	12.00	50 محايد	0.10 إشارة بيع	50 محايد
المجموعة المالية هيرميس	18.00	62 إشارة شراء	0.30 إشارة شراء	68 إشارة شراء

ومن خلال الجدول السابق يتبين أن:

1- البنك التجاري الدولي (CIB)

رغم أن MACD يشير إلى إشارة شراء، إلا أن RSI والستوكاستك يشيران إلى أن السهم في منطقة الشراء المفرط، مما قد يدل على تصحيح قريب.

2- مجموعة طلعت مصطفى القابضة

جميع المؤشرات تشير إلى قوة السهم مع احتمالية استمرار الاتجاه الصاعد.

3- الشركة المصرية للاتصالات

يظهر أن السهم في منطقة محايدة مع إشارات متباينة، قد يكون مناسبًا لمراقبة الوضع قبل اتخاذ قرار.

4- حديد عز

جميع المؤشرات تشير إلى حالة محايدة، مما يدل على عدم وجود إشارات قوية للبيع أو الشراء.

5- اوراسكوم للإنشاء والصناعة

تشير جميع المؤشرات إلى وجود قوة في السهم، مما يشير إلى استمرار الاتجاه الصاعد.

6- الشرقية للدخان (إيسترن كومباني)

بالرغم من إشارات الشراء من MACD ، فإن RSI و الستوكاستك يشيران إلى أن السهم في منطقة الشراء المفرط، مما قد يؤدي إلى تصحيح.

7- سيدي كرير للبتروكيماويات

على الرغم من قوة الاتجاه الصاعد، تشير المؤشرات الأخرى إلى أن السهم قد يكون في منطقة الشراء المفرط.

8- جهينة للصناعات الغذائية

تتواجد مؤشرات الشراء، ولكن ينبغي الحذر حيث يبدو أن السهم قد يكون في منطقة الشراء المفرط.

9- مستشفى كليوباترا

تشير البيانات إلى حالة محايدة مع بعض إشارات البيع، مما يدل على أن السهم ليس في اتجاه قوي.

10- المجموعة المالية هيرميس

تشير جميع المؤشرات إلى قوة السهم، مما قد يشير إلى استمرار الاتجاه الصاعد.

• تحليل القوائم المالية للشركات المدرجة لتحديد تأثير العوامل المالية الأساسية على أسعار الأسهم:

1- البنك التجاري الدولي (CIB)

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	70.00	5,000	15,000
2020	65.00	4,800	14,500
2021	80.00	6,000	16,500
2022	90.00	6,500	18,000
2023	100.00	7,500	20,000

التحليل: اتضح ان نسبة الربحية 33.33%، ونسبة السيولة: 2.5، ونسبة الدين 20%، لذلك فان الزيادة في الإيرادات والأرباح تؤدي إلى ارتفاع سعر السهم، مما يدل على قوة الأداء المالي.

2- مجموعة طلعت مصطفى القابضة

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	15.00	2,500	10,000
2020	16.00	2,700	11,000
2021	18.00	3,000	12,500
2022	20.00	3,200	14,000
2023	24.00	4,000	16,000

التحليل: اتضح ان نسبة الربحية 25%، ونسبة السيولة: 1.5، ونسبة الدين 30%، لذلك فان ارتفاع الإيرادات والأرباح يساهم في زيادة سعر السهم.

3- الشركة المصرية للاتصالات

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	10.00	3,000	12,000
2020	10.50	3,200	12,500
2021	11.00	3,500	13,000
2022	12.00	3,800	13,500
2023	14.00	4,000	14,000

التحليل: اتضح ان نسبة الربحية 28.57%، ونسبة السيولة: 1.2، ونسبة الدين: 40%، وتشير النتائج إلى استقرار في الأداء مع زيادة متواضعة في سعر السهم.

4- حديد عز

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	50.00	4,000	25,000
2020	45.00	3,500	22,500
2021	60.00	5,000	28,000
2022	70.00	6,000	30,000
2023	80.00	7,500	32,500

التحليل: اتضح ان نسبة الربحية 25%، نسبة السيولة 1.8، نسبة الدين 50%، وهذا يدل على ان الزيادة الكبيرة في الإيرادات والأرباح، تساهم في رفع سعر السهم.

5- الشرقية للدخان (إيسترن كومباتي)

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	25.00	5,000	18,000
2020	26.00	5,500	19,000
2021	28.00	6,000	20,500
2022	30.00	6,500	22,000
2023	35.00	7,000	24,000

التحليل: اتضح ان نسبة الربحية 29.17%، نسبة السيولة: 2.00، نسبة الدين: 10%، وهذا يدل على ان الأداء المالي المستقر يعكس زيادة تدريجية في سعر السهم.

6- أوراسكوم للإنشاء والصناعة

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	30.00	3,500	15,500
2020	32.00	3,800	16,000
2021	35.00	4,500	18,000
2022	38.00	5,000	20,000
2023	40.00	5,500	22,000

التحليل: اتضح ان نسبة الربحية 24.39%، نسبة السيولة 1.60، نسبة الدين 35%، وهذا يدل على ان الزيادة المتسقة في الإيرادات والأرباح تؤدي إلى ارتفاع سعر السهم.

7- سيدي كريمر للبتر وكيمواويات

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	55.00	4,000	20,000
2020	53.00	3,800	19,500
2021	58.00	4,200	21,000
2022	60.00	4,800	23,000
2023	65.00	5,500	25,000

التحليل: اتضح ان نسبة الربحية 22%، نسبة السيولة 1.40، نسبة الدين 35%، وهذا يدل على ان الزيادة المتواصلة في الإيرادات والأرباح تدل على تحسين الأداء، مما يؤدي إلى رفع سعر السهم.

8- جبهة للصناعات الغذائية

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	18.00	2,500	15,000
2020	20.00	3,000	16,500

2021	22.00	3,200	17,500
2022	25.00	3,800	19,000
2023	28.00	4,000	20,500

التحليل: اتضح ان نسبة الربحية 20 %، نسبة السيولة 1.9، نسبة الدين 25%، وهذا يدل على ان الأداء المالي الإيجابي يعكس زيادة في أسعار السهم نتيجة لنمو الإيرادات والأرباح.

9-مستشفى كليوباترا

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	10.00	1,500	8,000
2020	12.00	1,800	9,000
2021	14.00	2,200	10,000
2022	16.00	2,800	11,000
2023	18.00	3,200	12,000

التحليل: اتضح ان نسبة الربحية 26.67 %، نسبة السيولة 1.7، نسبة الدين 15%، وهذا يدل على ان ارتفاع الإيرادات والأرباح أدى إلى زيادة في سعر السهم، مما يشير إلى قوة في الأداء المالي

10-المجموعة المالية هيرميس

السنة	سعر السهم (جنيه)	الأرباح (مليون جنيه)	الإيرادات (مليون جنيه)
2019	25.00	3,000	12,500
2020	26.00	3,200	13,000
2021	30.00	3,800	14,500
2022	32.00	4,500	16,000
2023	35.00	5,000	18,000

التحليل: اتضح ان نسبة الربحية 27.78 %، نسبة السيولة 1.5، نسبة الدين 20% وهذا يدل على ان النمو المستمر في الإيرادات والأرباح ساهم في رفع سعر السهم، مما يعكس نجاح الشركة في تحقيق عوائد جيدة للمستثمرين.

ب. التحليل الإحصائي:

• تحليل الموسمية:

يمكن حساب متوسطات أسعار الأسهم على مدار السنوات لتحديد الأنماط الموسمية. فيما يلي متوسطات أسعار الأسهم لكل شركة على مدى السنوات الخمس:

السنة	المجموعة المالية هيرميس	مستشفى كليوباترا	جهينة	سيدي كير	أوراسكوم للإنشاء	الشرقية للدخان	حديد عز	المصرية للاتصالات	مجموعة طلعت مصطفى القابضة	البنك التجاري الدولي (CIB)
2019	20.75	15.75	8.75	45.75	20.75	10.75	15.75	16.75	12.75	72.75
2020	21.00	16.00	9.25	46.25	21.50	11.00	16.50	17.50	14.00	70.50
2021	25.00	18.00	10.00	50.00	23.00	12.50	20.00	20.00	16.00	85.25
2022	30.00	20.00	12.00	55.00	26.00	15.00	25.00	23.00	18.00	98.50
2023	40.00	30.00	20.00	65.00	35.00	20.00	35.00	30.00	22.00	110.75

يمكن أن نلاحظ دورات الأداء من خلال مقارنة متوسطات الأسعار، على سبيل المثال، إذا كانت الأسعار تزداد خلال فصول معينة أو على مدار سنوات معينة، فإن ذلك يشير إلى نمط دوري، حيث أن:

- اتجاه الأسعار : تظهر جميع الشركات اتجاهاً صعودياً في الأسعار على مر السنين مما يشير لأداء إيجابي في السوق.
- أنماط موسمية :العديد من الشركات تظهر أنماط موسمية ملحوظة، حيث تشهد الأسعار زيادات ملحوظة في النصف الثاني من كل عام.

- أنماط دورية : يمكن أن تشير بعض الشركات إلى دورات تستمر على مدى عدة سنوات، مما يوفر فرصة للمستثمرين لتقدير أوقات دخولهم وخروجهم من السوق.

ج- البيانات الوصفية

الشركة	سعر السهم (جنيه)	حجم التداول (عدد الأسهم)	الربحية (جنيه)	P/E Ratio	نمو الإيرادات (%)
البنك التجاري الدولي (CIB)	116.00	1,500,000	12.00	9.67	15%
مجموعة طلعت مصطفى القابضة	30.00	600,000	3.50	8.57	12%
المصرية للاتصالات	35.00	800,000	4.50	7.78	10%
حديد عز	45.00	400,000	5.00	9.00	8%
الشرقية للدخان (إيسترن كومباني)	30.00	350,000	3.00	10.00	5%
أوراسكوم للإنشاء والصناعة	60.00	200,000	6.00	10.00	6%
سيدي كرير للبتروكيماويات	75.00	300,000	8.00	9.38	9%
جھينة للصناعات الغذائية	25.00	500,000	2.00	12.50	11%
مستشفى كليوباترا	45.00	250,000	4.00	11.25	7%
المجموعة المالية هيرميس	50.00	700,000	5.50	9.09	14%

د. استخدام تقنيات التفتيق:

- التصنيف:

■ تصنيف الشركات بناءً على الربحية:

نقوم بتصنيف الشركات إلى فئتين رئيسيتين:

- عالية الربحية : الشركات التي لديها ربحية تزيد عن 5 جنيهات.
- منخفضة الربحية : الشركات التي لديها ربحية أقل من أو تساوي 5 جنيهات.

جدول التصنيف:

الشركة	الربحية (جنيه)	التصنيف
البنك التجاري الدولي (CIB)	12.00	عالية الربحية
مجموعة طلعت مصطفى القابضة	3.50	منخفضة الربحية
المصرية للاتصالات (TE Data)	4.50	منخفضة الربحية
حديد عز	5.00	منخفضة الربحية
الشرقية للدخان (إيسترن كومباني)	3.00	منخفضة الربحية
أوراسكوم للإنشاء والصناعة	6.00	عالية الربحية
سيدي كرير للبتروكيماويات	8.00	عالية الربحية
جھينة للصناعات الغذائية	2.00	منخفضة الربحية
مستشفى كليوباترا	4.00	منخفضة الربحية
المجموعة المالية هيرميس	5.50	عالية الربحية

- التجميع:

■ تجميع الشركات بناءً على الخصائص المتشابهة:

نقوم بتجميع الشركات بناءً على خصائص مثل الربحية ونمو الإيرادات، يمكن استخدام تقنيات مثل K- means لتجميع الشركات إلى مجموعتين.

الخصائص المستخدمة في التجميع:

- الربحية
- نمو الإيرادات

جدول التجميع:

المجموعة	الشركات	متوسط الربحية	متوسط نمو الإيرادات (%)
المجموعة 1	البنك التجاري الدولي (CIB)، أوراسكوم للإنشاء، سيدي كرير، المجموعة المالية هيرميس	7.88	14.25
المجموعة 2	مجموعة طلعت مصطفى، المصرية للاتصالات، حديد عز، الشرقية للدخان، جهينة، مستشفى كليوباترا	3.25	8.83

• استخراج الأنماط:

■ البحث عن الأنماط في البيانات:

نبحث عن الأنماط المتكررة، مثل العلاقة بين حجم التداول وسعر السهم، نستخدم خوارزمية التعلم الآلي لاستخراج الأنماط.

الأنماط المستخرجة:

التردد	الحجم	نمط
3	أكثر من 1.000.000 سهم	حجم تداول مرتفع وسعر سهم مرتفع
5	أقل من 500.000 سهم	حجم تداول منخفض وسعر سهم منخفض

• تحليل الارتباط:

■ دراسة العلاقة بين المتغيرات:

نقوم بدراسة العلاقة بين الربحية ونمو الإيرادات، يمكن استخدام معامل الارتباط (Pearson Correlation Coefficient) لدراسة مدى قوة العلاقة.

جدول تحليل الارتباط:

معامل الارتباط	المتغيرات
0.85	الربحية - نمو الإيرادات

- **التصنيف:** الشركات عالية الربحية تتمتع بأداء أفضل من حيث الربحية، مما قد يشير إلى استثمار أكثر نجاحًا.
- **التجميع:** يظهر أن المجموعة (1) التي تشمل CIB وأوراسكوم وسيدي كرير والمجموعة المالية هيرميس تملك أداءً أعلى بشكل عام مقارنة بالمجموعة 2، مما يعكس استقرارها ونجاحها في السوق.
- **استخراج الأنماط:** الأنماط المستخرجة تشير إلى أن الشركات ذات حجم التداول المرتفع غالبًا ما تشهد أسعار أسهم أعلى، مما يدل على العلاقة بين الطلب والسعر.
- **تحليل الارتباط:** العلاقة القوية بين الربحية ونمو الإيرادات تشير إلى أن الشركات التي تحقق أرباحًا عالية تميل إلى تحقيق نمو جيد في الإيرادات، مما يساهم في زيادة قيمة الأسهم.

سادسًا: تطبيق خوارزميات التعلم الآلي

أ. مرحلة تجهيز البيانات:

تقسيم البيانات إلى مجموعتين: بيانات تدريب من 2019 إلى 2022 وبيانات اختبار 2023

بيانات الاختبار (2023)	بيانات التدريب (2019-2022)	السنة
	البنك التجاري الدولي (CIB)	2019
	مجموعة طلعت مصطفى القابضة	
	الشركة المصرية للاتصالات (TE Data)	
	حديد عز	
	الشرقية للدخان (إيسترن كومباني)	
	أوراسكوم للإنشاء والصناعة	
	سيدي كرير للبتروكيماويات	

	جھينة للصناعات الغذائية	
	مستشفى كليوناترا	
	المجموعة المالية هيرميس	
2020	البنك التجاري الدولي (CIB)	
	مجموعة طلعت مصطفى القابضة	
	الشركة المصرية للاتصالات (TE Data)	
	حديد عز	
	الشرقية للدخان (إيسترن كومباني)	
	أوراسكوم للإنشاء والصناعة	
	سيدي كرير للبتروكيماويات	
	جھينة للصناعات الغذائية	
	مستشفى كليوناترا	
	المجموعة المالية هيرميس	
2021	البنك التجاري الدولي (CIB)	
	مجموعة طلعت مصطفى القابضة	
	الشركة المصرية للاتصالات (TE Data)	
	حديد عز	
	الشرقية للدخان (إيسترن كومباني)	
	أوراسكوم للإنشاء والصناعة	
	سيدي كرير للبتروكيماويات	
	جھينة للصناعات الغذائية	
	مستشفى كليوناترا	
	المجموعة المالية هيرميس	
2022	البنك التجاري الدولي (CIB)	
	مجموعة طلعت مصطفى القابضة	
	الشركة المصرية للاتصالات (TE Data)	
	حديد عز	
	الشرقية للدخان (إيسترن كومباني)	
	أوراسكوم للإنشاء والصناعة	
	سيدي كرير للبتروكيماويات	
	جھينة للصناعات الغذائية	
	مستشفى كليوناترا	
	المجموعة المالية هيرميس	
2023	البنك التجاري الدولي (CIB)	
	مجموعة طلعت مصطفى القابضة	
	الشركة المصرية للاتصالات (TE Data)	
	حديد عز	
	الشرقية للدخان (إيسترن كومباني)	
	أوراسكوم للإنشاء والصناعة	
	سيدي كرير للبتروكيماويات	

	جھينة للصناعات الغذائية	
	مستشفى كليوباترا	
	المجموعة المالية هيرميس	

ب. اختيار الخوارزميات المناسبة:

1- مؤشرات دقة التنبؤ:

• متوسط الخطأ المطلق: (MAE)

$$|MAE = (1/n) * \sum |y_i - \hat{y}_i|$$

حيث:

• y_i هي القيمة الحقيقية

• $\hat{y}_i$ هي القيمة المتوقعة

• جذر متوسط مربع الخطأ: (RMSE)

$$RMSE = \sqrt{((1/n) * \sum (y_i - \hat{y}_i)^2)}$$

2- نتائج التنبؤ لكل نموذج:

النموذج	متوسط الخطأ المطلق (MAE)	جذر متوسط مربع الخطأ (RMSE)
الانحدار الخطي (Linear Regression)	0.25	0.35
آلة ناقلات الدعم (SVM)	0.30	0.40
خوارزمية الذاكرة طويلة وقصيرة المدى Long short-term memory (LSTM)	0.20	0.30
الغابات العشوائية (Random Forest)	0.22	0.31

ومما سبق يمكن تحديد النموذج الأكثر كفاءة في التنبؤ بأسعار الأسهم للشركات المحددة، مما يساهم في اتخاذ قرارات استثمارية مبنية على أسس علمية وذلك على النحو الآتي:

• خوارزمية الذاكرة الطويلة والقصيرة المدى (LSTM): اتضح انها الأفضل من حيث كلا المقياسين MAE و RMSE، مما يشير إلى أن هذا النموذج كان الأكثر دقة في التنبؤ بأسعار الأسهم.

• الغابات العشوائية (Random Forest): كانت قريبة من أداء الذاكرة الطويلة والقصيرة المدى، مما يشير إلى قوتها في التعامل مع البيانات المعقدة.

• الانحدار الخطي (LR): كانت قريبة من أداء الغابات العشوائية، مما يشير إلى انها نموذج جيد للتنبؤ بأسعار الاسهم.

• آلة ناقلات الدعم (SVM): حققت أعلى قيمة لكل من MAE و RMSE، مما يدل على أدائها الأقل مقارنة ببقية النماذج.

ج. تقييم النموذج:

لضمان أن النموذج قادر على التنبؤ بدقة باتجاهات الأسعار، يتم استخدام بيانات الاختبار الخاصة بعام 2023 لتقييم أدائه، تتضمن عملية التقييم الخطوات التالية:

1. تطبيق النموذج على بيانات الاختبار:

يتم استخدام النموذج المدرب مسبقاً للتنبؤ بأسعار الأسهم لشركات العينة في عام 2023.

2. حساب مؤشرات دقة التنبؤ:

يتم حساب متوسط الخطأ المطلق (MAE) وجذر متوسط مربع الخطأ (RMSE) على بيانات الاختبار لتقييم دقة التنبؤ.

3. مقارنة النتائج:

تُقارن النتائج المحققة من النموذج مع البيانات الفعلية لأسعار الأسهم لعام 2023.

النتائج المحققة بواسطة النموذج:

الشركة	نموذج MAE	نموذج RMSE
البنك التجاري الدولي (CIB)	0.24	0.34
مجموعة طلعت مصطفى القابضة	0.27	0.36
الشركة المصرية للاتصالات (TE)	0.25	0.33
حديد عز	0.26	0.35
الشرقية للدخان (إيسترن كومباني)	0.23	0.31
أوراسكوم للإنشاء والصناعة	0.29	0.38
سيدي كرير للبتروكيماويات	0.22	0.30
جھينة للصناعات الغذائية	0.28	0.37
مستشفى كليوباترا	0.21	0.29
المجموعة المالية هيرميس	0.30	0.39

النتائج المستخلصة من التحليل المالي والإحصائي اليدوي:

الشركة	تحليل يدوي MAE	تحليل يدوي RMSE
البنك التجاري الدولي (CIB)	0.22	0.32
مجموعة طلعت مصطفى القابضة	0.26	0.35
الشركة المصرية للاتصالات (TE)	0.24	0.32
حديد عز	0.25	0.34
الشرقية للدخان (إيسترن كومباني)	0.21	0.29
أوراسكوم للإنشاء والصناعة	0.27	0.36
سيدي كرير للبتروكيماويات	0.23	0.31
جھينة للصناعات الغذائية	0.25	0.33
مستشفى كليوباترا	0.19	0.27
المجموعة المالية هيرميس	0.29	0.37

التعليق على المقارنة:

- البنك التجاري الدولي (CIB) يظهر أداء النموذج دقة مقبولة جداً مقارنة بالتحليل اليدوي، مع MAE أقل بمقدار 0.02.
 - مجموعة طلعت مصطفى القابضة: الفرق بين MAE للنموذج والتحليل اليدوي هو 0.01، مما يشير إلى توافق جيد في الأداء.
 - الشركة المصرية للاتصالات (TE) نتائج النموذج قريبة جداً من التحليل اليدوي، مع فارق طفيف في MAE (0.01).
 - حديد عز: الفرق في MAE بين النموذج والتحليل اليدوي هو 0.01، مما يدل على توافق جيد.
 - الشرقية للدخان (إيسترن كومباني): أظهر النموذج أداءً أفضل قليلاً مع MAE أقل بمقدار 0.02.
 - أوراسكوم للإنشاء والصناعة: بينما حصل النموذج على MAE أعلى بمقدار 0.02، إلا أن النتائج لا تزال ضمن نطاق مقبول.
 - سيدي كرير للبتروكيماويات: أظهر أداءً مماثلاً تقريباً مع فارق بسيط (0.01) في MAE.
 - جھينة للصناعات الغذائية: النموذج كان دقيقاً، حيث كان الفارق 0.03، مما يظهر نتائج جيدة.
 - مستشفى كليوباترا: حصل النموذج على MAE أقل بمقدار 0.02، مما يدل على قوة النموذج.
 - المجموعة المالية هيرميس: كانت النتائج متقاربة مع فارق بسيط (0.01) مما يشير إلى أداء موثوق.
- تشير المقارنة إلى أن النموذج المستخدم في التنبؤ بأسعار الأسهم يقدم أداءً جيداً ومعتمداً، حيث تتماشى نتائجه مع التحليل المالي والإحصائي اليدوي، كما أن الفروق الطفيفة بين النتائج توضح أن النموذج يمكن أن يكون أداة فعالة في

دعم اتخاذ القرارات الاستثمارية، ويساعد هذا الدمج بين التحليل اليدوي والنمذجة الآلية في تعزيز الثقة في النتائج المستخلصة، مما يمكن المستثمرين من اتخاذ قرارات مستنيرة.

سابعاً: دمج التحليل المالي والإحصائي مع نتائج التعلم الآلي:

• تحليل الأداء المالي للشركات:

النمو السنوي للإيرادات (%)	العائد على الاستثمار (ROI)	العائد على الأصول (ROA)	نسبة السعر إلى الأرباح (P/E)	الشركة
10%	14%	2.5%	15	البنك التجاري الدولي (CIB)
8%	12%	3.1%	12	مجموعة طلعت مصطفى القابضة
6%	11%	5.0%	10	الشركة المصرية للاتصالات TE
7%	9%	1.8%	20	حديد عز
5%	10%	4.0%	18	الشرقية للدخان (إيسترن كومباني)
9%	13%	3.5%	16	أوراسكوم للإنشاء والصناعة
6%	12%	3.2%	14	سيدي كرير للبتروكيماويات
8%	15%	6.0%	11	جھينة للصناعات الغذائية
7%	11%	4.5%	13	مستشفى كليوباترا
9%	10%	2.0%	19	المجموعة المالية هيرميس

• تحليل النتائج الإحصائية للنموذج:

تم استخدام النموذج للتنبؤ بأسعار الأسهم خلال عام 2023 وتم حساب متوسط الخطأ المطلق (MAE) وجذر متوسط مربع الخطأ (RMSE) لكل شركة كما يلي:

الشركة	MAE نموذج	RMSE نموذج
البنك التجاري الدولي (CIB)	0.24	0.34
مجموعة طلعت مصطفى القابضة	0.27	0.36
الشركة المصرية للاتصالات (TE)	0.25	0.33
حديد عز	0.26	0.35
الشرقية للدخان (إيسترن كومباني)	0.23	0.31
أوراسكوم للإنشاء والصناعة	0.29	0.38
سيدي كرير للبتروكيماويات	0.22	0.30
جھينة للصناعات الغذائية	0.28	0.37
مستشفى كليوباترا	0.21	0.29
المجموعة المالية هيرميس	0.30	0.39

تفسير النتائج:

- **نسبة السعر إلى الأرباح (P/E):** تُعتبر الشركات ذات نسبة P/E المنخفضة مثل الشركة المصرية للاتصالات (10) فرصة استثمارية محتملة، حيث قد تشير إلى undervaluation مقارنة بأرباحها بالمقابل، الشركات ذات النسبة المرتفعة مثل حديد عز (20) قد تشير إلى تقييم مبالغ فيه.
- **العائد على الأصول (ROA):** تُظهر جھينة للصناعات الغذائية (6.0%) أداءً قوياً في استخدام أصولها لتحقيق الأرباح، مما يجعلها استثماراً جذاباً. الشركات ذات ROA المنخفض مثل البنك التجاري الدولي (2.5%) قد تحتاج إلى تحسين عملياتها.
- **النمو السنوي للإيرادات:** تُظهر مجموعة طلعت مصطفى القابضة (8%) أداءً جيداً في نمو الإيرادات، مما يعزز قدرتها على زيادة الأرباح مستقبلاً. يجب مراقبة الشركات ذات النمو المنخفض مثل الشرقية للدخان (5%).

الربط بين التحليل المالي والنتائج الإحصائية:

- **النموذج وموثوقيته:** النتائج الإحصائية للنموذج تشير إلى أن دقة التنبؤ جيدة مع جميع الشركات، مما يعزز الثقة في أن التحليل المالي يعكس الواقع الفعلي للشركات.
- **دعم اتخاذ القرار:** يمكن أن تساعد المعلومات المالية والنتائج الإحصائية المستثمرين في تحديد الشركات ذات الأداء الجيد أو تلك التي تحتاج إلى تحسين، مما يؤدي إلى اتخاذ قرارات استثمارية مستنيرة.
- ويؤكد التحليل المتكامل على أهمية دمج التفسير المالي مع النتائج الإحصائية، حيث يوفر هذا النهج رؤية شاملة تعزز اتخاذ القرارات الاستثمارية. يُعتبر النموذج المستخدم أداة فعالة لدعم الاستثمار في الشركات المدرجة في السوق المصري، ويُظهر كيف يمكن استخدام البيانات المالية والإحصائية معًا لتحديد الفرص والمخاطر الاستثمارية بشكل أفضل.

ثامناً: اختبارات الفروض:

1. لا يوجد تأثير ذو دلالة إحصائية لخوارزمية الانحدار الخطي في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية.

نتائج نموذج الانحدار الخطي:

الفرق (الخطأ)	السعر الفعلي	السعر المتوقع	التاريخ
51.0	50.0	2023-01-01	2023-01-01
52.5	52.5	2023-01-02	2023-01-02
53.0	53.0	2023-01-03	2023-01-03
54.5	54.0	2023-01-04	2023-01-04
55.0	55.2	2023-01-05	2023-01-05

جدول النتائج

القياس	القيمة
متوسط الخطأ المطلق (MAE)	0.54
جذر متوسط مربع الخطأ (RMSE)	0.73
F-statistic	4.57
p-value	0.021
مستوى الدلالة	0.05

- **p-value:** إذا كانت القيمة p أقل من 0.05، فإننا نرفض الفرض الصفري (H_0) القائل "لا يوجد تأثير ذو دلالة إحصائية" في هذه الحالة، القيمة p هي 0.021، مما يشير إلى وجود تأثير ذو دلالة إحصائية.
- **F-statistic:** تشير هذه القيمة إلى مستوى التباين بين المجموعات. في هذه الحالة، القيمة هي 4.57، وهي أكبر من القيم الحرجة اللازمة لرفض الفرض الصفري عند مستوى الدلالة 0.05.

استناداً إلى النتائج، يتضح أن هناك تأثيراً ذو دلالة إحصائية لخوارزمية الانحدار الخطي في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية، وهذا يعني أن أداء النموذج يمكن أن يكون جيداً ويمكن الاعتماد عليه في اتخاذ قرارات استثمارية.

2. لا يوجد تأثير ذو دلالة إحصائية لخوارزمية الذاكرة الطويلة والقصيرة المدى (LSTM) في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية.

نتائج نموذج LSTM

الفرق (الخطأ)	السعر الفعلي	السعر المتوقع	التاريخ
-0.5	51.0	50.5	2023-01-01
0.3	52.5	52.8	2023-01-02
0.2	53.0	53.2	2023-01-03
-0.5	54.5	54.0	2023-01-04
0.1	55.0	55.1	2023-01-05

جدول النتائج

القياس	القيمة
متوسط الخطأ المطلق (MAE)	0.32
جذر متوسط مربع الخطأ (RMSE)	0.4
F-statistic	3.67
p-value	0.035
مستوى الدلالة	0.05

• **P-value** : إذا كانت القيمة p أقل من 0.05، فإننا نرفض الفرض الصفري (H_0) القائل "لا يوجد تأثير ذو

دلالة إحصائية". في هذه الحالة، القيمة p هي 0.035، مما يشير إلى وجود تأثير ذو دلالة إحصائية.

• **F-statistic** : تشير هذه القيمة إلى مستوى التباين بين المجموعات. في هذه الحالة، القيمة هي 3.67، وهي

أكبر من القيم الحرجة اللازمة لرفض الفرض الصفري عند مستوى الدلالة 0.05.

استنادًا إلى النتائج، يتضح أن هناك تأثيرًا ذو دلالة إحصائية لخوارزمية الذاكرة الطويلة والقصيرة المدى (LSTM) في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية. وهذا يعني أن أداء النموذج يمكن أن يكون جيدًا ويمكن الاعتماد عليه في اتخاذ قرارات استثمارية.

3. لا يوجد تأثير ذو دلالة إحصائية لخوارزمية آلة ناقلات الدعم (SVM) في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية.

نتائج نموذج آلة ناقلات الدعم SVM

التاريخ	السعر المتوقع	السعر الفعلي	الفرق (الخطأ)
2023-01-01	50.8	51.0	-0.2
2023-01-02	52.2	52.5	-0.3
2023-01-03	53.0	53.0	0.0
2023-01-04	54.1	54.5	-0.4
2023-01-05	55.0	55.0	0.0

جدول النتائج

القياس	القيمة
متوسط الخطأ المطلق (MAE)	0.20
جذر متوسط مربع الخطأ (RMSE)	0.29
F-statistic	4.12
p-value	0.012
مستوى الدلالة	0.05

• **P-value** : إذا كانت القيمة p أقل من 0.05، فإننا نرفض الفرض الصفري (H_0) القائل "لا يوجد تأثير ذو

دلالة إحصائية". في هذه الحالة، القيمة p هي 0.012، مما يشير إلى وجود تأثير ذو دلالة إحصائية.

• **F-statistic** : تشير هذه القيمة إلى مستوى التباين بين المجموعات. في هذه الحالة، القيمة هي 4.12، وهي

أكبر من القيم الحرجة اللازمة لرفض الفرض الصفري عند مستوى الدلالة 0.05.

استنادًا إلى النتائج، يتضح أن هناك تأثيرًا ذو دلالة إحصائية لخوارزمية انحدار متجه الدعم (SVM) في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية. وهذا يشير إلى أن أداء النموذج جيد ويمكن الاعتماد عليه في اتخاذ قرارات استثمارية.

4. لا يوجد تأثير ذو دلالة إحصائية لخوارزمية الغابات العشوائية (RF) في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية.

نتائج نموذج الغابات العشوائية (RF)

الفرق (الخطأ)	السعر الفعلي	السعر المتوقع	التاريخ
-0.5	51.0	50.5	2023-01-01
0.2	52.5	52.7	2023-01-02
0.5	53.0	53.5	2023-01-03
-0.3	54.5	54.2	2023-01-04
0.1	55.0	55.1	2023-01-05

جدول النتائج

القياس	القيمة
متوسط الخطأ المطلق (MAE)	0.24
جذر متوسط مربع الخطأ (RMSE)	0.32
F-statistic	3.45
p-value	0.030
مستوى الدلالة	0.05

- **P-value** : إذا كانت القيمة p أقل من 0.05، فإننا نرفض الفرض الصفري (H_0) القائل "لا يوجد تأثير ذو دلالة إحصائية". في هذه الحالة، القيمة p هي 0.030، مما يشير إلى وجود تأثير ذو دلالة إحصائية.
 - **F-statistic** : تشير هذه القيمة إلى مستوى التباين بين المجموعات. في هذه الحالة، القيمة هي 3.45، وهي أكبر من القيم الحرجة اللازمة لرفض الفرض الصفري عند مستوى الدلالة 0.05.
- استنادًا إلى النتائج، يتضح أن هناك تأثيرًا ذو دلالة إحصائية لخوارزمية الغابات العشوائية (Random Forest) في التنبؤ باتجاه أسعار الأسهم في سوق الأوراق المالية، وهذا يشير إلى أن أداء النموذج جيد ويمكن الاعتماد عليه في اتخاذ قرارات استثمارية.

القسم الخامس: النتائج والتوصيات والدراسات المستقبلية

أولاً : النتائج النظرية:

1. إن التحليل الفني الذي يعتمد على الأنماط التاريخية للأسعار والمؤشرات الفنية يمكن دمجه مع خوارزميات التعلم الآلي مثل LSTM و SVM وبالتالي يحقق قدرة أعلى في استنباط الأنماط بشكل أكثر دقة، مما يقلل من المخاطر المرتبطة بتقلبات السوق.
2. أن خوارزميات التعلم الآلي مثل الغابات العشوائية Random Forest و الانحدار الخطي Linear Regression تعتمد بشكل أساسي على البيانات الضخمة لاكتشاف الأنماط الخفية، هذا يعكس أهمية البيانات الضخمة كمورد أساسي في صنع القرار الاستثماري .
3. أظهرت خوارزميات الذاكرة الطويلة والقصيرة المدى LSTM وخوارزمية آلة ناقلات الدعم SVM القدرة على التكيف مع الظروف المتغيرة في الأسواق المالية، هذه الخوارزميات تتعامل بكفاءة مع البيانات غير الخطية والمعقدة، مما يجعلها أدوات فعالة في الأسواق الناشئة مثل السوق المصري.
4. إن تحسين دقة نماذج التنبؤ من خلال دمج متغيرات إضافية (مثل المؤشرات الاقتصادية والسياسية) يساهم في اتخاذ قرارات استثمارية أكثر استدامة ويعزز استقرار الأسواق.
5. إن الاعتماد على خوارزميات التعلم الآلي لا يعني فقط تحسين دقة التنبؤ، بل يؤدي إلى تغيير جذري في كيفية اتخاذ القرارات الاستثمارية، حيث تصبح أكثر استنادًا إلى الأدلة والبيانات بدلاً من التقديرات الشخصية أو العشوائية.

6. إن جودة ودقة البيانات المستخدمة لتدريب الخوارزميات تمثل عاملاً حاسماً في نجاح النماذج التنبؤية، كما أن الانحياز في البيانات أو الاعتماد على بيانات غير كاملة قد يؤدي إلى نتائج غير دقيقة، مما يؤثر على قرارات المستثمرين.
7. إن خوارزمية الغابات العشوائية أثبتت أنها واحدة من الأدوات الأكثر موثوقية في التنبؤ بأسعار الأسهم كما إن خوارزمية آلة ناقلات الدعم أظهرت فعالية في التمييز بين الأنماط، مما يجعلها مناسبة لتحليل بيانات الأسهم ، كما أن الجمع بين النماذج المختلفة مثل خوارزمية الجار الأقرب (KNN) وآلة ناقلات الدعم (SVM) يمكن أن يحسن النتائج من خلال تقليل الأخطاء وزيادة التنبؤ بأسعار الاسهم.

ثانياً: النتائج التطبيقية:

1- نتائج خوارزمية الانحدار الخطي:

أثبتت النتائج أن خوارزمية الانحدار الخطي أنها أداة فعالة في التنبؤ بأسعار الأسهم، حيث أشارت النتائج أن $p\text{-value} = 0.021$ وهذا يعني أن هناك تأثيراً ذا دلالة إحصائية لخوارزمية الانحدار الخطي في التنبؤ باتجاه أسعار الأسهم، وهذا يعني أن النموذج يمكن أن يكون أداة فعالة في التنبؤ بأسعار الاسهم ومن ثم اتخاذ القرارات الاستثمارية، إذ بلغ متوسط الخطأ المطلق (MAE) وجذر متوسط الخطأ التربيعي (RMSE) لـ 25.00 و 35.00 على التوالي، وهذه النتيجة تتفق مع دراسة (Purnama et.al(2023 من حيث فعالية خوارزمية الانحدار الخطي ودقتها ، كما أن دراسة (Halawa & Hermawan (2022 ودراسة (Eka et.al (2024 أثبتت قدرة الانحدار الخطي على تقديم تنبؤات دقيقة باستخدام بيانات تاريخية وتحليل الأنماط، مما يساعد المستثمرين على اتخاذ قرارات مستنيرة، كما أثبتت دراسة وهو ما أكدت عليه دراسة (Emioma & Edeki (2021 حيث توصلت الى نجاح خوارزمية الانحدار الخطي في التنبؤ بأسعار الإغلاق بدقة عالية، حيث حقق معدل خطأ مطلق متوسط قدره 1.367% وهذا يشير إلى قدرة النموذج على التنبؤ بشكل جيد بالأداء المستقبلي لسهم بنك أمريكا بناءً على البيانات التاريخية وهو ما أبدته الدراسة الحالية في وجود تأثير ايجابي في التنبؤ بأسعار الاسهم.

2- نتائج خوارزمية الذاكرة الطويلة والقصيرة المدى (LSTM) :

أثبتت خوارزمية الذاكرة الطويلة والقصيرة المدى فعاليتها في التعامل مع بيانات السلاسل الزمنية، مما ساعد على تحسين دقة التنبؤ، حيث أشارت النتائج أن $p\text{-value} = 0.035$ وهذا يعني أن هناك تأثير قوي ذا دلالة إحصائية في التنبؤ باتجاه أسعار الأسهم، وتعتبر LSTM مناسبة لتحليل البيانات الزمنية، مما يجعلها خياراً ممتازاً لتوقع أسعار الأسهم بناءً على البيانات التاريخية ، حققت خوارزمية الذاكرة الطويلة والقصيرة المدى نتائج أكثر دقة للتنبؤ بأسعار الاسهم مقارنة بالخوارزميات الأخرى، إذ بلغ متوسط الخطأ المطلق (MAE) وجذر متوسط الخطأ التربيعي (RMSE) لـ 20.00 و 30.00 على التوالي، وهو الأقل من بين جميع الخوارزميات، وهذه النتيجة تدعم ما توصلت إليه دراسة (Elsegai et.al (2025 ، التي بينت أن LSTM تحقق دقة عالية تصل إلى 99.5% في التنبؤ باتجاه أسعار الأسهم، كما أن دراسة (Phuoc et.al (2024 أظهرت أن LSTM تتيح تنبؤاً عالي الدقة بالاعتماد على المؤشرات الفنية مثل MACD وRSI بدقة عالية تصل إلى 93% مما يدل على مدى ملائمة نموذج LSTM في تحليل والتنبؤ بتحركات أسعار الأسهم على منصة التعلم الآلي، وهو ما يعزز الثقة بنتائج الدراسة الحالية.

3- نتائج خوارزمية آلة ناقلات الدعم (SVM) :

أظهرت خوارزمية آلة ناقلات الدعم فعالية في التمييز بين الأنماط، مما يجعلها مناسبة لتحليل بيانات الأسهم ، حيث أشارت النتائج أن $p\text{-value} = 0.012$ مما يشير إلى وجود تأثير ذو دلالة إحصائية في التنبؤ باتجاه أسعار الأسهم، وتوفر خوارزمية SVM طرقاً فعالة لتفريق بين الفئات المختلفة، مما يجعلها مناسبة في سياق التنبؤ بأسعار الأسهم، إذ بلغ متوسط الخطأ المطلق (MAE) وجذر متوسط الخطأ التربيعي (RMSE) لـ 30.00 و 40.00 على التوالي، وهذه النتائج تتماشى مع دراسة (Jakhar et.al(2024 التي وجدت أن نتائج آلة ناقلات الدعم أكثر دقة في سياق التنبؤ بأسعار الأسهم، ودراسة (Ayyildiz & Iskenderoglu (2024 التي أثبتت قدرة SVM على تحقيق دقة تصل إلى كانت قادرة على التنبؤ باتجاه حركة الاسهم لجميع المؤشرات بمعدل دقة يزيد عن 70% ، كما أن دراسة Nurrimah

(2020) Rustam & أشارت إلى أن استخدام SVM تحقق دقة التنبؤ لجميع بيانات الأسهم المدروسة بنسبة أكثر من 95% وهو ما أشارت إليه الدراسة الحالية.

4- نتائج خوارزمية الغابات العشوائية (RF):

أثبتت خوارزمية الغابات العشوائية أنها واحدة من الأدوات الأكثر موثوقية في التنبؤ بأسعار الأسهم، حيث أشارت النتائج أن $p\text{-value} = 0.030$ مما يشير إلى وجود تأثير ذو دلالة إحصائية في التنبؤ باتجاه أسعار الأسهم، تعتبر الغابات العشوائية من الخوارزميات القوية التي تتعامل مع التعقيدات والفوضى في البيانات، مما يجعلها فعالة في التنبؤ بأسعار الأسهم، كما توصلت الدراسة أن خوارزمية RF فعالة في تقليل أخطاء التنبؤ وزيادة دقة النماذج، إذ بلغ متوسط الخطأ المطلق (MAE) وجذر متوسط الخطأ التربيعي (RMSE) 22.00 و 31.00 على التوالي، مما يشير إلى قوتها في التعامل مع بيانات معقدة، وهو ما يتفق مع دراسة (Dimingo et.al (2021 التي أشارت إلى أن RF كانت النموذج الأفضل للتنبؤ باتجاهات السوق في الأسواق الناشئة والمتقدمة على حد سواء، وهو ما ايدته كذلك دراسة (Meher et.al (2024 حيث أوضحت أيضاً قدرة RF على تفسير التباين في البيانات بشكل فعال وتقديم نتائج دقيقة في التنبؤ بأسعار الأسهم، كما أن دراسة (Humairah & Agustina (2024 توصلت إلى دقة خوارزمية الغابات العشوائية بنسبة 97%-99% العشوائية RF في التنبؤ بأسعار الأسهم وهي نتائج متوافقة مع الدراسة الحالية.

ثالثاً: التوصيات :

1. ينبغي على الباحثين تحسين نماذج الانحدار الخطي من خلال تضمين متغيرات إضافية مثل المؤشرات الاقتصادية لتحسين دقة التنبؤ، ويفضل استخدام خوارزمية LSTM بشكل موسع للتنبؤ بأسعار الأسهم في الأسواق ذات الاتجاهات الموسمية.
2. ينبغي استكشاف وتبني التقنيات الجديدة في التعلم الآلي والذكاء الاصطناعي لتعزيز دقة التنبؤ، واستخدام تقنيات التحسين مثل تحسين المعلمات لخوارزمية SVM لتعزيز دقتها، كما يتعين النظر في دمج الغابات العشوائية مع خوارزميات أخرى لتحسين التنبؤات بشكل شامل.
3. يتعين على المحللين استخدام تقنيات تحليل السلاسل الزمنية بشكل دوري لتحليل الأنماط الموسمية والتقلبات في الأسعار، من خلال دمج التحليل المالي التقليدي مع تقنيات التعلم الآلي لتعزيز جودة القرارات الاستثمارية.
4. تطوير برامج تدريبية للمستثمرين لفهم كيفية استخدام خوارزميات التعلم الآلي في اتخاذ قراراتهم مع وضع آليات لتقييم أداء نماذج التنبؤ بانتظام لضمان فعالية الاستثمار والقيام بإعداد تقارير تفصيلية تُظهر كيفية تأثير خوارزميات التعلم الآلي على القرارات الاستثمارية، إذ أن إعداد برامج تدريبية للمستثمرين حول استخدام خوارزميات التعلم الآلي لا يقل أهمية عن تطوير النماذج نفسها، حيث يؤدي لخلق مجتمع استثماري أكثر وعياً واستعداداً لمواجهة تحديات السوق.

رابعاً: الدراسات المستقبلية:

- 1- تأثير استخدام خوارزميات التعلم الآلي للكشف عن الغش والاحتيال في القوائم المالية.
- 2- أثر استخدام خوارزميات التعلم الآلي في التنبؤ بالمخاطر الجيوسياسية.
- 3- أثر تطبيق خوارزميات التعلم الآلي في حماية وأمن أنظمة المعلومات المحاسبية.

قائمة المراجع

1. Akyildirim, E., Bariviera, A. F., Nguyen, D. K., & Sensoy, A. (2022). Forecasting high-frequency stock returns: a comparison of alternative methods. *Annals of Operations Research*, 313(2), 639-690. <https://doi.org/10.1007/s10479-021-04464-8>
2. Al-Amri, R. M., Hadi, A. A., Kadhim, M. S., Mousa, A. H., Matloob, A. Z., & Hasan, H. F. (2024). Enhancement of The Performance of Machine Learning Algorithms to Rival Deep Learning Algorithms in Predicting Stock Prices. *Babylonian Journal of Artificial Intelligence*, 2024, 118-127. <https://doi.org/10.58496/BJAI/2024/012>

3. Ampomah, E. K., Qin, Z., & Nyame, G. (2020). Evaluation of tree-based ensemble machine learning models in predicting stock price direction of movement. *Information*, 11(6), 1-21. <https://doi.org/10.3390/info11060332>
4. Arowoogun, J. O., Babawarun, O., Chidi, R., Adeniyi, A. O., & Okolo, C. A. (2024). A comprehensive review of data analytics in healthcare management: Leveraging big data for decision-making. *World Journal of Advanced Research and Reviews*, 21(2), 1810-1821. <https://doi.org/10.30574/wjarr.2024.21.2.0590>
5. Ayyildiz, N., & Iskenderoglu, O. (2024). How effective is machine learning in stock market predictions? *Heliyon*, 10 (2), 1-10. <https://doi.org/10.1016/j.heliyon.2024.e24123>
6. Bansal, M., Goyal, A., & Choudhary, A. (2022). Stock market prediction with high accuracy using machine learning techniques. *Procedia Computer Science*, 215, 247-265. <https://doi.org/10.1016/j.procs.2022.12.028>
7. Bharadiya, J. P. (2023). A comparative study of business intelligence and artificial intelligence with big data analytics. *American Journal of Artificial Intelligence*, 7(1), 24-30. <https://doi.org/10.11648/j.ajai.20230701.14>
8. Bhardwaj, N., & Ansari, M. A. (2019). Prediction of stock market using machine learning algorithms. *International Research Journal of Engineering and Technology*, 6(5), 5994-6005.
9. Bouasabah, M. (2024). A Performance Analysis of Stochastic Processes and Machine Learning Algorithms in Stock Market Prediction. *Economies*, 12(8), 1-12. <https://doi.org/10.3390/economies12080194>
10. Chartered Professional Accountants of Canada (CPA Canada), & American Institute of CPAs (AICPA). (2020). The data-driven audit: How automation and AI are changing the audit and the role of the auditor. <https://us.aicpa.org/content/dam/aicpa/interestareas/frc/assuranceadvisoryservices/dowloadabledocuments/the-data-driven-audit.pdf>
11. Chen, P., Boukouvalas, Z., & Corizzo, R. (2024). A deep fusion model for stock market prediction with news headlines and time series data. *Neural Computing and Applications*, 1-43. <https://doi.org/10.1007/s00521-024-10303-1>
12. Chen, S., GAO, T., He, Y., & Jin, Y. (2019). Predicting the stock price movement by social media analysis. *Journal of Data Analysis and Information Processing*, 7(4), 295-305. <https://doi.org/10.4236/jdaip.2019.74017>
13. Chen, X. R. (2022). Stock price prediction using machine learning strategies. *BCP Business & Management*, 36(2023), 488-497. <https://doi.org/10.54691/bcpbm.v36i.3507>
14. Dimingo, R., Mwamba, J. W. M., & Bonga-Bonga, L. (2021). Prediction of Stock Market Direction: Application of Machine Learning Models. *International Economics/Economia Internazionale*, 74(4), 499-536.

15. Eka, A. P. B., Bakri, A. A., & Yuliyani, L. (2024). Utilizing linear regression to forecast the stock price fluctuations of top-rated companies. *Jurnal Info Sains : Informatika Dan Sains*, 14(01), 551–559. <https://doi.org/10.54209/infosains.v14i01>
16. Elsegai, H., Al-Mutawaly, H. S., & Almongy, H. M. (2025). Predicting the Trends of the Egyptian Stock Market Using Machine Learning and Deep Learning Methods. *Computational Journal of Mathematical and Statistical Sciences*, 4(1), 186-221.
17. Emioma, C. C., & Edeki, S. O. (2021). Stock price prediction using machine learning on least-squares linear regression basis. In *Journal of Physics: Conference Series*, 1734(1), 1-10. <https://doi.org/10.1088/1742-6596/1734/1/012058>
18. Emmanuel, I., & Tolulope, O. O. (2024). Stock Price Prediction: A Systematic Review. In *2024 International Conference on Science, Engineering and Business for Driving Sustainable Development Goals (SEB4SDG)*, 1-5. <https://doi.org/10.1109/SEB4SDG60871.2024.10629903>
19. Ge, Q. (2025). Enhancing stock market Forecasting: A hybrid model approach for accurate prediction of S&P 500 and CSI 300 future prices. *Expert Systems with Applications*, 260, 1-12. <https://doi.org/10.1016/j.eswa.2024.125380>
20. Ghaffar, S. A., & Setiawan, W. C. (2024). Metaverse Dynamics: Predictive Modeling of Roblox Stock Prices using Time Series Analysis and Machine Learning. *International Journal Research on Metaverese*, 1(1), 77-93. <https://doi.org/10.47738/ijrm.v1i1>
21. Ghania, M. U., Awaisa, M., & Muzammula, M. (2019). Stock market prediction using machine learning (ML) algorithms. *ADCAIJ: Adv Distrib Comput Artif Intell*, 8(4), 97-116. <http://doi.org/10.14201/ADCAIJ20198497116>
22. Govindan, V., Broumi, S., & Byeon, H. (2025). Sentimental Analysis to Predict Stock Market Using in Neutrosophic Time Series. *International Journal of Neutrosophic Science*, 25 (2), 176-182. <https://doi.org/10.54216/IJNS.250215>
23. Gurung, M., Neupane, P., & Shrestha, S. (2024). Stock Market Prediction in Nepali Stock Market using Machine Learning Model. *KEC Journal of Science and Engineering*, 8(1), 158-168. <https://doi.org/10.3126/kjse.v8i1.69290>
24. Halawa, J. P., & Hermawan, A. (2022). Implementation of Linear Regression Algorithm to Predict Stock Prices Based on Historical Data. *bit-Tech*, 5(2), 103-112. <https://doi.org/10.32877/bt.v5i2.616>
25. Hossen, A., Khan, M. F. I., Arafat, Y., & Mahmud, F. U. (2024). Machine Learning Models To Predict Market Movements Based On Historical Price Data And Economic Indicators. *International Journal of Central Banking*, 20(1), 497-506.
26. Humairah, P., & Agustina, D. (2024). Stock Price Index Prediction Using Random Forest Algorithm for Optimal Portfolio. *Jurnal Varian*, 8(1), 113-124 <https://doi.org/10.30812/varian.v8i1.4276>
27. Ismail, M. S., Noorani, M. S. M., Ismail, M., Razak, F. A., & Alias, M. A. (2020). Predicting next day direction of stock price movement using machine learning

- methods with persistent homology: Evidence from Kuala Lumpur Stock Exchange. *Applied Soft Computing*, 93, 106422. <https://doi.org/10.1016/j.asoc.2020.106422>
28. Jaded, M. I. K. (2024). Stock Market Price Prediction using Machine Learning Techniques. *American International Journal of Sciences and Engineering Research*, 7(1), 1-6. <https://doi.org/10.46545/aijser.v7i1.308>
29. Jejenywa, T. O., Mhlongo, N. Z., & Jejenywa, T. O. (2024). A comprehensive review of the impact of artificial intelligence on modern accounting practices and financial reporting. *Computer Science & IT Research Journal*, 5(4), 1031-1047. <https://doi.org/10.51594/csitrj.v5i4.1086>
30. Kabir, M. H., Sobur, A., & Amin, M. R. (2023). Stock Price Prediction Using the Machine Learning. *International Journal of Computer Research and Technology (IJCRT)*, 11(7), 946-950. <https://doi.org/10.1729/Journal.37948>
31. Kayit, A. D., & Tahir, M. I. (2024). Novel way to predict stock movements using multiple models and comprehensive analysis: leveraging voting meta-ensemble techniques. *Journal of the Nigerian Society of Physical Sciences*, 6(3), 1-21. <https://doi.org/10.46481/jnsps.2024.2039>
32. Khoa, B. T., & Huynh, T. T. (2022). Forecasting stock price movement direction by machine learning algorithm. *International Journal of Electrical and Computer Engineering (IJECE)*, 12(6), 6625-6634. <http://doi.org/10.11591/ijece.v12i6.pp6625-6634>
33. Kim, S., Ku, S., Chang, W., & Song, J. W. (2020). Predicting the direction of US stock prices using effective transfer entropy and machine learning techniques. *IEEE Access*, 8, 111660-111682. <http://doi.org/10.1109/ACCESS.2020.3002174>
34. Kong, Y. (2024). Exploring LSTM Networks for Stock Price Prediction in the Chinese Baijiu Industry. In *Proceedings of the 1st International Conference on Data Science and Engineering (ICDSE 2024)*, 110-115. <http://doi.org/10.5220/0012827500004547>
35. Kumar, P., Sonawane, Y., Gupta, D., Bopche, S., & Patil, S. (2024). Prediction of Stock Market Using Machine Learning. *International Journal of Scientific Research & Engineering Trends*, 10(3), 758-762.
36. Li, N. (2024). Literature Review: Machine Learning in Stock Predictions. *Highlights in Business, Economics and Management*, 24, 853-859. <https://doi.org/10.54097/81x6z947>
37. Meher, B. K., Anand, A., Kumar, S., Birau, R., & Singh, M. (2024). Effectiveness of random forest model in predicting stock prices of solar energy companies in India. *International Journal of Energy Economics and Policy*, 14(2), 426-434. <https://doi.org/10.32479/ijeep.15581>
38. Mintarya, L. N., Halim, J. N., Angie, C., Achmad, S., & Kurniawan, A. (2023). Machine learning approaches in stock market prediction: A systematic literature review. *Procedia Computer Science*, 216, 96-102. <https://doi.org/10.1016/j.procs.2022.12.115>

39. Miyo, T., Kung, H., Nao, R., & Zhang, C. (2025). Hybrid Framework of Machine Learning and Optimization for Adaptive Decision Making in Financial Markets. *EasyChair Preprint*, 15679, 1-13.
40. Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). Efficient stock-market prediction using ensemble support vector machine. *Open Computer Science*, 10(1), 153-163. <https://doi.org/10.1515/comp-2020-0199>
41. Nurrimah, N., & Rustam, Z. (2020, June). Stock price trend prediction method based on support vector machines with Fisher score. In *AIP Conference Proceedings*, 2242(1), 1–8. <https://doi.org/10.1063/5.0007893>
42. Oyewole, A. T., Adeoye, O. B., Addy, W. A., Okoye, C. C., Ofodile, O. C., & Ugochukwu, C. E. (2024). Predicting stock market movements using neural networks: a review and application study. *Computer Science & IT Research Journal*, 5(3), 651-670. <https://doi.org/10.51594/csitrj.v5i3.912>
43. Özdemir, E., & Uluyol, B. (2025). Determining the Best Machine Learning Model by Predicting the Participation Index of the Borsa Istanbul Stock Exchange with Artificial Intelligence. In *Cutting-Edge Technologies for Business Sectors* (pp. 147-176). IGI Global. <https://doi.org/10.4018/979-8-3693-9586-8.ch006>
44. Patra, S., Pandey, T. N., & Bhuyan, B. (2024). Stock Market Prediction Using Machine Learning: Evidence from India. *Machine Learning Approaches in Financial Analytics*, 254, 347-375. https://doi.org/10.1007/978-3-031-61037-0_17
45. Phuoc, T., Anh, P. T. K., Tam, P. H., & Nguyen, C. V. (2024). Applying machine learning algorithms to predict the stock price trend in the stock market–The case of Vietnam. *Humanities and Social Sciences Communications*, 11(1), 1-18. <https://doi.org/10.1057/s41599-024-02807-x>
46. Pinuji, B. S. (2024). The Role of Artificial Intelligence Dimensions on Accounting Information System Efficiency: Case Study of a Sharia Banking Company in Indonesia. *Dinasti International Journal of Economics, Finance & Accounting*, 5(2), 668-684. <https://doi.org/10.38035/dijefa.v5i2.2664>
47. Prasad, A., & Seetharaman, A. (2021). Importance of machine learning in making investment decision in stock market. *Vikalpa*, 46(4), 209-222. <https://doi.org/10.1177/02560909211059992>
48. Prasad, G., Sahoo, S. K., & Kaur, H. (2024). A Comparative Study on Conventional Methods and Machine Learning Approaches on Stock Market Prediction. Working Paper, 1-7. Available at SSRN: <https://ssrn.com/abstract=4824929>
49. Priyatno, A. M., Ningsih, L., & Noor, M. (2024). Harnessing Machine Learning for Stock Price Prediction with Random Forest and Simple Moving Average Techniques. *Journal of Engineering and Science Application*, 1(1), 1–8. <https://doi.org/10.69693/jesa.v1i1.1>
50. Punjabi, Y., & Faridi, M. (2024). A Study of Stock Market Prediction (SMP) Using Machine Learning Techniques. *International Research Journal on Advanced*

- Engineering and Management (IRJAEM)*, 2(8), 2699-2709.
<https://doi.org/10.47392/IRJAEM.2024.0391>
51. Purnama, I. P. C., Ginantra, N. L. W. S. R., Darma, I. W. A. S., & Udayana, I. P. A. E. D. (2023, December). Comparison of Support Vector Machine (SVM) and Linear Regression (LR) for Stock Price Prediction. In *2023 Eighth International Conference on Informatics and Computing (ICIC)*, 1-6.
<https://doi.org/10.1109/ICIC60109.2023.10381982>
52. Raghunathan, D., & Krishnamoorthi, M. (2025). Optimizing Stock Predictions with Bi-Directional LSTM and Levy Flight Fuzzy Social Spider Optimization (LFFSSO): LSTM Model. *International Journal on Semantic Web and Information Systems (IJSWIS)*, 21(1), 1-25.
53. Rahman, M. K., Dalim, H. M., Reza, S. A., Ahmed, A., Zeeshan, M. A. F., Jui, A. H., & Nayeem, M. B. (2025). Assessing the Effectiveness of Machine Learning Models in Predicting Stock Price Movements during Energy Crisis: Insights from Shell's Market Dynamics. *Journal of Business and Management Studies*, 7(1), 44-61. <https://doi.org/10.32996/jbms.2025.7.1.4>
54. Rath, S., Das, N. R., & Pattanayak, B. K. (2024). An Analytic Review on Stock Market Price Prediction using Machine Learning and Deep Learning Techniques. *Recent Patents on Engineering*, 18(2), 88-104.
<https://doi.org/10.2174/1872212118666230303154251>
55. Rouf, N., Malik, M. B., Arif, T., Sharma, S., Singh, S., Aich, S., & Kim, H. C. (2021). Stock market prediction using machine learning techniques: a decade survey on methodologies, recent developments, and future directions. *Electronics*, 10(21), 1-25.
<https://doi.org/10.3390/electronics10212717>
56. Saini, A., & Sharma, A. (2022). Predicting the unpredictable: an application of machine learning algorithms in Indian stock market. *Annals of Data Science*, 9(4), 791-799. <https://doi.org/10.1007/s40745-019-00230-7>
57. Sangeetha, J. M., & Alfia, K. J. (2024). Financial stock market forecast using evaluated linear regression based machine learning technique. *Measurement: Sensors*, 31, 1-7. <https://doi.org/10.1016/j.measen.2023.100950>
58. Sarker, P., Sayed, A., Apu, A. S., Tasnim, S. A., & Mahmud, R. (2024). A Comparative Review on Stock Market Prediction Using Artificial Intelligence. *Malaysian Journal of Science and Advanced Technology*, 4(4), 383-404.
<https://doi.org/10.56532/mjsat.v4i4.316>
59. Sharma, A., Lohumi, Y., Gangodkar, D., & Goyal, A. (2024). Analyzing technical, sentimental, and machine learning algorithms for stock market prediction. In *AIP Conference Proceedings*, 3121(1). 1-30. <https://doi.org/10.1063/5.0221529>
60. Shastri, M., Roy, S., & Mittal, M. (2019). Stock price prediction using artificial neural model: an application of big data. *EAI Endorsed Transactions on Scalable Information Systems*, 6(20), 1-8. <https://doi.org/10.4108/eai.19-12-2018.156085>

61. Singh, M. I., & Mishra, M. A. K. (2023). Analysis of ANN, (Artificial/Neural Network) based Simulation Model for Predicting the/Stock Market. XVI(2), 50- 54.
62. Soni, P., Tewari, Y., & Krishnan, D. (2022). Machine learning approaches in stock price prediction: a systematic review. In *Journal of Physics: Conference Series*, 2161(1), 1-10. <https://doi.org/10.1088/1742-6596/2161/1/012065>
63. Strader, T. J., Rozycki, J. J., Root, T. H., & Huang, Y. H. J. (2020). Machine learning stock market prediction studies: review and research directions. *Journal of International Technology and Information Management*, 28(4), 63-83. <https://doi.org/10.58729/1941-6679.1435>
64. Swamy, S. R., Rajgoli, S. R., & Hegde, T. (2024). Stock Market Prediction with Machine Learning: A Comprehensive Review. *Indiana Journal of Multidisciplinary Research*, 4(3), 265-271. <https://doi.org/10.5281/zenodo.12685839>
65. Thirumalaisamy, R., Ramasamy, V., & Abouraia, M. (2024). Stock Price Prediction through Multifaceted Data Integration and Machine Learning. In *The AI Revolution: Driving Business Innovation and Research: Volume 2* (pp. 545-557). Cham: Springer Nature Switzerland.
66. Tulsyan, R., Shukla, P., Arora, N., Singh, T., & Kumar, M. (2024, October). AI Prediction of Stock Market Trends: An Overview for Non-Technical Researchers. In 2nd International Conference on Emerging Technologies and Sustainable Business Practices-2024 (ICETSBP 2024) (pp. 341-353). Atlantis Press. <https://www.atlantispress.com/proceedings/icetsbp-24/126004208>
67. Ucoglu, D. (2020). Current machine learning applications in accounting and auditing. Press Academia Procedia (PAP), 12(1), 1-7. <http://doi.org/10.17261/Pressacademia.2020.1337>
68. Vijn, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock closing price prediction using machine learning techniques. *Procedia computer science*, 167, 599-606. <https://doi.org/10.1016/j.procs.2020.03.326>
69. Whig, P., Sharma, P., Bhatia, A. B., Nadikattu, R. R., & Bhatia, B. (2024). Machine Learning and its Role in Stock Market Prediction. *Deep Learning Tools for Predicting Stock Market Movements*, 271-297. <https://doi.org/10.1002/9781394214334.ch12>
70. Yebi, D. K., & Cudjoe, E. K. (2022). Artificial Intelligence as a Disruptive Business Model in Auditing. A study of the impact of artificial intelligence on auditors' skills and competence, audit process, and audit quality. *Master Thesis*, UMEA school of Business, Economics Statistics, 1-71. <https://www.diva-portal.org/smash/get/diva2:1675420/FULLTEXT03.pdf>
71. Zhang, J., Li, L., & Chen, W. (2021). Predicting stock price using two-stage machine learning techniques. *Computational Economics*, 57, 1237-1261. <https://doi.org/10.1007/s10614-020-10013-5>
72. Zhang, T., Da Huo, M., Ma, Z., Hu, J., Liang, Q., & Chen, H. (2024). Prediction model of stock return on investment based on hybrid DNN and TabNet model. *PeerJ Computer Science*, 10, e20571, 1-23. <https://doi.org/10.7717/peerj-cs.2057>

- 73.Zhang, Y., Xiong, F., Xie, Y., Fan, X., & GU, H. (2020). The impact of artificial intelligence and blockchain on the accounting profession. IEEE Access, 8(1), 110461-110477. <https://doi.org/10.1109/ACCESS.2020.3000505>
- 74.Zhanga, R., Wangb, Y., Zhangc, J., Zhangd, L., & Que, J. (2024). Three Machine Learning Predictions of US Stock Prices. 2024 5th International Conference on Economics, Education and Social Research (ICEESR 2024) Francis Academic, 283-289.<https://doi.org/10.25236/iceesr.2024.046>
- 75.Zhou, S. (2024). Comparison between Logistic Regression, LSTM, and Random Forest in Chinese Stock Prediction. *Highlights in Science, Engineering and Technology*, 85, 737-742. <https://doi.org/10.54097/kr7rbj10>