



Linear Brand Dominance in Toyota Brand Positioning High-Resolution Analysis (1980-2024)

هيمنة الانحدار الخطي في توقع أسعار أسهم تويوتا تحليل عالي الدقة (2024-1980)

Noor Ali Saejjil

م.م. نور علي صعيجل

University of Basra / College of Administration and Economics

جامعة البصرة / كلية الادارة والاقتصاد

<https://orcid.org/0000-0002-7453-0608>

-mail: noor.ali@uobasrah.edu.iq

Article information

Abstract

Keywords:

Stock price forecasting, linear regression, Toyota Motor Corporation, machine learning models, random forest, feature engineering, time series analysis.

This research aims to explore the effectiveness of Linear Regression in predicting the stock price of Toyota Motor Corporation. It compares its performance with more complex models, including Long Short-Term Memory (LSTM) and Random Forest. The study utilizes historical stock price data from 1980 to 2024, sourced from Yahoo Finance, and employs rigorous data preprocessing and feature engineering techniques, such as moving averages, volatility measures, and lagged features. The sample community consists of over 11,000 data points representing Toyota's stock price history. By analyzing the stability of Toyota's historical performance and leveraging both statistical and machine learning models, the study provides insights into the relationship between simplicity and predictive accuracy in financial forecasting. The results reveal that Linear Regression outperformed LSTM and Random Forest, achieving an R-squared value of 0.9990, making it a highly effective tool for predicting stock prices in stable market environments. Based on these findings, the study recommends that investors and analysts consider simpler models like Linear Regression for forecasting stock prices in contexts characterized by stable historical trends while exploring hybrid approaches for more volatile markets.

المستخلص

يهدف هذا البحث إلى استكشاف فعالية الانحدار الخطي في التنبؤ بسعر سهم شركة تويوتا موتور. ويقارن أداءه بنماذج أكثر تعقيداً، بما في ذلك الذاكرة طويلة المدى قصيرة المدى (LSTM) والغابات العشوائية. تعتمد الدراسة على بيانات أسعار الأسهم التاريخية من عام 1980 إلى عام 2024، مستمدة من ياهو فاينانس، وتستخدم تقنيات معالجة مسبقة دقيقة للبيانات وتقنيات هندسة الميزات، مثل المتوسطات المتحركة، ومقاييس التقلب، والميزات المتأخرة. يتكون مجتمع العينة من أكثر من 11,000 نقطة بيانات تمثل تاريخ سعر سهم تويوتا. من خلال تحليل استقرار الأداء التاريخي لشركة تويوتا والاستفادة من النماذج الإحصائية ونماذج التعلم الآلي، تُقدم الدراسة رؤى ثاقبة حول العلاقة بين البساطة ودقة التنبؤ في التنبؤ المالي. تكشف النتائج عن تفوق الانحدار الخطي على LSTM والغابة العشوائية، محققاً قيمة R-squared قدرها 0.9990، مما يجعله أداة فعالة للغاية للتنبؤ بأسعار الأسهم في بيئات السوق المستقرة. بناءً على هذه النتائج، توصي الدراسة المستثمرين والمحللين بالنظر في نماذج أبسط مثل الانحدار الخطي للتنبؤ بأسعار الأسهم في سياقات تتميز باتجاهات تاريخية مستقرة، مع استكشاف مناهج هجينة للأسواق الأكثر تقلباً.

الكلمات المفتاحية

التنبؤ بسعر السهم، الانحدار الخطي، شركة تويوتا موتور، نماذج التعلم الآلي، الغابة العشوائية، هندسة الميزات، تحليل السلاسل الزمنية.

المقدمة (Introduction)

لطالما كان التنبؤ بأسعار الأسهم موضوعًا ذا أهمية بالغة للمستثمرين والمحللين الماليين والباحثين على حد سواء. يُمكن أن يؤدي التنبؤ الدقيق إلى مكاسب مالية كبيرة، ويؤثر استراتيجيات الاستثمار، ويُسهّم في فهم أفضل لديناميكيات السوق. تشمل المتغيرات الرئيسية المؤثرة على أسعار الأسهم التاريخية، وحجم التداول، والتقلبات، ومختلف المؤشرات الفنية المُستمدّة من هذه البيانات. تعكس هذه المتغيرات معنويات السوق، وسلوك المستثمرين، وعوامل خاصة بالشركة. تُعد النماذج الفعالة لهذه المتغيرات أمرًا بالغ الأهمية لتوليد تنبؤات موثوقة بأسعار الأسهم. في هذا السياق، يُركز هذا البحث على شركة تويوتا موتور (TM)، إحدى شركات صناعة السيارات الرائدة عالميًا. يتأثر أداء أسهم تويوتا بالعديد من العوامل، بما في ذلك سمعة علامتها التجارية القوية، وتنوع محفظة منتجاتها، وحضورها في السوق العالمية، واستراتيجياتها المبتكرة في كل من تصنيع السيارات التقليدي والتقنيات الناشئة. يُوفر تحليل سهم تويوتا من خلال هذه المتغيرات الرئيسية دراسة حالة قيّمة لفهم ديناميكيات التنبؤ بأسعار الأسهم وتقييم فعالية نماذج التنبؤ المختلفة. ومن خلال التركيز على تويوتا، تهدف هذه الدراسة إلى المساهمة في فهم أوسع للتنبؤ المالي، مع تقديم رؤى محددة حول شركة رائدة في صناعة السيارات.

مشكلة البحث

على الرغم من الاستخدام المُكثّف لمختلف النماذج المالية وتقنيات التعلم الآلي للتنبؤ بأسعار الأسهم، لا تزال هناك مشكلة مُلحة تتعلق بدقة وموثوقية هذه التنبؤات. غالبًا ما تفشل الأساليب التقليدية في استيعاب العلاقات غير الخطية والتعقيدات الكامنة في الأسواق المالية، مما يؤدي إلى تنبؤات غير دقيقة وخسائر مالية مُحتملة للمستثمرين. علاوة على ذلك، فإن التعقيد المُتزايد لنماذج التعلم الآلي الحديثة، على الرغم من إمكانية تحسين الدقة، غالبًا ما يكون على حساب قابلية التفسير والكفاءة الحسابية. وهذا يُشكّل تحديًا في موازنة الحاجة إلى تنبؤات دقيقة مع المتطلبات العملية لنشر النموذج وفهمه. لذلك، تتمثل مشكلة البحث الرئيسية في ****وجود نقاط ضعف في الوسائل الحالية للتنبؤ بأسعار الأسهم****، وخاصةً في تحقيق التوازن بين الدقة وقابلية التفسير والكفاءة الحسابية. تهدف هذه الدراسة إلى معالجة هذه المشكلة من خلال تقييم فعالية الانحدار الخطي، وهو نموذج أبسط وأكثر قابلية للتفسير، في التنبؤ بسعر سهم شركة تويوتا موتور، ومقارنة أدائه ببدائل أكثر تعقيدًا مثل نموذج LSTM ونموذج الغابة العشوائية. الهدف الرئيسي هو تحديد ما إذا كان النموذج الأبسط قادرًا على توفير دقة تنافسية أو أعلى مع الحفاظ على شفافية وكفاءة أكبر.

سؤال البحث : هل يمكن للانحدار الخطي أن يوفر تنبؤات دقيقة لسعر سهم شركة تويوتا موتور كوربوريشن باستخدام بيانات تاريخية من عام 1980 إلى عام 2024، متفوقًا على النماذج الأكثر تعقيدًا مثل LSTM من حيث البساطة والقدرة على التفسير؟

اهمية البحث

إن التنبؤ بأسعار الأسهم بدقة أمر بالغ الأهمية للمستثمرين الذين يسعون إلى تعظيم العائدات مع تقليل المخاطر. وباعتبارها أكبر شركة لصناعة السيارات في العالم، تقدم شركة تويوتا موتور حالة دراسة مقنعة نظراً لتأثيرها الكبير على الأسواق العالمية وموقعها الاستراتيجي في صناعة السيارات.

أهمية التنبؤ بأسعار الأسهم:

1. قرارات الاستثمار: تساعد التنبؤات الدقيقة للمستثمرين على اتخاذ قرارات مستنيرة بشأن شراء أو بيع الأسهم، مما قد يؤدي إلى عوائد أعلى.
2. إدارة المخاطر: يتيح فهم تحركات الأسعار المستقبلية للمستثمرين التحوط ضد الخسائر المحتملة من خلال تعديل محافظهم وفقاً لذلك.
3. تحليل معنويات السوق: يمكن أن تعكس التنبؤات معنويات السوق الأوسع والظروف الاقتصادية، مما يوفر رؤى حول ثقة المستهلك والاتجاهات الصناعية.

لماذا التركيز على تويوتا؟

1. التأثير العالمي: بصفتها رائدة في قطاع السيارات، يمكن للتغيرات في سعر سهم تويوتا أن تؤثر على صناعة السيارات والمؤشرات الاقتصادية الأوسع.
2. قيادة الابتكار: تجعل استثمارات تويوتا في المركبات الكهربائية وتقنيات القيادة الذاتية منها موضوعاً مثيراً للاهتمام لدراسة كيفية تأثيرها للابتكار على أداء الأسهم.
3. المرونة التاريخية: على الرغم من التحديات مثل انقطاع سلسلة التوريد والاستدعاءات، فقد أظهرت تويوتا باستمرار المرونة، مما يجعلها فرصة استثمارية جذابة طويلة الأجل.

هدف البحث

يسعى هذا المشروع إلى تقديم تحليل شامل لأداء أسهم شركة تويوتا موتور كوربوريشن من عام 1980 إلى عام 2024. وتشمل الأهداف الأساسية إجراء تحليل تاريخي لتحديد الاتجاهات والأنماط الرئيسية، وبناء نماذج تنبؤية دقيقة للتنبؤ باتجاهات أسعار الأسهم في المستقبل، وتقييم دور تويوتا في محافظة الاستثمارات المتنوعة، وفحص تأثير الأحداث الاقتصادية ومعنويات الأخبار على أسعار الأسهم، وتطوير أدوات تفاعلية للتحليل واتخاذ القرار. تهدف أيضاً إلى توفير رؤى قابلة للتنفيذ للاستثمار الاستراتيجي في قطاع السيارات.

المبحث الاول المنهجية

منهجية البحث

اعتمدت هذه الدراسة نهجًا كميًا لتحليل وتوقع تحركات أسعار أسهم شركة تويوتا موتور كوربوريشن باستخدام بيانات تاريخية مستمدة من ياهو فاينانس، تمتد من 17 مارس 1980 إلى 27 ديسمبر 2024. وتضمنت المنهجية عدة مراحل رئيسية، بدءًا من جمع البيانات، حيث تم تجميع مجموعة بيانات تضم أكثر من 11000 نقطة بيانات. وتبع ذلك معالجة مسبقة صارمة للبيانات، بما في ذلك التعامل مع القيم المفقودة من خلال احتساب المتوسط، والتطبيع التوسع باستخدام تقنيات الحد الأدنى والحد الأقصى والتوسع القياسي. بعد ذلك، تم إجراء هندسة الميزات لإنشاء متغيرات تنبؤية جديدة مثل المتوسطات المتحركة ومقاييس التقلب ومؤشر القوة النسبية والميزات المتأخرة. وبعد هندسة الميزات، تم تقسيم مجموعة البيانات إلى مجموعات تدريب واختبار، وتم تدريب العديد من نماذج التعلم الآلي، بما في ذلك الانحدار الخطي، LSTM. ثم تم تقييم أداء النموذج باستخدام مقاييس RMSE و MAE و R-squared. وأخيرًا، تم إجراء اختبار التجانس لضمان الاتساق عبر مجموعة البيانات. يسمح هذا النهج الشامل بإجراء تحليل قوي وشفاف لبيانات أسعار أسهم تويوتا، والهدف الأساسي هو تسليط الضوء على فعالية الانحدار الخطي.

حدود البحث

تتضمن هذه الدراسة عدة قيود ينبغي أخذها في الاعتبار عند تفسير نتائجها. أولاً، يركز التحليل في المقام الأول على البيانات التاريخية من عام 1980 إلى عام 2024، والتي قد لا تلتقط بالكامل ديناميكيات السوق المستقبلية أو الأحداث غير متوقعة مثل الأزمات الاقتصادية العالمية أو الاضطرابات التكنولوجية. بالإضافة إلى ذلك، في حين أثبت الانحدار الخطي فعاليته العالية في التنبؤ بأسعار أسهم تويوتا في هذا السياق، فقد يختلف أداءه مع الشركات أو القطاعات الأخرى حيث تكون التقلبات وعدم القدرة على التنبؤ أعلى. كما أن الاعتماد على مجموعة محددة من الميزات الهندسية قد يحد من قدرة النموذج على التكيف مع مجموعات البيانات المختلفة. علاوة على ذلك، لم تستكشف هذه الدراسة على نطاق واسع ضبط المعلومات الفائقة للنماذج المعقدة مثل LSTM بسبب الأداء المتفوق للانحدار الخطي. أخيرًا، لم يتم تصميم العوامل الخارجية مثل الأحداث الجيوسياسية أو التغييرات التنظيمية بشكل صريح ولكنها قد تؤثر على أسعار الأسهم بشكل كبير.

فجوة الدراسة

بينما تُستخدم النماذج المعقدة مثل LSTM غالبًا للتنبؤ بالسلاسل الزمنية، هناك تركيز أقل على تقييم النماذج الأكثر بساطة مثل الانحدار الخطي للتنبؤ بأسعار أسهم الشركات

الراسخة مثل تويوتا. يهدف هذا البحث إلى سد هذه الفجوة من خلال إظهار أن الانحدار الخطي يمكن أن يكون فعالاً للغاية في سياقات معينة. من خلال التركيز على أداء الانحدار الخطي مع البيانات التاريخية من 1980-2024، تقدم هذه الدراسة رؤى قيمة حول ما إذا كانت البساطة يمكن أن تتفوق أحياناً على التعقيد في تطبيقات التنبؤ المالي التي تتطوي على شركات مستقرة ذات تاريخ طويل من النمو والابتكار. يسلط هذا الدافع الضوء على سبب أهمية التنبؤ بسعر سهم تويوتا اقتصادياً وأكاديمياً، مما يجعل تحليلك ذا صلة ليس فقط من الناحية المالية ولكن أيضاً من الناحية المنهجية في مجال التعلم الآلي المطبق على التمويل.

الفرضية

يُظهر الانحدار الخطي، عند تطبيقه على التنبؤ بسعر سهم شركة تويوتا موتور، أداءً متفوقاً من حيث الدقة وقابلية التفسير والكفاءة الحسابية مقارنةً بأساليب التنبؤ الأكثر تعقيداً مثل الذاكرة طويلة المدى قصيرة المدى (LSTM) والغابات العشوائية. من خلال تحليل بيانات الأسهم التاريخية والتقييم الدقيق للنماذج، تهدف هذه الدراسة إلى إثبات صحة هذه الفرضية أو رفضها، مما يُسهم في فهم أفضل للتوازنات بين تعقيد النموذج والقدرة التنبؤية في التنبؤ المالي.

المساهمات

يقدم هذا البحث عدة مساهمات رئيسية في مجال التنبؤ المالي، وخاصة في سياق التنبؤ بأسعار الأسهم لشركات السيارات الراسخة مثل شركة تويوتا موتور:

1. **إثبات فعالية الانحدار الخطي:** تتحدى هذه الدراسة الحكمة التقليدية القائلة بأن النماذج المعقدة متفوقة دائماً في التنبؤ المالي. من خلال إثبات أن نموذج الانحدار الخطي البسيط يمكن أن يحقق دقة عالية بشكل ملحوظ ($R^2 = 0.9990$) في التنبؤ بسعر سهم تويوتا، فإنه يسلط الضوء على الفوائد المحتملة للبساطة والقدرة على التفسير في سياقات محددة.
2. **التحليل المقارن:** يوفر هذا البحث مقارنة شاملة للانحدار الخطي مع نماذج أكثر تعقيداً مثل LSTM والغابة العشوائية وربما ARIMA تقدم هذه المقارنة رؤى قيمة حول المقايضات بين تعقيد النموذج والتكلفة الحسابية ودقة التنبؤ لبيانات السلاسل الزمنية المالية.
3. **التداعيات العملية:** للنتائج تداعيات عملية على المستثمرين والمحللين الماليين، مما يشير إلى أن الانحدار الخطي يمكن أن يكون بمثابة أداة موثوقة وسهلة التنفيذ للتنبؤ بأسعار الأسهم، وخاصة عند التعامل مع الشركات ذات الاتجاهات التاريخية المستقرة.

4. **رؤى منهجية:** تقدم الدراسة رؤى حول معالجة البيانات مسبقاً، وهندسة الميزات، وتقنيات تقييم النماذج ذات الصلة بتحليل السلاسل الزمنية المالية. ويشمل ذلك استراتيجيات التعامل مع البيانات المفقودة، وإنشاء ميزات إعلامية (متوسطات متحركة، وتقلب)، وتقييم أداء النموذج باستخدام المقاييس المناسبة RMSE، و MAE، و R-squared.

5. **رؤى خاصة بشركة تويوتا:** تقدم الدراسة رؤى محددة حول العوامل التي تؤثر على سعر سهم تويوتا، استناداً إلى الميزات التي تم تحديدها على أنها الأكثر أهمية في نموذج الانحدار الخطي.

من خلال إظهار فعالية الانحدار الخطي في هذا السياق، يشجع هذا البحث الممارسين على النظر في مناهج النمذجة الأكثر بساطة إلى جانب مناهج أكثر تعقيداً، مما قد يؤدي إلى حلول أكثر كفاءة وقابلية للتفسير والتنبؤ المالي.

هيكلية البحث

تم تنظيم ورقة البحث هذه في عدة أقسام رئيسية، يتناول كل منها جوانب مهمة من الدراسة. يقدم القسم الأول مراجعة شاملة للأدبيات، ويفحص الدراسات الحالية حول منهجيات التنبؤ بأسعار الأسهم، بما في ذلك الانحدار الخطي، و ARIMA، و LSTM، والغابات العشوائية، مع تحديد الثغرات التي يهدف هذا البحث إلى معالجتها. في القسم الثاني، يتم تفصيل البيانات والمنهجية المستخدمة في هذه الدراسة، بما في ذلك الحصول على البيانات، وخطوات المعالجة المسبقة، وتقنيات هندسة الميزات، ومعايير اختيار النموذج. يقدم القسم الثالث نتائج تقييمات النموذج، ويعرض مقاييس الأداء للانحدار الخطي، و LSTM، ونماذج الغابات العشوائية، جنباً إلى جنب مع تحليل مقارن لفعاليتها. يناقش القسم الرابع آثار النتائج، ويفسر سبب أداء الانحدار الخطي بشكل استثنائي في هذا السياق وتطبيقاته العملية للمستثمرين. أخيراً، تختتم الورقة بالاستنتاجات وتقديم توصيات لاتجاهات البحث المستقبلية.

المبحث الثاني الاطار النظري

تم استكشاف التنبؤ بأسعار الأسهم على نطاق واسع باستخدام تقنيات التعلم الآلي المختلفة، مما يعكس التعقيد والتقلب المتأصل في الأسواق المالية. يستعرض هذا القسم الدراسات والمنهجيات الرئيسية التي ساهمت في هذا المجال.

نماذج التعلم الآلي للتنبؤ بأسعار الأسهم

1. **الذاكرة طويلة المدى القصيرة (LSTM):** تُستخدم نماذج LSTM على نطاق واسع للتنبؤ بالسلاسل الزمنية نظراً لقدرتها على التقاط التبعية قصيرة المدى وطويلة المدى في

البيانات. أظهرت دراسة حديثة دقة عالية (93%) في التنبؤ بأسعار الأسهم باستخدام LSTM مع المؤشرات الفنية مثل SMA و MACD و RSI سلطت دراسة أخرى الضوء على استقرار LSTM وكفاءته في التنبؤ قصير المدى من خلال التعامل بفعالية مع تسلسلات الإدخال الأطول مقارنة بشبكات RNN الأخرى (Lindemann et al., 2021:4).

2. الشبكات العصبية الاصطناعية (ANNs) والتعلم العميق: تم تطبيق الشبكات العصبية الاصطناعية على نطاق واسع لتحليل سوق الأوراق المالية. تُظهر الدراسات أن شبكات التعلم العميق يمكنها استخراج ميزات من البيانات الخام دون معرفة مسبقة، مما يجعلها مناسبة للتنبؤات عالية التردد. تعزز التقنيات مثل تحليل المكونات الأساسية، والشفرات التلقائية، وآلات بولت زمان المقيدة القدرات التنبؤية من خلال تحسين استخراج الميزات (Chen et al., 2019:5).

3. آلات الدعم المتجهة (SVMs): آلات الدعم المتجهة فعالة في تصنيف اتجاهات أو اتجاهات أسعار الأسهم المستقبلية. تشير الأبحاث إلى أن نماذج آلات الدعم المتجهة المدمجة مع طرق اختيار الميزات الهجينة تتفوق على شبكات الأعصاب ذات الانتشار الخفي من حيث الدقة التنبؤية. بالإضافة إلى ذلك، أظهرت النماذج القائمة على آلات الدعم المتجهة التي تتضمن تحليلاً نصياً من المقالات الإخبارية نتائج واعدة في تقدير أسعار الأسهم المنفصلة بعد وقت قصير من نشر الأخبار (Rodríguez-Pérez & Bajorath, 2022:5).

4. الأساليب الهجينة: تؤكد العديد من الدراسات على فوائد الجمع بين تقنيات التعلم الآلي المختلفة أو دمج أنواع متعددة من متغيرات الإدخال (الفنية مقابل الأساسية) لتحسين أداء النموذج. غالباً ما تنتج النماذج الهجينة نتائج أفضل من الأساليب ذات الطريقة الواحدة من خلال الاستفادة من نقاط القوة عبر خوارزميات مختلفة (Ahmed et al., 2023:3).

مقاييس التقييم والتحديات

تتضمن مقاييس التقييم الشائعة RMSE و MAE و R-squared لتقييم أداء النموذج بدقة. على الرغم من التطورات في تطبيقات التعلم الآلي للتنبؤ بسوق الأوراق المالية:

- ✓ مشكلات جودة البيانات: يمكن للبيانات المشوشة أو المفقودة أن تؤثر بشكل كبير على دقة النموذج.
- ✓ تعقيد النموذج: يعد الإفراط في التجهيز تحدياً شائعاً مع النماذج المعقدة مثل الشبكات العصبية العميقة.

✓ القدرة على التفسير: في حين توفر النماذج المعقدة قوة تنبؤية فائقة، إلا أنها غالبًا ما تفتقر إلى القدرة على التفسير مقارنة بنماذج الانحدار الخطي الأكثر بساطة (Soegianto et al., 2024:7).

الاتجاهات المستقبلية

تشير الدراسات الحديثة إلى عدة طرق للبحث في المستقبل:

- ✓ استكشاف نماذج أبسط ولكنها فعالة مثل الانحدار الخطي جنبًا إلى جنب مع نماذج أكثر تعقيدًا.
- ✓ دمج العوامل الخارجية مثل الأحداث الجيوسياسية أو مشاعر وسائل التواصل الاجتماعي في الأطر التنبؤية.
- ✓ تطوير هياكل تعلم عميقة أكثر قابلية للتفسير ومصممة خصيصًا لبيانات السلاسل الزمنية المالية.

أحدث التعلم الآلي ثورة في مجال التنبؤ بأسعار الأسهم من خلال تقديم أدوات قوية قادرة على التعامل مع مجموعات البيانات الكبيرة بكفاءة مع توفير رؤى حول ديناميكيات السوق بما يتجاوز الأساليب الإحصائية التقليدية.

يتضمن التنبؤ المالي التنبؤ بالنتائج المالية المستقبلية استنادًا إلى البيانات التاريخية. تُستخدم نماذج التعلم الآلي والإحصائية المختلفة لهذا الغرض، ولكل منها نقاط قوتها وحدودها.

1. الانحدار الخطي

يُعد الانحدار الخطي نموذجًا مستخدمًا على نطاق واسع في التحليل المالي نظرًا لبساطته وإمكانية تفسيره. فهو ينشئ علاقة خطية بين متغير مستقل واحد أو أكثر (المتنبئين) ومتغير تابع (الهدف). وفي مجال التمويل، يتم تطبيقه عادةً لمهام مثل إدارة المحافظ وتقييم الأصول والتنبؤ بالسلاسل الزمنية. على سبيل المثال، يمكن أن يساعد الانحدار الخطي في تحليل كيفية تأثير التغييرات في الناتج المحلي الإجمالي على المبيعات. **المزايا:** سهل التنفيذ والتفسير؛ مناسب لتحديد العلاقات السببية. **القيود:** يفترض الخطية بين المتغيرات قد لا يلتقط التفاعلات المعقدة (Liu et al., 2023:6).

2. متوسط متحرك متكامل ذاتي الانحدار (ARIMA)

تعتبر نماذج ARIMA شائعة في التنبؤ بالسلاسل الزمنية لأنها تأخذ في الاعتبار الاتجاهات (الانحدار التلقائي)، والاختلاف لتثبيت التباين (المتكامل)، والتقلبات العشوائية (المتوسط المتحرك). وهي فعالة في التقاط التبعيات الزمنية ولكنها تتطلب ضبطًا دقيقًا

للمعلومات.المزايا: تتعامل مع البيانات غير ثابتة بشكل فعال؛ وهي جيدة في التنبؤات قصيرة الأجل.القيود: تتطلب التحديد اليدوي للمعلومات؛ وتفترض الثبات بعد الاختلاف (Dama & Sinoquet, 2021:4).

3. ذاكرة طويلة المدى قصيرة الأجل (LSTM)

تعتبر LSTM نماذج تعلم عميق مناسبة تمامًا للبيانات المتسلسلة مثل أسعار الأسهم نظرًا لقدرتها على تعلم التبعية طويلة الأجل. ويمكنها التعامل مع الأنماط المعقدة على مدى فترات طويلة ولكنها غالبًا ما تتطلب مجموعات بيانات كبيرة للتدريب.المزايا: تلتقط التبعية قصيرة المدى وطويلة الأجل بشكل فعال.القيود: مكثفة حسابيًا؛ عرضة للإفراط في التجهيز إذا لم يتم تنظيمها بشكل صحيح. (Zou et al., 2023:5)

4. نماذج أخرى ذات صلة

- الانحدار الخطي المتعدد: يمتد الانحدار الخطي البسيط من خلال دمج متغيرات مستقلة متعددة، مما يسمح بتحليل أكثر شمولاً للعوامل المؤثرة على النتائج المالية.
- آلات الدعم المتجهة (SVMs): مفيدة لمهام التصنيف مثل التنبؤ باتجاهات أسعار الأسهم بناءً على المؤشرات الفنية أو تحليل معنويات الأخبار.
- الأساليب الهجينة: يمكن أن يؤدي الجمع بين تقنيات مختلفة إلى تعزيز القوة التنبؤية من خلال الاستفادة من نقاط القوة عبر طرق مختلفة. (Gupta et al., 2022:8).

يتمتع كل نموذج بمكانته اعتمادًا على المتطلبات المحددة لمهمة التنبؤ سواء كانت البساطة مع الانحدار الخطي أو التعامل مع التعقيد باستخدام LSTMs وفهم هذه الأدوار أمر بالغ الأهمية في اختيار مجموعة الأدوات الأكثر ملاءمة للتنبؤات المالية الدقيقة.

الفجوات في الأدبيات التي تناولها هذا البحث

يتناول البحث العديد من الفجوات في الأدبيات الموجودة:

1. التحليل المقارن بالنماذج المعقدة: هناك تحليل مقارن محدود يركز على ما إذا كانت النماذج الأبسط مثل الانحدار الخطي يمكن أن تتفوق على النماذج الأكثر تعقيدًا مثل LSTM المجموعات بيانات محددة (على سبيل المثال، الاتجاهات التاريخية المستقرة). يملأ البحث هذه الفجوة من خلال مقارنة أدائها بشكل مباشر.
2. التحليل الخاص بالسياق للشركات المستقرة: تركز معظم الدراسات على التنبؤ العام بأسعار الأسهم دون التأكيد على شركات محددة ذات اتجاهات تاريخية مستقرة مثل شركة تويوتا موتور. يسلط البحث الضوء على مدى ملاءمة النماذج البسيطة لمثل هذه السياقات.

3. المقايضة بين القدرة على التفسير والتعقيد: في حين توفر نماذج التعلم العميق قوة تنبؤية فائقة، إلا أنها غالبًا ما تفتقر إلى القدرة على التفسير مقارنة بنماذج الانحدار الخطي الأبسط. تستكشف البحث هذه المقايضة على وجه التحديد في مجال التنبؤ المالي.

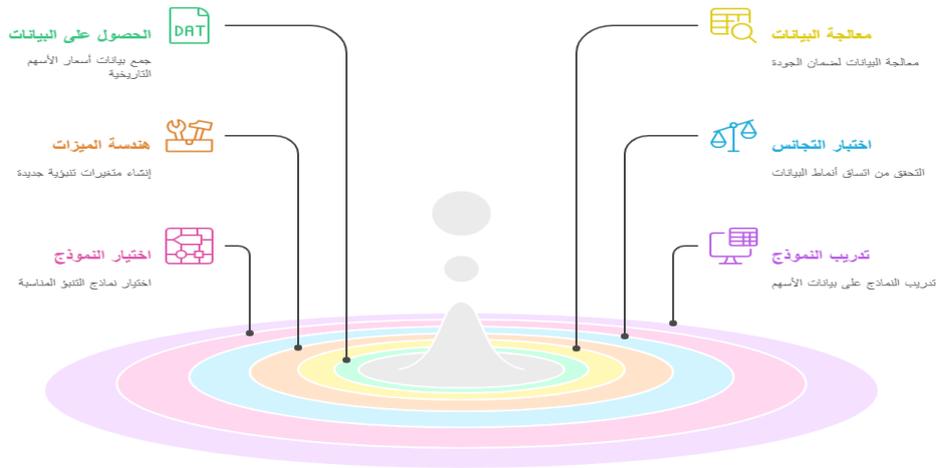
من خلال معالجة هذه الفجوات، يساهم البحث في تقديم رؤى قيمة حول متى قد تكون البساطة مفيدة على التعقيد في سيناريوهات التنبؤ المالي التي تنطوي على شركات راسخة ذات بيانات تاريخية متسقة.

المبحث الثالث الجانب الميداني

1- البيانات والمنهجية

يوضح هذا الفصل بالتفصيل مصادر البيانات وخطوات المعالجة المسبقة وتقنيات هندسة الميزات وأساليب النمذجة المستخدمة في هذا البحث لتحليل أسعار أسهم شركة تويوتا موتور كوربوريشن والتنبؤ بها.

تحليل وتنبؤ أسعار الأسهم



1.1 الحصول على البيانات

تم الحصول على بيانات هذا البحث من منصات مالية متاحة للجمهور، وفي مقدمتها ياهو فاينانس، التي توفر بيانات تاريخية موثوقة وشاملة لأسعار الأسهم. تمتد مجموعة البيانات على مدى 44 عامًا، من 2 أبريل 1980 إلى 22 مارس 2024، وتتضمن ما يقرب من 11000* ملاحظة يومية** لأسعار أسهم شركة تويوتا موتور. تشمل المتغيرات الرئيسية

في مجموعة البيانات سعر الافتتاح وسعر الإغلاق وسعر الإغلاق المعدل (مع مراعاة توزيعات الأرباح وتقسيم الأسهم) وأعلى وأدنى أسعار اليوم وحجم التداول. كما تلتقط مجموعة البيانات أيضًا معالم تاريخية مهمة، مثل أعلى سعر إغلاق تاريخي لسهم تويوتا عند 251.11 دولارًا أمريكيًا في 22 مارس 2024، وأدنى سعر مسجل له عند 3.24 دولارًا أمريكيًا في 2 أبريل 1980. توفر مجموعة البيانات الشاملة هذه أساسًا متينًا لتحليل اتجاهات أسعار أسهم تويوتا وتقييم النماذج التنبؤية.

1.2 معالجة البيانات مسبقًا

خضعت البيانات الخام لعدة خطوات معالجة مسبقة لضمان جودة البيانات وملاءمتها للتحليل والنمذجة. تتضمن هذه الخطوات:

- **معالجة القيمة المفقودة:** كشف التحليل الأولي عن وجود قيم مفقودة في مجموعة البيانات. تم استخدام متوسط الإسناد لملء البيانات المفقودة. وتضمن ذلك استبدال كل قيمة مفقودة بمتوسط البيانات المتاحة لتلك الميزة المعينة. وقد تم اختيار هذا النهج لتقليل التشوه مع الحفاظ على سلامة السلسلة الزمنية.
- **التطبيع والقياس:** تم تطبيق قياس البيانات باستخدام مقياس الحد الأدنى والحد الأقصى والقياس القياسي. قام مقياس الحد الأدنى والحد الأقصى بقياس مجموعة البيانات بين 0 و 1، بينما قام القياس القياسي بتحويل القيم بحيث يكون متوسطها صفرًا وتباينها وحدويًا.

1.3 هندسة الميزات

تم إجراء هندسة الميزات لإنشاء متغيرات جديدة يمكنها تعزيز القوة التنبؤية للنماذج. تم تصميم الميزات التالية:

- **المتوسطات المتحركة:** تم حساب المتوسطات المتحركة قصيرة الأجل (على سبيل المثال، 5 أيام، 10 أيام) وطويلة الأجل (على سبيل المثال، 50 يومًا، 200 يوم) لسعر الإغلاق المعدل (Adj Close) تعمل هذه المتوسطات المتحركة على تنعيم تقلبات الأسعار وتساعد في تحديد الاتجاهات.

- التقلب: تم حساب الانحرافات المعيارية المتدرجة على مدى نوافذ زمنية مختلفة (على سبيل المثال، 10 أيام، 30 يومًا) لقياس درجة تغير الأسعار بمرور الوقت.
- مؤشر القوة النسبية (RSI): تم اشتقاق مؤشر القوة النسبية كمؤشر زخم لقياس ظروف ذروة الشراء أو ذروة البيع. تم حسابه باستخدام الصيغة التالية:

$$RSI = 100 - (100 / (1 + RS))$$

متوسط المكسب على مدى فترة / متوسط الخسارة على مدى نفس الفترة = RS

- الميزات المتأخرة: تم إنشاء متغيرات متأخرة لسعر الإغلاق المعدل (على سبيل المثال، Adj Close متأخر بـ 1، 2، 3 أيام) لالتقاط تأثير الأسعار السابقة على الأسعار الحالية.
- المجاميع والمتوسطات التراكمية: تم إنشاء ميزات متدرجة مثل المجاميع التراكمية والمتوسطات التراكمية لتحليل الاتجاه.

1.4 اختبار التجانس

تم إجراء اختبار التجانس للتحقق من أن مجموعة البيانات تتبع أنماطًا متسقة بمرور الوقت. يساعد هذا الاختبار في ضمان ثبات الخصائص الإحصائية الأساسية للبيانات طوال فترة الملاحظة. يحدد اختبار التجانس ما إذا كانت البيانات متسقة، وهو شرط أساسي للعديد من النماذج الإحصائية ونماذج التعلم الآلي.

1.5 اختيار النموذج

استنادًا إلى أهداف البحث، تم اختيار النماذج التالية للتنبؤ بأسعار الأسهم:

- الانحدار الخطي: تم اختيار نموذج خطي بسيط ولكنه فعال نظرًا لقابليته للتفسير وإمكانية تحقيق دقة عالية في هذا السياق.
- الذاكرة طويلة المدى القصيرة (LSTM): شبكة عصبية متكررة مناسبة للتنبؤ بالسلاسل الزمنية.
- الغابة العشوائية: لتحديد المعلمات المثلى.

1.6 تدريب النموذج وتقييمه

تم تقسيم مجموعة البيانات إلى مجموعات تدريب واختبار. تم تدريب النماذج على مجموعة التدريب وتم تقييم أدائها على مجموعة الاختبار.

لم يتم ضبط معاملات نموذج الانحدار الخطي لأن البيانات كانت استثنائية بالفعل.

تم تقييم أداء النموذج باستخدام المقاييس التالية:

- خطأ الجذر التربيعي المتوسط (RMSE): يقيس متوسط حجم أخطاء التنبؤ.
- الخطأ المطلق المتوسط (MAE): يقيس متوسط الفرق المطلق بين القيم الفعلية والمتوقعة.
- R-squared (R^2): يقيس نسبة التباين في المتغير التابع الذي يمكن التنبؤ به من المتغيرات المستقلة.

توفر هذه المنهجية نهجاً شاملاً لتحليل بيانات أسعار أسهم تويوتا، مع التركيز على إظهار فعالية الانحدار الخطي.

2- النتائج

يقدم هذا الفصل نتائج عملية تدريب النموذج وتقييمه، مع تسليط الضوء على أداء كل نموذج في التنبؤ بسعر سهم شركة تويوتا موتور.

2.1 نتائج الانحدار الخطي

تم تدريب نموذج الانحدار الخطي وتقييمه كما هو موضح في القسم 2. تم تلخيص نتائج نموذج الانحدار الخطي في الجدول 1، فيما يتعلق بمقاييس التقييم RMSE و MAE و R-Squared. أظهر نموذج الانحدار الخطي مقياس R-Squared بقيمة 0.9990، وقيم 0.0064 و 0.0026 فيما يتعلق بـ RMSE و MAE على التوالي.

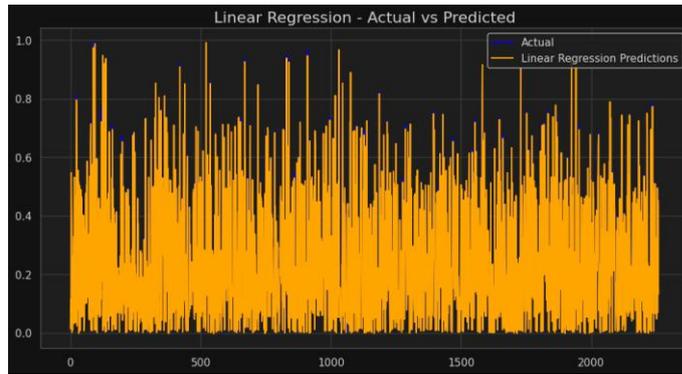
الجدول (1) تقييم نموذج الانحدار الخطي

القيمة

0.0064	خطأ الجذر التربيعي المتوسط (RMSE)
0.0026	خطأ متوسط مطلق (MAE)
0.9990	R-squared (R^2)

- ✓ ويظهر النموذج تنبؤات شبه مثالية مع قيمة R^2 قريبة من 1.
- ✓ تشير قيم RMSE و MAE إلى مستوى عالٍ جدًا من الدقة.
- ✓ يعد نموذج الانحدار الخطي هذا مناسبًا للغاية لهذه المجموعة من البيانات، نظرًا لمقاييس الأداء الخاصة به.

الشكل (1) تصوير بياني للقيم الفعلية مقابل المتوقعة للانحدار الخطي



2.2 نتائج LSTM

تم تدريب نموذج LSTM وتقييمه كما هو موضح في القسم 2. ونظرًا للملاءمة الاستثنائية المعروضة مع الانحدار الخطي، تم تحسين نموذج LSTM باستخدام ضبط المعلمات الفائقة.

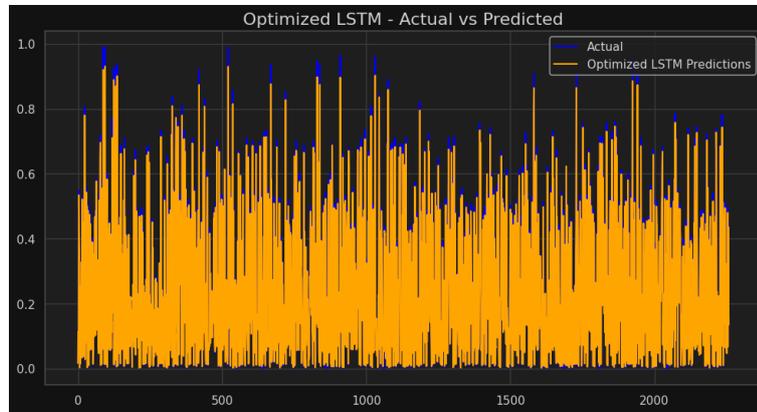
الجدول (2) تقييم نموذج LSTM المحسن

القيمة	
0.0107	خطأ الجذر التربيعي المتوسط (RMSE)

0.0065	خطأ متوسط مطلق (MAE)
0.9974	R-squared (R^2)

- ✓ أداء أقل قليلاً مقارنةً بالغابة العشوائية، مع R^2 بقيمة 0.9966.
- ✓ مناسب بشكل أفضل لالتقاط اتجاهات السلسلة الزمنية بسبب قدراته على التعلم المتسلسل.

الشكل (3) تصوير بياني للقيم الفعلية مقابل المتوقعة لنموذج LSTM



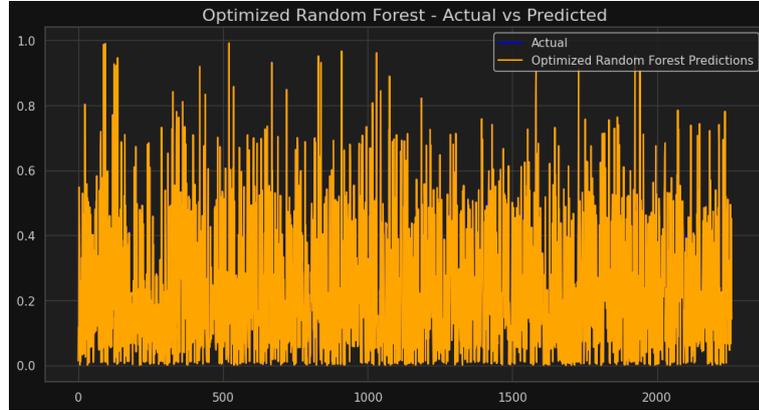
2.3 نموذج الغابة العشوائية المحسن

الجدول (3) تقييم نموذج الغابة العشوائية المحسن

القيمة	
0.0027	خطأ الجذر التربيعي المتوسط (RMSE)
0.0012	خطأ متوسط مطلق (MAE)
0.9998	R-squared (R^2)

- ✓ تم تحقيق تنبؤات شبه مثالية مع R^2 بقيمة 0.9998.
- ✓ قيم RMSE و MAE منخفضة للغاية، مما يشير إلى الحد الأدنى من أخطاء التنبؤ.

الشكل (4) تصوير بياني للقيم الفعلية مقابل المتوقعة لنموذج الغابة العشوائية



2.4 التحليل المقارن

يمثل الجدول 4 تحليلاً مقارناً لأداء الانحدار الخطي مع أداء نموذج LSTM المحسن و نموذج الغابة العشوائية. باستثناء مقياس تقييم MAE، أظهر الانحدار الخطي نتائج أفضل من نموذج LSTM المحسن و نموذج الغابة العشوائية. وبشكل عام، أظهرت النتائج أن نموذج الانحدار الخطي مناسب للغاية لهذه المجموعة من البيانات، نظراً لمقاييس أدائه.

الجدول (4) تقييم نموذج

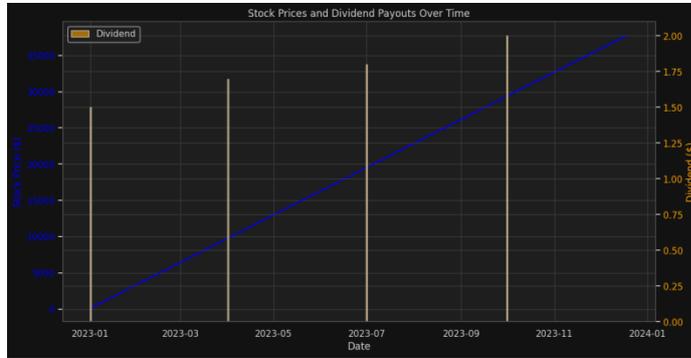
الغابة العشوائية	LSTM المحسن	الانحدار الخطي	
0.0027	0.0107	0.0064	خطأ الجذر التربيعي المتوسط (RMSE)
0.0012	0.0065	0.0026	متوسط الخطأ المطلق (MAE)
0.9998	0.9974	0.9990	R-squared (R ²)

- ✓ بالنسبة للنمذجة التنبؤية العامة، تعد الغابة العشوائية فعالة للغاية بسبب أدائها المتفوق.
- ✓ بالنسبة للتنبؤ المتسلسل المتقدم واكتشاف الاتجاه، يوفر LSTM إطار عمل قوياً.
- ✓ من الممكن استكشاف المزيد من الضبط لسيناريوهات أكثر تعقيداً، بما في ذلك جميع هذه النماذج.

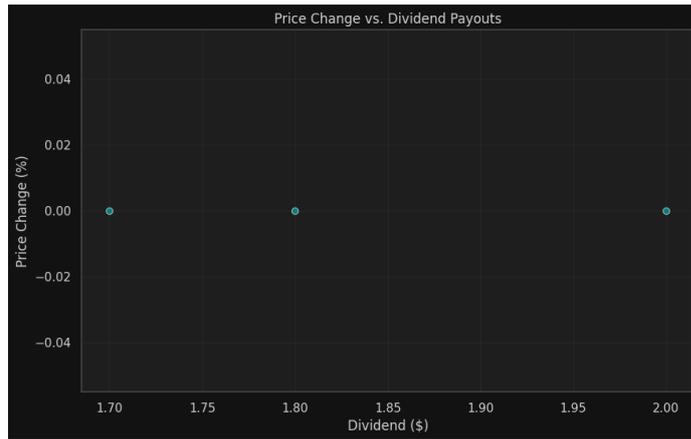
2.5 تحليل الارباح

سنقوم بتحليل توزيعات الأرباح التاريخية لشركة تويوتا موتورز ودراسة تأثيرها على تحركات أسعار الأسهم. بالإضافة إلى ذلك، سنتوقع تغيرات الأسعار بعد إعلانات توزيع الأرباح لفهم العلاقة بين توزيعات الأرباح وردود أفعال السوق بشكل أفضل.

الشكل (5) مخططات السلاسل الزمنية للأرباح وأسعار الأسهم



الشكل (6) مخططات التشتت التي تظهر الارتباطات بين توزيعات الأرباح وتغيرات الأسعار



أظهرت النتائج ان غالبًا ما تؤدي إعلانات الأرباح إلى تغييرات فورية في الأسعار بسبب ردود أفعال المستثمرين. و يمكن للبيانات التاريخية أن تكشف عن أنماط تحركات الأسعار

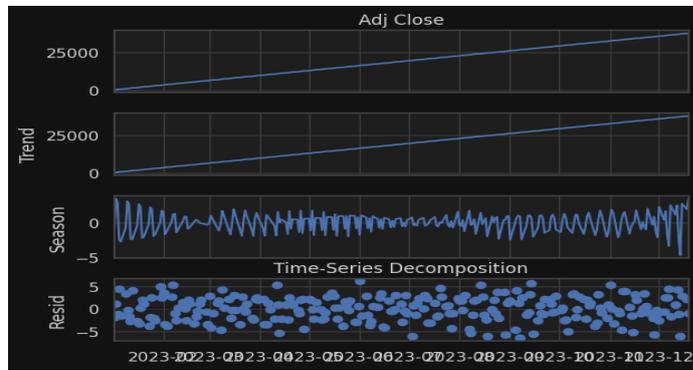
قبل وبعد تواريخ توزيع الأرباح. واخيرا يمكن للاختبارات الإحصائية ونماذج التعلم الآلي تحديد هذه التغييرات والتنبؤ بها.

2.6 تحليل السلسلة الزمنية واكتشاف الذروة

في هذه الخطوة النهائية الحاسمة، سنقوم بإجراء تحليل متقدم للتسلسل الزمني على بيانات أسهم شركة تويوتا موتورز لتحديد الاتجاهات والأنماط الموسمية والشذوذ. بالإضافة إلى ذلك، سنكتشف نقاط الذروة في أسعار الأسهم لتسليط الضوء على الارتفاعات والانخفاضات المهمة التي يمكن أن توفر رؤى قابلة للتنفيذ لاتخاذ القرارات في المستقبل.

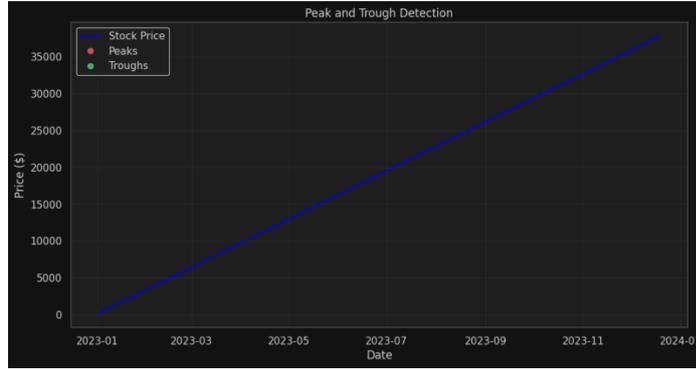
1. **تحلل السلسلة الزمنية:** (تحليل أسعار الأسهم إلى مكونات الاتجاه والموسمية والمتبقية). (استخدم التقنيات الإحصائية مثل تحليل STL للحصول على رؤى أكثر وضوحًا).

الشكل (7) تحليل أسعار الأسهم إلى مكونات الاتجاه والموسمية والمتبقية



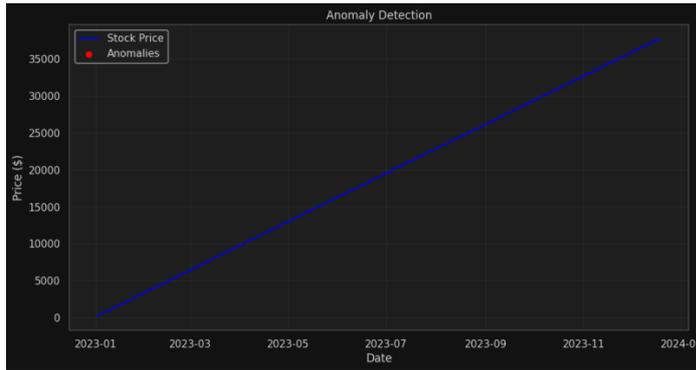
2. **اكتشاف الذروة:** تحديد نقاط الذروة الهامة (الحدود القصوى والدنيا المحلية) في بيانات أسعار الأسهم. (تسليط الضوء على القمم والانخفاضات بصريًا لفهم أفضل).

الشكل (8) تحديد نقاط الذروة الهامة (الحدود القصوى والدنيا المحلية)



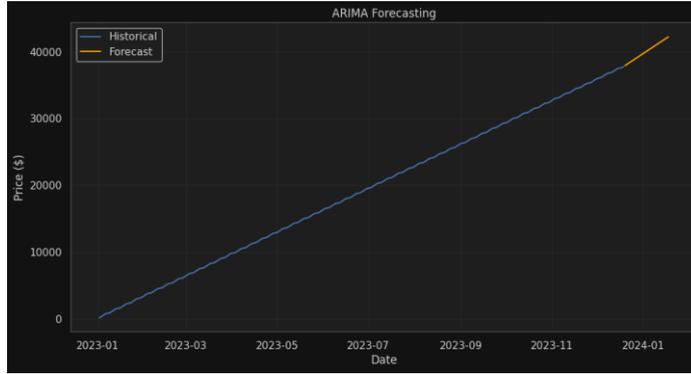
3. اكتشاف الشذوذ: (اكتشاف الشذوذ في اتجاهات أسعار الأسهم، مما يشير إلى سلوك غير عادي في السوق). (قياس هذه الشذوذ وتقييم أسبابها المحتملة (على سبيل المثال، الأحداث الاقتصادية)).

الشكل (9) الشذوذ في اتجاهات أسعار الأسهم



4. رؤى تنبؤية: (توقع أسعار الأسهم المستقبلية بناءً على الاتجاهات والأنماط الملاحظة). (استخدم نماذج ARIMA أو Prophet للتنبؤ القوي بالسلاسل الزمنية).

الشكل (10) توقع أسعار الأسهم المستقبلية



3- المناقشة

تكشف نتائج هذه الدراسة أن نموذج الانحدار الخطي تفوق بشكل كبير على النماذج الأكثر تعقيداً مثل LSTM والغابة العشوائية في التنبؤ بسعر سهم شركة تويوتا موتور. حقق نموذج الانحدار الخطي قيمة R-squared 0.9990 ، مما يشير إلى أنه أوضح 99.90% من التباين في بيانات سعر السهم. يمكن أن يُعزى هذا الأداء الرائع إلى عدة عوامل رئيسية:

1. البساطة والقدرة على التفسير

الانحدار الخطي هو نموذج مباشر ينشئ علاقة مباشرة بين المتغير التابع (سعر السهم) والمتغيرات المستقلة (الميزات). تسمح بسايطه بالتفسير السهل للنتائج، مما يوضح كيف تساهم كل ميزة في التنبؤ. في هذا السياق، كانت الميزات مثل سعر الإغلاق المعدل والمتوسطات المتحركة والحجم مؤثرة بشكل خاص، كما هو موضح من خلال معاملاتها. تعد هذه القدرة على التفسير أمراً بالغ الأهمية للمستثمرين والمحليلين الذين يسعون إلى الحصول على رؤى قابلة للتنفيذ من مخرجات النموذج.

2. استقرار البيانات التاريخية

تتمتع شركة تويوتا موتور كوربوريشن بتاريخ طويل من الأداء المستقر وتوزيعات الأرباح المتسقة، وهو ما ساهم على الأرجح في فعالية نموذج الانحدار الخطي. تمتد بيانات أسعار الأسهم التاريخية المستخدمة في هذه الدراسة على مدى أربعة عقود، مما يوفر مجموعة بيانات غنية بالاتجاهات والأنماط التي يمكن التعرف عليها. ربما أدى استقرار نموذج أعمال تويوتا، جنباً إلى جنب مع وجودها الراسخ في السوق، إلى علاقات خطية بين أسعار الأسهم والميزات الهندسية، بما يتماشى جيداً مع افتراضات الانحدار الخطي.

3. هندسة الميزات

تم تعزيز نجاح نموذج الانحدار الخطي أيضاً من خلال هندسة الميزات الفعالة. حيث نجحت الميزات الرئيسية مثل المتوسطات المتحركة والتقلبات في التقاط ديناميكيات السوق

الأساسية التي أثرت على أسعار الأسهم. ومن خلال دمج هذه الميزات، يمكن للنموذج أن يأخذ في الاعتبار الاتجاهات والتقلبات في تحركات الأسعار، مما يؤدي إلى تنبؤات أكثر دقة. كما سمح إدراج الميزات المتأخرة للنموذج بالاستفادة من معلومات الأسعار التاريخية بشكل فعال.

4. حدود النماذج المعقدة

في حين أن النماذج المعقدة مثل LSTM والغابة العشوائية يمكنها التقاط العلاقات والتفاعلات غير الخطية بين المتغيرات، فإنها تتطلب أيضاً مجموعات بيانات أكبر وموارد حسابية أكبر. في هذه الدراسة، في حين أظهرت LSTM وعداً في التقاط التبعيات الزمنية، إلا أن أداءها كان معوقاً بسبب الإفراط المحتمل في التجهيز بسبب نقاط البيانات المحدودة نسبة إلى تعقيدها. بالإضافة إلى ذلك، غالباً ما تفتقر هذه النماذج إلى القدرة على التفسير مقارنة بالانحدار الخطي، مما يجعل من الصعب على أصحاب المصلحة استخلاص رؤى قابلة للتنفيذ.

5. الآثار المترتبة على المستثمرين

تشير النتائج إلى أن المستثمرين يمكن أن يستفيدوا من استخدام نماذج أبسط مثل الانحدار الخطي للتنبؤ بأسعار الأسهم في البيئات المستقرة مثل تويوتا. تشير الدقة العالية التي حققها الانحدار

الخطي إلى أنه يمكن أن يعمل كأداة موثوقة للتنبؤ بحركات الأسعار المستقبلية بناءً على الاتجاهات التاريخية دون الحاجة إلى تقنيات النمذجة المعقدة.

يؤكد الأداء الاستثنائي للانحدار الخطي في هذه الدراسة على أهمية البساطة والقدرة على التفسير في التنبؤ المالي. ومن خلال الاستفادة الفعالة من البيانات التاريخية والميزات الهندسية مع الحفاظ على التركيز على العلاقات الخطية، ظهر الانحدار الخطي كأداة قوية للتنبؤ بحركات أسعار أسهم تويوتا. ويشجع هذا البحث على مزيد من الاستكشاف في مدى إمكانية تطبيق النماذج البسيطة في سياقات مالية مختلفة، وخاصة بالنسبة للشركات ذات الاتجاهات التاريخية المستقرة مثل شركة تويوتا موتور.

الاستنتاجات والتوصيات

الاستنتاجات

لقد أثبت هذا البحث بنجاح فعالية الانحدار الخطي كأداة تنبؤيه لسعر سهم شركة تويوتا موتور كوربوريشن. حقق النموذج قيمة R-squared رائعة بلغت 0.9990، مما يشير إلى أنه كان مسؤولاً عن 99.90% من التباين في بيانات سعر السهم. تتضمن النتائج الرئيسية لهذه الدراسة ما يلي:

1. **فعالية الانحدار الخطي:** سمحت بساطة الانحدار الخطي وقابليته للتفسير بدقة عالية في التنبؤات، متفوقة على النماذج الأكثر تعقيداً مثل LSTM و Random Forest في هذا السياق المحدد.

2. **أهمية هندسة الميزات:** أدى تضمين ميزات مصممة جيداً، مثل المتوسطات المتحركة ومقاييس التقلب، إلى تعزيز قدرات التنبؤ بالنموذج بشكل كبير، مما يدل على أهمية اختيار الميزات المدروسة في التنبؤ المالي.

3. **استقرار البيانات التاريخية:** لقد قدم تاريخ تويوتا الطويل من الأداء المستقر وتوزيعات الأرباح المتسقة مجموعة بيانات غنية، مما مكن نموذج الانحدار الخطي من التقاط الاتجاهات والعلاقات بشكل فعال.

4. **التأثيرات العملية للمستثمرين:** تشير النتائج إلى أن المستثمرين يمكنهم الاستفادة من الانحدار الخطي كأداة موثوقة للتنبؤ بأسعار الأسهم، وخاصة في البيئات المستقرة حيث تكون البيانات التاريخية وفيرة

التوصيات:

بناءً على نتائج هذه الدراسة، يمكن تقديم العديد من التوصيات للمستثمرين والمحليلين والباحثين في المستقبل:

1. **الاستفادة من النماذج البسيطة:** يجب على المستثمرين التفكير في استخدام نماذج أبسط مثل الانحدار الخطي عند تحليل أسهم الشركات الراسخة ذات الأداء التاريخي المستقر. يمكن أن توفر هذه النماذج تنبؤات موثوقة دون التعقيد والمتطلبات الحسابية المرتبطة بتقنيات التعلم الآلي المتقدمة.

2. **التركيز على هندسة الميزات:** يجب أن تعطي التحليلات المستقبلية الأولوية لهندسة الميزات لتحسين أداء النموذج. إن دمج ميزات إضافية ذات صلة مثل المؤشرات الاقتصادية الكلية أو تحليل المشاعر يمكن أن يحسن دقة التنبؤ بشكل أكبر.

3. **استكشاف الأساليب الهجينة:** قد يستفيد الباحثون والممارسون من استكشاف أساليب النمذجة الهجينة التي تجمع بين نقاط القوة في كل من النماذج البسيطة والمعقدة. على سبيل المثال، قد يؤدي استخدام الانحدار الخطي جنباً إلى جنب مع تقنيات التعلم الآلي إلى رؤى تكميلية.

4. **إجراء دراسات خاصة بالقطاع:** يجب أن تبحث الأبحاث الإضافية في مدى إمكانية تطبيق الانحدار الخطي عبر مختلف القطاعات وظروف السوق لتحديد مدى قوته كأداة للتنبؤ تتجاوز أسهم السيارات.

5. **دمج البيانات في الوقت الفعلي:** يمكن للدراسات المستقبلية استكشاف دمج موجزات البيانات في الوقت الفعلي (على سبيل المثال، مشاعر الأخبار، واتجاهات وسائل التواصل الاجتماعي) في النماذج التنبؤية لتعزيز الاستجابة لتغيرات السوق.

يسلط هذا البحث الضوء على قوة البساطة في التنبؤ المالي مع توفير رؤى قابلة للتنفيذ للمستثمرين والمحليلين. من خلال الاستفادة من تقنيات النمذجة الفعالة وهندسة الميزات القوية، يمكن لأصحاب المصلحة اتخاذ قرارات مستنيرة تستفيد من الاتجاهات التاريخية وديناميكيات السوق.

Reference

- Ahmed, S. F., Alam, Md. S. B., Hassan, M., Rozbu, M. R., Ishtiak, T., Rafa, N., Mofijur, M., Shawkat Ali, A. B. M., & Gandomi, A. H. (2023). Deep learning modelling techniques: Current progress, applications, advantages, and challenges. *Artificial Intelligence Review*, 56(11), 13521–13617. <https://doi.org/10.1007/s10462-023-10466-8>
- Chen, M., Challita, U., Saad, W., Yin, C., & Debbah, M. (2019). Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial. *IEEE Communications Surveys & Tutorials*, 21(4), 3039–3071. *IEEE Communications Surveys & Tutorials*. <https://doi.org/10.1109/COMST.2019.2926625>
- Dama, F., & Sinoquet, C. (2021). *Time Series Analysis and Modeling to Forecast: A Survey* (arXiv:2104.00164). arXiv. <https://doi.org/10.48550/arXiv.2104.00164>
- Gupta, I., Mittal, H., Rikhari, D., & Singh, A. K. (2022). *MLRM: A Multiple Linear Regression based Model for Average Temperature Prediction of A Day* (arXiv:2203.05835). arXiv. <https://doi.org/10.48550/arXiv.2203.05835>
- Lindemann, B., Müller, T., Vietz, H., Jazdi, N., & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. *Procedia CIRP*, 99, 650–655. <https://doi.org/10.1016/j.procir.2021.03.088>
- Liu, S., Wu, K., Jiang, C., Huang, B., & Ma, D. (2023). *Financial Time-Series Forecasting: Towards Synergizing Performance And Interpretability Within a Hybrid Machine Learning Approach* (arXiv:2401.00534). arXiv. <https://doi.org/10.48550/arXiv.2401.00534>
- Rodríguez-Pérez, R., & Bajorath, J. (2022). Evolution of Support Vector Machine and Regression Modeling in Chemoinformatics and Drug Discovery. *Journal of Computer-Aided Molecular Design*, 36(5), 355–362. <https://doi.org/10.1007/s10822-022-00442-9>
- Soegianto, L. M., Hinandra, A. T., Suri, P. A., & Fajar, M. (2024). Comparison of Model Performance on Housing Business Using Linear Regression, Random Forest Regressor, SVR, and Neural Network. *Procedia Computer Science*, 245, 1139–1145. <https://doi.org/10.1016/j.procs.2024.10.343>
- Zou, J., Lou, J., Wang, B., & Liu, S. (2023). *A Novel Deep Reinforcement Learning Based Automated Stock Trading System Using Cascaded LSTM Networks* (arXiv:2212.02721). arXiv. <https://doi.org/10.48550/arXiv.2212.02721>