

الاستلام: 2024-12-2، القبول: 2025-1-21، النشر: 2025-3-1.

مقارنة فعالية نموذج LSTM وتحليل الاتجاه في التنبؤ بأسعار الذهب بالدولار الأمريكي دراسة تحليلية للفترة من 2010 إلى 2024

¹محمد مصطفى عبد العالي عبد الجواد ، ²مجدي رمضان يوسف المتخطري

تقنية المعلومات، المعهد العالي للعلوم والتقنية /أمساد، ليبيا. Astef_li@yahoo.com

العلوم الإدارية والمالية، المعهد العالي للعلوم والتقنية /أمساد، Magdibosif@Gmail.com

ملخص البحث

تهدف هذه الدراسة إلى مقارنة فعالية نموذج LSTM وأداة تحليل الاتجاه التقليدية في التنبؤ بأسعار الذهب بالدولار الأمريكي خلال الفترة الممتدة من 2010 إلى 2024. تعتمد الدراسة على مجموعة بيانات تاريخية تشمل التاريخ وسعر الذهب. تمحورت الدراسة حول تحليل أداء نموذج LSTM مقارنة بأداة تحليل الاتجاه التقليدية لفهم التغيرات في أسعار الذهب وتقديم توقعات دقيقة. كشفت النتائج عن تفوق نموذج LSTM بشكل ملحوظ على أداة تحليل الاتجاه التقليدية في دقة التنبؤ. عند تحويل القيم إلى نسب مئوية، تبين أن نموذج LSTM كان أكثر دقة بنسبة 29.7% في جذر متوسط مربع الخطأ (RMSE) و 25.6% في متوسط الخطأ المطلق (MAE) مقارنةً بأداة تحليل الاتجاه التقليدية. يعزى هذا التفوق إلى قدرة نموذج LSTM على معالجة البيانات الزمنية والتسلسلية بفعالية، مما يمكنه من فهم الأنماط المعقدة في البيانات وتقديم توقعات أكثر دقة. تميز نموذج LSTM بقدرته على التعلم من الأنماط التاريخية طويلة الأمد، مما يوفر دقة أعلى في التنبؤات مقارنة بالنماذج التقليدية.

الكلمات المفتاحية: التنبؤ بأسعار الذهب، نموذج LSTM، تحليل الاتجاه، البيانات الزمنية، التحليل المالي.

Comparing the Effectiveness of the LSTM Model and Trend Analysis in Predicting Gold Prices in US Dollars: An Analytical Study for the Period from 2010 to 2024

Mohamd MA Abdellgoad, Magdi R B Elmtkhtri

¹Information Technology, Higher Institute of Science and Technology / Amsad, Libya

Email: astef_li@yahoo.com

²Management & financial sciences, Higher Institute of Science and Technology / Amsad, Libya

Email: Magdibosif@Gmail.com

Abstract

This study aims to compare the effectiveness of the LSTM model and traditional trend analysis in predicting gold prices in US dollars over the period from 2010 to 2024. The study

relies on a historical dataset that includes the date and the price of gold. The focus is on analyzing the performance of the LSTM model compared to the traditional trend analysis tool to understand changes in gold prices and provide accurate forecasts. The results revealed that the LSTM model significantly outperforms the traditional trend analysis tool in forecasting accuracy. When the values were converted into percentages, the LSTM model was found to be 29.7% more accurate in root-mean-square error (RMSE) and 25.6% more accurate in mean absolute error (MAE) compared to the traditional trend analysis tool. This superiority is attributed to the LSTM model's ability to effectively process temporal and sequential data, enabling it to understand complex patterns in the data and make predictions that are more accurate. The LSTM model was able to learn from long-term historical patterns, providing higher forecast accuracy than traditional models.

Keywords: Gold price forecasting, LSTM model, trend analysis, time series data, financial analysis.

1. المقدمة

يلعب الذهب دوراً فريداً في النظم المالية عبر الثقافات المختلفة حول العالم. يتميز الذهب بقيمة تتجاوز بكثير تطبيقاته الصناعية، على عكس المعادن الثمينة الأخرى. يُعد الذهب أداة استثمارية مهمة تُستخدم لتتنوع المخاطر التجارية، وخاصة من خلال العقود الآجلة ومشتقاتها. وكأي سوق آخر، يخضع سوق الذهب للمضاربات والتقلبات. يتمتع الذهب بميزة كونه ملاذاً آمناً يفوق فعاليته مقارنة بأي معدن ثمين آخر يُستخدم في الاستثمارات، كما يحمل خصائص الحيلة في العديد من الدول.

يُعد سوق الذهب أحد أهم الأسواق العالمية، حيث يتم تداول الذهب كسلعة تجارية على نطاق واسع. ويتركز التداول بشكل رئيسي في أسواق الذهب الأوروبية (COMEX)، الأسترالية (ASX)، الأمريكية (NYMEX)، والهندي (MCX). في أوقات التضخم وعدم الاستقرار الاقتصادي، يلجأ المستثمرون إلى أصول آمنة للحفاظ على قيمة استثماراتهم، ويُعتبر الذهب من أبرز هذه الأصول. عبر التاريخ، أثبت الذهب قدرته على الحفاظ على قوته الشرائية حتى في ظل ارتفاع معدلات التضخم. ولهذا السبب، يهتم الباحثون والاقتصاديون بشكل كبير بدراسة وتحليل أسعار الذهب والتنبؤ بها، يلعب الذهب دوراً حيوياً في الاقتصاد العالمي، كونه يُعتبر مؤشراً على الاستقرار الاقتصادي والسياسي. يُستخدم كوسيلة لتخزين الثروة وتوفير الأمان في الأوقات الاقتصادية الحرجة. بالإضافة إلى ذلك، يُستخدم في العديد من الصناعات مثل الإلكترونيات، الطب، والتجارة (Shafiee & Topal, 2010; Raghuram, 2020).

تتجلى مشكلة الدراسة في صعوبة التنبؤ بأسعار الذهب بسبب العوامل العديدة والمتداخلة التي تؤثر على السوق، هناك فجوة معرفية في تحديد النموذج الأمثل لتوقع الأسعار بدقة، سواء باستخدام

النماذج التقليدية (GRU (Gated & Bidirectional Long Short-Term Memory Recurrent Unit).

تحليل تأثير التغيرات الزمنية تعتبر التغيرات الزمنية عنصراً مهماً في تحديد دقة التنبؤ بأسعار الذهب. فالأحداث الاقتصادية والسياسية، والتغيرات الموسمية، والاتجاهات طويلة الأمد، كلها تلعب دوراً في تشكيل سعر الذهب على مر الزمن. هذا التحليل يهدف إلى فهم كيف تؤثر هذه التغيرات الزمنية على دقة النماذج المستخدمة في التنبؤ بأسعار الذهب، وما إذا كانت هذه النماذج قادرة على التكيف مع هذه التغيرات بشكل فعال (Khani, Vahidnia, & Abbasi, 2020).

تهدف هذه الدراسة إلى تحليل كفاءة النماذج المستخدمة في التنبؤ بأسعار الذهب، مع إبراز أهمية الحصول على تنبؤات دقيقة لدعم القرارات الاستثمارية. سيتم التركيز على مقارنة أداء نموذج LSTM مع الأدوات التقليدية لتحليل الاتجاه، لتحديد النموذج الأكثر كفاءة ودقة. تشمل الدراسة أيضاً تحديد الفجوة المعرفية بين النماذج التقليدية والمتقدمة في توقع أسعار الذهب، مع التأكيد على دور التنبؤات الدقيقة في اتخاذ قرارات استثمارية مدروسة. تعتمد الدراسة على تحليل أسعار الذهب بالدولار الأمريكي باستخدام بيانات تاريخية تمتد من عام 2010 حتى 2024، وتتضمن المتغيرات الأساسية في هذه الدراسة التاريخ وسعر الذهب بالدولار الأمريكي، مما يساعد الباحثين والمستثمرين في اختيار النموذج الأمثل لتوقع أسعار الذهب (Manjula & Karthikeyan, 2019).

2. الأدبيات النظرية

نظرة عامة على أسواق الذهب آليات عمل سوق الذهب حيث يُعد من أقدم الأسواق المالية في العالم، يتم تداول الذهب كسلعة ذات قيمة عالية. يشمل السوق العالمي للذهب عدة جوانب، منها:

- التعدين والإنتاج: إنتاج الذهب يبدأ من عمليات التعدين في المناجم. أكبر الدول المنتجة للذهب تشمل الصين، أستراليا، وروسيا.
- التكرير والتصنيع: بعد استخراج الذهب، يتم تكريره وتحويله إلى سبائك وأشكال أخرى قابلة للتداول.
- التداول الفعلي والتداول الإلكتروني: يتم تداول الذهب في الأسواق الفعلية مثل بورصة لندن للمعادن (LME) وأسواق العقود الآجلة مثل COMEX. بالإضافة إلى ذلك، هناك منصات إلكترونية للتداول.
- استخداماته المتنوعة: يُستخدم الذهب في تصنيع المجوهرات، كاحتياطي في البنوك المركزية، وفي صناعات أخرى مثل الإلكترونيات والطب.

العوامل المؤثرة على أسعار الذهب: العرض والطلب كما هو الحال مع أي سلعة، يتأثر سعر الذهب بعوامل العرض والطلب في السوق.

الأوضاع الاقتصادية: التغيرات في الاقتصاد العالمي، مثل التضخم أو الركود، يمكن أن تؤثر على سعر الذهب.

التغيرات الجيوسياسية: الأوضاع السياسية غير المستقرة يمكن أن تدفع المستثمرين للبحث عن الذهب كملاذ آمن.

السياسات النقدية: قرارات البنوك المركزية بشأن أسعار الفائدة والسياسات النقدية الأخرى تؤثر أيضاً على سعر الذهب.

1.2 تحليل الاتجاه أدوات ومفهوم التحليل التقليدي للاتجاه في الأسواق المالية

مفهوم التحليل التقليدي للاتجاه هو جزء أساسي من التحليل الفني في الأسواق المالية يعتمد هذا النوع من التحليل على دراسة البيانات التاريخية للأسعار وأحجام التداول لتحديد الاتجاهات المستقبلية في الأسواق. الهدف من تحليل الاتجاه هو تحديد نمط السعر واتجاهه (صعوداً أو هبوطاً) والتنبؤ بحركة الأسعار المستقبلية بناءً على تلك الاتجاهات.

أدوات تحليل الاتجاه التقليدي: الخطوط الاتجاهية (Trend Lines) تُستخدم لتحديد اتجاه السوق من خلال رسم خطوط على الرسم البياني تربط بين القمم أو القيعان.

المتوسطات المتحركة (Moving Averages) تُستخدم لتحديد الاتجاه العام للسعر من خلال تصفية الضوضاء من تحركات الأسعار اليومية.

مؤشرات الزخم (Momentum Indicators): مثل مؤشر القوة النسبية (RSI) ومؤشر ستوكاستيك، تُستخدم لقياس سرعة وقوة الحركة السعرية.


الشموع اليابانية (Candlestick Patterns) تُستخدم لفهم سلوك السوق بناءً على أشكال الشموع المرسومة على الرسوم البيانية.

القنوات السعرية (Price Channels): تُستخدم لتحديد نطاقات التداول بين خطوط الدعم والمقاومة (Murphy, 1999).

2.2 شبكات LSTM كيفية عملها في مجال التنبؤ بالسلاسل الزمنية

الشبكة العصبية للذاكرة طويلة المدى القصيرة (LSTM) هي نوع من الشبكات العصبية المتكررة (RNN) المصممة للتغلب على مشكلة التدرج المتلاشي وتعلم التبعية طويلة المدى. وهي تستخدم هياكل متخصصة تسمى البوابات للتحكم في تدفق المعلومات عبر حالة الخلية، مما يجعلها فعالة لمهام مثل التنبؤ بالسلاسل الزمنية في مجالات مختلفة بما في ذلك التمويل والطب والسلوك البشري.

تكون وحدة LSTM عادةً من خلية وثلاث بوابات: بوابة إدخال وبوابة إخراج، وبوابة نسيان تتذكر الخلية القيم على فترات زمنية عشوائية، وتنظم البوابات تدفق المعلومات إلى داخل وخارج الخلية. تحدد بوابات النسيان المعلومات التي يجب التخلص منها من الحالة السابقة، وذلك من خلال تعيين الحالة السابقة والمدخلات الحالية لقيمة بين 0 و 1. تشير القيمة (المقربة) إلى الاحتفاظ بالمعلومات، وتمثل القيمة 0 التخلص منها. تحدد بوابات الإدخال أي أجزاء من المعلومات الجديدة يجب تخزينها في حالة الخلية الحالية، باستخدام نفس النظام الذي تستخدمه بوابات النسيان لتحكم بوابات الإخراج في أي جزء من المعلومات في حالة الخلية الحالية يجب إخراجها، من خلال تعيين قيمة من 0 إلى 1 للمعلومات، مع مراعاة الحالتين السابقة والحالية، يسمح إخراج المعلومات ذات الصلة بشكل انتقائي من الحالة الحالية. شبكة LSTM بالحفاظ على التبعيات المفيدة طويلة الأجل لإجراء التنبؤات، سواء في خطوة زمنية حالية أو مستقبلية (Hochreiter & Schmidhuber, 1996؛ Gers, Schmidhuber, & Cummins, 2000).



الشكل 1: بوابات شبكات LSTM

3.2 الدراسات السابقة

هناك العديد من التقنيات الحديثة التي تم استكشافها في مجال التنبؤ بأسعار الذهب، وتشمل هذه التقنيات النماذج الديناميكية، تقنيات توقيت العوامل المخصصة، وقدرة التعلم الديناميكي في نماذج الانحدار الخطي. ومع ذلك، تظهر الانتقادات نتيجة التعقيدات المتضمنة، حيث تؤثر عوامل متعددة على تقدير العلاقة بين المتنبئين المحتملين والعائدات المتوقعة. أثارت التطورات الحديثة في التعلم العميق، والتي أظهرت أداءً متميزاً في مجالات مثل الرؤية الحاسوبية ومعالجة اللغة الطبيعية، اهتماماً متزايداً بتطبيق هذه التقنيات على تحليل البيانات المالية.

وبشكل أكثر تحديدًا، قام بعض الباحثين بدراسة العديد من التطورات في نماذج التنبؤ بأسعار الذهب. فقد بحث Shafiee و Topal (2010) في العلاقة بين سعر النفط وسعر الذهب، بالإضافة إلى دراسات أخرى بارزة تستخدم تقنيات التعلم الآلي للتنبؤ بأسعار الذهب.

بفضل التوافر الكبير للبيانات في المجال المالي وتحسن فعالية الحساب في العقود الأخيرة، طوّر الباحثون نماذج متعددة تعتمد على تقنيات التعلم الآلي للتنبؤ بأسعار الذهب. على سبيل المثال، قارن "Naliniprava" بين أداء نموذجين وهما ARIMA و MLR في التنبؤ بأسعار الذهب الشهرية، وأشارت النتائج إلى أن نموذج ARIMA يتفوق على نموذج MLR، مما يبرز التأثير الكبير لسعر الذهب في الشهر الأخير على السعر الحالي (Naliniprava, 2017).

Bandyopadhyay و Guha ألقيا الضوء بشكل أكبر على القيود المتعلقة بتقنيات السلاسل الزمنية، وخصوصًا أوجه القصور في نموذج ARIMA للتنبؤ بأسعار الذهب. نظرًا لأن أسعار الذهب تظهر عدم خطية ملحوظة، فإن فعالية نموذج ARIMA تقتصر على التنبؤات قصيرة المدى التي تعتمد على التغيرات الطفيفة في البيانات المتاحة (Guha & Bandyopadhyay, 2016).

بدلاً من ذلك، اقترح "Georgia" وآخرون استخدام نموذج نظام الاستدلال العصبي الضبابي التكيفي (ANFIS) كبديل أفضل لنماذج AR و ARMA و ARIMA في التنبؤ بأسعار الذهب. تبرز دراستهم الأداء التنبؤ القوي لنموذج ANFIS وتوصي بتطبيق النماذج القائمة على الشبكات العصبية الضبابية في التنبؤ بأسعار السلع الأساسية الأخرى (Georgia et al., 2013).

في دراسة أخرى، قدم "Hadavandi" وآخرون نموذجًا للسلاسل الزمنية يعتمد على نهج تحسين سرب الجسيمات (PSO) للتنبؤ بأسعار الذهب بدقة. أظهرت نتائج بحثهم فعالية هذا النموذج في إدارة التقلبات وتحقيق دقة تنبؤ عالية، مما يجعله أداة مناسبة للتعامل مع تحديات التنبؤ المالي (Hadavandi, 2010) (Ghanbari, & Abbasian-Naghnesh, 2010).

جرى "Li و Liu" بحثًا حول التنبؤ باتجاه تقلب أسعار الذهب، واقترحوا طريقة الغابة العشوائية لتحقيق ذلك. أكدوا على أهمية التنبؤ الدقيق باتجاهات أسعار الذهب، وحددوا عوامل مختلفة تم أخذها في الاعتبار. ومع ذلك، فإن جمع البيانات لعوامل متعددة يمكن أن يكون تحديًا. أظهرت تجاربهم المكثفة مع البيانات الواقعية أن طريقة الغابة العشوائية كانت قوية في التنبؤ باتجاهات أسعار الذهب. بينت نتائجهم أن عاملين فقط، هما مؤشر داو جونز الصناعي ومؤشر إس بي 500، كانا حاسمين لتحقيق تنبؤات دقيقة باستخدام هذه الخوارزمية (Liu & Li, 2017).

استخدم "Madziwa" وآخرون نموذج (ARDL) للتنبؤ بأسعار الذهب السنوية، ووجدوا أنه يتفوق على نهج العودة إلى المتوسط العشوائي و (ARIMA). أكدت نتائجهم على التأثير الكبير للطلب على الذهب

على الأسعار، بينما أشارت إلى أن أسعار سندات الخزنة لم يكن لها تأثير ملحوظ (Madziwa et al., 2022).

اقترح "Li" نهجًا للتنبؤ بسعر الذهب يجمع بين شبكة عصبية بالترددات الموجية (Wavelet Neural Network) وخوارزمية (ABC) جديدة. تقدم الخوارزمية المحسنة بديلاً لاستراتيجية اختيار سلسلة الثقوب الفاصلة التقليدية (Roulette)، وتدمج رسائل ردود الفعل من حالات التقارب للتكرارات السابقة. أظهرت النتائج التجريبية أن هذه الخوارزمية الجديدة تُظهر تقاربًا أسرع عند تطبيقها على وظائف المقارنة، وتعزز بشكل فعال قدرة النمذجة لشبكة (WNN) للتنبؤ بأسعار الذهب (Li, 2014).

طور "Huang و Chen" خوارزميات باستخدام ميزات إدخال مختلفة، بما في ذلك أسعار الذهب والمؤشرات المالية، للتنبؤ بدقة باتجاهات أسعار الأسهم. حقق نهجهم المقترح معدل دقة بنسبة 67% وأظهر عائداً أعلى على الاستثمار مقارنة بالنماذج الأخرى، مما يبرز أهمية مراعاة عوامل الذهب والنفط الخام لصناعات محددة (Chen & Huang, 2021).

قام "Verma" وآخرون بتحسين التنبؤ بأسعار الذهب في السوق الهندية باستخدام تقنيات الشبكة العصبية الاصطناعية المعدلة (ANN)، مما أدى إلى تحسين الكفاءة. طور "Mohtasham Khani" وآخرون نموذجًا قائمًا على LSTM للتنبؤ بسوق الأوراق المالية أثناء جائحة COVID-19، مستخدمين ميزات مثل حالات COVID-19 ومؤشرات السوق. حقق ناتج تسلسل المتجهات LSTM أفضل أداء بين طرق أخرى. تساهم هذه الدراسات بشكل جماعي في استكشاف الأدوات التقليدية الإحصائية وتقنيات التعلم الآلي للتنبؤ بأسعار الذهب، مما يوفر جوانب مختلفة من مزايا وعيوب النماذج المختلفة. تهدف هذه المقالة إلى فحص فعالية أدوات تحليل الاتجاه ونماذج LSTM للتنبؤ بأسعار الذهب (Verma et al., 2020؛ Mohtasham Khani et al., 2021).

3. منهجية الدراسة

يهدف هذا الفصل إلى تقديم وصف تحليلي للمنهجية المستخدمة في التنبؤ بأسعار الذهب عبر نماذج التعلم الآلي. تم اختيار هذه المنهجية نظرًا لأهميتها في تحليل البيانات واستخلاص الأنماط والعلاقات بين المتغيرات.

بدأت الدراسة بجمع البيانات من قاعدة بيانات "Datasets Gold Prices"، التي تتضمن 180 سجلًا شهريًا لأسعار الذهب على مدى سنوات من عام 2010 إلى 2024. خضعت هذه البيانات لعمليات تنقية وتحليل دقيقة لإزالة القيم المفقودة، وأخطاء الإدخال. ركز التحليل على البيانات الشهرية المتعلقة بالتاريخ والسعر، مما أتاح فهمًا عميقًا للتغيرات الزمنية والعوامل المؤثرة على أسعار الذهب.

1.3 اعداد بيئة البيانات

تم استخدام لغة البرمجة Python ومكتبات `Pandas` لتحليل البيانات حيث تم تنفيذ الخطوات التالية:

1. استدعاء المكتبات:

```
import pandas as pd
data = pd.read_csv ('monthly_gold_prices.csv')
print(data.head())
```

2. عرض البيانات CSV : يتم عرض البيانات من ملف CSV باستخدام مكتبة Pandas حيث تم عرض مجموعة من البيانات عن طريق دالة ((print (data. Head (20)) لتأكيد نجاح عملية قراءة البيانات.

جدول 1: عرض البيانات للمتغيرات: النتائج مستخرجة من مكتبة Pandas لتحليل البيانات من مجموعة بيانات "Datasets Gold Prices".

	DATE	GOLDPRICE;
0	2010-01	1119.575;
1	2010-02	1095.800;
2	2010-03	1115.554;
3	2010-04	1148.475;
4	2010-05	1204.321;
5	2010-06	1232.382;
6	2010-07	1196.000;
7	2010-08	1213.464;
8	2010-09	1271.461;
9	2010-10	1343.190;
10	2010-11	1371.784;
11	2010-12	1393.512;
12	2011-01	1360.475;
13	2011-02	1371.313;
14	2011-03	1422.848;
15	2011-04	1474.431;
16	2011-05	1512.188;
17	2011-06	1528.380;
18	2011-07	1568.526;
19	2011-08	1759.500;

3. تحليل الاتجاه (Trend Analysis) حساب المتوسط المتحرك البسيط (SMA):

المتوسط المتحرك البسيط (SMA) هو أداة تحليلية تُستخدم لتحديد الاتجاهات في البيانات الزمنية. يتم حساب SMA عن طريق أخذ متوسط مجموعة من القيم على فترة زمنية محددة. تم استخدام فترتين زمنيتين لتحليل المتوسط المتحرك البسيط (SMA) فترة 12 شهرًا وفترة 180 شهرًا. يهدف SMA لفترة 12 شهرًا إلى تحليل الاتجاهات قصيرة الأمد والتغيرات الموسمية، بينما يهدف SMA لفترة 180 شهرًا إلى تحليل الاتجاهات طويلة الأمد الأسعار الفعلية (Price) يعرض هذا الخط

التغيرات الشهرية في أسعار الذهب المتوسط المتحرك البسيط لفترة 12 شهراً (SMA_12) يعرض هذا الخط الاتجاهات قصيرة الأمد في الأسعار، مما يساعد في تحديد التغيرات الموسمية والاتجاهات السنوية. المتوسط المتحرك البسيط لفترة 180 شهراً (SMA_180) يعرض هذا الخط الاتجاهات طويلة الأمد في الأسعار، مما يساعد في تنعيم التقلبات القصيرة الأمد وتقديم رؤية واضحة للاتجاهات العامة على مدى فترة طويلة.

والسبب في عدم وجود قيم في عمود SMA_180 هو أن المتوسط المتحرك البسيط (SMA) لفترة 180 شهراً يتطلب 180 شهرًا من البيانات ليتم حسابه في الأشهر الأولى من البيانات، لا يوجد عدد كافٍ من الأشهر السابقة لحساب المتوسط المتحرك لفترة 180 شهراً، لذا تظهر القيم كـ (Not a Number).

جدول 2: عرض البيانات للمتغيرات (مستخرجة من Pandas مكتبة لتحليل البيانات من مجموعة بيانات "Datasets Gold Prices").


	Date	Price	SMA_12	SMA_180
0	2010-01	1119.575	NaN	NaN
1	2010-02	1095.800	NaN	NaN
2	2010-03	1115.554	NaN	NaN
3	2010-04	1148.475	NaN	NaN
4	2010-05	1204.321	NaN	NaN
5	2010-06	1232.382	NaN	NaN
6	2010-07	1196.000	NaN	NaN
7	2010-08	1213.464	NaN	NaN
8	2010-09	1271.461	NaN	NaN
9	2010-10	1343.190	NaN	NaN
10	2010-11	1371.784	NaN	NaN
11	2010-12	1393.512	1225.459833	NaN
12	2011-01	1360.475	1245.534833	NaN
13	2011-02	1371.313	1268.494250	NaN
14	2011-03	1422.848	1294.102083	NaN
15	2011-04	1474.431	1321.265083	NaN
16	2011-05	1512.188	1346.920667	NaN
17	2011-06	1528.380	1371.587167	NaN
18	2011-07	1568.526	1402.631000	NaN
19	2011-08	1759.500	1448.134000	NaN

Gold Prices with 12-Month and 180-Month SMA

4. الرسم البياني للأسعار الفعلية (Price) يتم عرضها كخط بياني يمثل التغيرات الشهرية في أسعار الذهب، حيث يعرض هذا الخط التغيرات الشهرية في أسعار الذهب. يمكن أن ترى التقلبات اليومية والشهرية في الأسعار، مما يعكس التغيرات الفورية في السوق.

المتوسط المتحرك البسيط لفترة 12 شهراً (SMA_12) يتم عرضه كخط بياني برتقالي يمثل الاتجاهات قصيرة الأمد في الأسعار حيث يعرض هذا الخط الاتجاهات قصيرة الأمد في أسعار الذهب في تحديد التغيرات

الموسمية والاتجاهات السنوية يمكنك ملاحظة كيف يتبع هذا الخط الأسعار الفعلية بشكل أكثر قرباً، مما يعكس التغيرات السريعة في السوق.



الشكل 2: الرسم البياني للأسعار الفعلية (SMA)

5. بناء نموذج LSTM (Long Short-Term Memory): تجهيز البيانات وتحويلها إلى نطاق 0 و1 باستخدام MinMaxScaler ثم تقسيمها إلى مجموعات تدريب واختبار.

بناء نموذج LSTM باستخدام مكتبة "Keras" لتحليل البيانات الزمنية. يتكون النموذج من طبقتين من LSTM طبقة كثيفة (Dense) وطبقة إخراج. تم استخدام محسن "adam" ودالة خسارة "mean_squared_error" لتجميع النموذج. تم تدريب النموذج باستخدام بيانات التدريب على دفعات صغيرة. حيث تم بناء النموذج، إضافة طبقة ادخال، إضافة طبقة الاولي من LSTM، إضافة الطبقة الثانية من LSTM، إضافة طبقة Dense، إضافة طبقة الإخراج، تجميع النموذج، تدريب النموذج.

6. اجراء التنبؤات باستخدام النموذج LSTM المتوقع للأسعار المستقبلية: تم استخدام نموذج LSTM المدرب للتنبؤ بأسعار الذهب، تم تقسيم بيانات التنبؤ إلى دفعات صغيرة لتسريع عملية التنبؤ، النتائج تشير إلى عدد الدفعات والوقت المستغرق لكل خطوة تنبؤ، نتائج التنبؤ على بيانات التدريب: عدد الدفعات 5 دفعات الوقت المستغرق لكل خطوة تنبؤ حوالي 7 ملي ثانية

5/5 ————— s 7ms/step0

نتائج التنبؤ على بيانات الاختبار

عدد الدفعات: دفعة واحدة الوقت المستغرق لكل خطوة تنبؤ حوالي 53 ملي ثانية.


1/1 ————— s 53ms/step0

الرسم البياني الناتج من عملية التنبؤ باستخدام نموذج LSTM يعرض مقارنة بين الأسعار الفعلية والتوقعات التي تم الحصول عليها من النموذج.

الأسعار الفعلية (Actual Prices) يعرض هذا الخط التغيرات الشهرية في أسعار الذهب، مما يعكس البيانات الحقيقية.

التوقعات على بيانات التدريب (Train Predict) يعرض هذا الخط التوقعات التي تم الحصول عليها من النموذج باستخدام بيانات التدريب. إذا كان هذا الخط قريباً من الخط الفعلي، فهذا يعني أن النموذج يتعلم بشكل جيد من البيانات.

التوقعات على بيانات الاختبار (Test Predict) يعرض هذا الخط التوقعات التي تم الحصول عليها من النموذج باستخدام بيانات الاختبار. إذا كان هذا الخط قريباً من الخط الفعلي، فهذا يعني أن النموذج قادر على التنبؤ بالأسعار بشكل دقيق باستخدام بيانات جديدة كما موضح في الشكل (3)



الشكل 3: التنبؤ باستخدام نموذج LSTM

7. تحليل الاتجاه باستخدام نموذج الانحدار الخطي: تم استخدام نموذج الانحدار الخطي لتحليل الاتجاه في أسعار الذهب. يتضمن الناتج التالي إعداد البيانات، بناء النموذج، والتنبؤ بالقيم المستقبلية. كما هو موضح في الجدول رقم (3).

جدول: 3 تحليل الاتجاه نموذج الانحدار الخطي مستخرجة من مكتبة Pandas لتحليل البيانات مجموعة بيانات "Datasets"

Gold Prices

```
[1528.06855993 1529.61467144 1531.16078295 1532.70689445 1534.25300596
1535.79911747 1537.34522897 1538.89134048 1540.43745198 1541.98356349
1543.529675 1545.0757865 1546.62189801 1548.16800952 1549.71412102
1551.26023253 1552.80634404 1554.35245554 1555.89856705 1557.44467856
1558.99079006 1560.53690157 1562.08301307 1563.62912458 1565.17523609
1566.72134759 1568.2674591 1569.81357061 1571.35968211 1572.90579362
1574.45190513 1575.99801663 1577.54412814 1579.09023965 1580.63635115
1582.18246266]
```

الناتج هو مجموعة من القيم المتنبئ بها لأسعار الذهب المستقبلية. هذه القيم تمثل الاتجاه المتوقع للأسعار بناءً على نموذج الانحدار الخطي الذي تم تدريبه على بيانات التدريب. القيم المتنبئ بها الأرقام التي تراها هي القيم المتنبئ بها لأسعار الذهب في الأشهر المستقبلية. على سبيل المثال، القيمة الأولى 1528.06855993 تمثل السعر المتوقع للشهر الأول بعد فترة التدريب، والقيمة الثانية 1529.61467144 تمثل السعر المتوقع للشهر الثاني، وهكذا. الاتجاه العام: هذه القيم تظهر الاتجاه العام المتوقع للأسعار بناءً على البيانات التاريخية. إذا كانت القيم تزداد بمرور الوقت، فهذا يشير إلى اتجاه صعودي في الأسعار، وإذا كانت تتخفف، فهذا يشير إلى اتجاه هبوطي.

4. عرض النتائج

في هذا الفصل، نستعرض نتائج الدراسة التي تم الحصول عليها من خلال تحليل البيانات باستخدام نموذج LSTM وأداة تحليل الاتجاه التقليدية، تم تقييم أداء النموذجين باستخدام معايير الدقة المختلفة مثل RMSE و MAE

1.4 تقييم أداء النماذج باستخدام RMSE و MAE

تم تقييم أداء نموذج LSTM ونموذج تحليل الاتجاه (Trend Analysis) باستخدام الجذر التربيعي لمتوسط الخطأ التربيعي (RMSE) ومتوسط الخطأ المطلق (MAE). النتائج تشير إلى أن نموذج LSTM يقدم تنبؤات أكثر دقة مقارنة بنموذج تحليل الاتجاه كما هو موضح في الجدول أدناه.


جدول 4 أداء النماذج باستخدام MAE-RMSE النتائج من مكتبة Pandas لتحليل البيانات مجموعة بيانات "Datasets Gold Prices".

المعيار	نموذج LSTM	نموذج تحليل الاتجاه
RMSE	420.56	598.29
MAE	390.86	525.55

2.4 رسم التنبؤات بأسعار الذهب باستخدام النماذج

تم استخدام مكتبة Matplotlib لرسم التنبؤات بأسعار الذهب باستخدام نماذج مختلفة. حيث يتضمن إعداد البيانات، تعديل المحور السيني، ورسم البيانات الفعلية والتنبؤات. كما هو موضح في الشكل رقم (4)

Actual Prices يعرض هذا الخط الأسعار الفعلية للذهب.
LSTM Predictions يعرض هذا الخط التنبؤات التي تم الحصول عليها من نموذج LSTM.
Trend Analysis Predictions يعرض هذا الخط التنبؤات التي تم الحصول عليها من نموذج تحليل الاتجاه.



الشكل (4) التنبؤ بأسعار الذهب باستخدام النماذج

3.4 مقارنة أداء النموذجين LSTM ونموذج تحليل الاتجاه

يمكن أن تختلف الأخطاء بين نموذج LSTM ونموذج تحليل الاتجاه بناءً على طبيعة عمل كل منهما وطريقة تعاملهما مع البيانات. هناك بعض النقاط المحتملة لتحليل الأخطاء كما موضح في الجدول أدناه.

جدول رقم 5 مقارنة أداء النماذج (النتائج مستخرجة من الدراسة الخاصة بالمؤلفين .)

المتغير المستقل	نموذج LSTM (التأثير والسبب)	نموذج تحليل الاتجاه (التأثير والسبب)
عدد النقاط الزمنية	يحسن الأداء (تعلم الأنماط المتكررة)	غير متأثر بشكل كبير
نوع المتغيرات	يؤثر على دقة التنبؤ (تعلم الأنماط الدورية)	غير متأثر بشكل كبير
درجة التعقيد	يحسن الأداء (استخلاص الأنماط الدقيقة)	يتدهور الأداء (غير مهياً للتعقيدات)
استقرار الاتجاهات	أقل تأثراً بالاستقرار	يتحسن الأداء مع الاستقرار
التغيرات المفاجئة	أقل تأثراً (نموذج أكثر تكيفاً)	يتدهور الأداء (غير مهياً للتغيرات)
المدخلات المتعددة	يحسن الأداء (يستفيد من تعدد المدخلات)	يتدهور الأداء (لا يستوعب تعدد المتغيرات)

5. التوصيات والاستنتاجات

- بناءً على الدراسة التي قمنا بها حول التنبؤ بأسعار الذهب باستخدام نماذج LSTM والانحدار الخطي، يمكننا تقديم بعض التوصيات:
- تشجيع على تطوير نماذج LSTM أكثر تعقيداً وملاءمة للبيانات الزمنية طويلة الأمد
 - استكشاف نماذج جديدة تجمع بين ميزات LSTM ونماذج تحليل الاتجاه للاستفادة من قدرات كلا النوعين .
 - تحليل متعمق للمتغيرات المستقلة وكيفية تأثيرها على أداء النماذج المختلفة.
 - ممكن تحسين دقة التنبؤات من خلال تضمين المزيد من العوامل المؤثرة في أسعار الذهب، مثل أسعار النفط، ومؤشرات الأسهم، والأحداث الاقتصادية العالمية.
 - يمكن دمج نقاط القوة في كلا النموذجين للحصول على تنبؤات أكثر دقة. على سبيل المثال، يمكن استخدام نموذج LSTM لتحديد الاتجاهات العامة ونموذج الانحدار الخطي لتحليل التغيرات القصيرة الأجل.
 - التحديث المستمر للنماذج يجب تحديث النماذج بشكل دوري لضمان دقتها وملاءمتها للظروف الحالية في السوق.
 - دراسة طرق تحسين التعامل مع البيانات المفقودة أو المتقطعة.
 - تمويل مشاريع بحثية تطبيقية تهدف إلى تحسين نماذج LSTM واستخدامها في مجالات مختلفة مثل التنبؤ المالي، والرعاية الصحية، وغيرها.

المصادر والمراجع

- Shafiee, S., & Topal, E. (2010). An overview of global gold market and gold price forecasting. *Resource Policy*, 35(3), 178-189.
- Raghuram, K. S. "Statistical, machine learning predictive analytics and the impact of stock market indicators in predicting gold prices." [No publication date available]
- Khani, M. M., Vahidnia, S., & Abbasi, A. (2020). "A deep learning based methods for forecasting gold price with respect to pandemics."
- Manjula, K. A., & Karthikeyan, P. (2019). "Gold price prediction using ensemble based machine learning techniques." *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI), IEEE*.
- Murphy, J. J. (1999). "Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications." *New York Institute of Finance*.
- Hochreiter, S., & Schmidhuber, J. (1996). "LSTM can solve hard long time lag problems." *Proceedings of the 9th International Conference on Neural Information Processing Systems (NIPS'96), Cambridge, MA, USA: MIT Press*, pp. 473-479.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). "Learning to Forget: Continual Prediction with LSTM." *Neural Computation*, 12(10), 2451-2471.
doi:10.1162/089976600300015015.
- Shahriar, S., & Topal, E. (2010). "Resources policy." *vol. 35, no. 3*.
- Naliniprava, T. (2017). "International Journal of Economics and Financial Issues." *vol. 7, no. 4*.
- Guha, B., & Bandyopadhyay, G. (2016). "Journal of Advanced Management Science." *vol. 4, no. 2*.
- Georgia, M., et al. (2013). "International Journal of Financial Engineering and Risk Management." *vol. 2, no. 1*.
- Hadavandi, E., Ghanbari, A., & Abbasian-Naghneh, S. (2010). "Developing a time series model based on particle swarm optimization for gold price forecasting." *Third International Conference on Business Intelligence and Financial Engineering, IEEE*.
- Liu, D., & Li, Z. (2017). "Gold price forecasting and related influence factors analysis based on random forest." *Proceedings of the Tenth International Conference on Management Science and Engineering Management, Springer Singapore*.

Madziwa, L., et al. (2022). "Resources Policy." *vol. 76*.

Li, B. (2014). "Computational intelligence and neuroscience."

Chen, Y. C., & Huang, W. C. (2021). "Applied Soft Computing." *vol. 112*.

Verma, S., et al. (2020). "IAES International Journal of Artificial Intelligence." *vol. 9, no. 1*.

Mohtasham Khani, M., et al. (2021). "SN Computer Science." *vol. 2, no. 4*.