

اختبار قدرة نماذج التعلم العميق (LSTM و Transformers) على التنبؤ بالسلوك السعري  
لمؤشر S&P 500: (دراسة تجريبية)

Testing the Ability of Deep Learning Models (LSTM and Transformers) to Predict the Price Behavior  
of the S&P 500 Index: An Empirical Study

محمد يزيد صالح<sup>1\*</sup>، أسماء كسري<sup>2</sup>

<sup>1</sup> جامعة باجي مختار، عنابة (الجزائر) (Mohamed-yazid.salhi@univ-annaba.dz)

<sup>2</sup> المدرسة العليا لعلوم التسيير، عنابة (الجزائر) (Kesri.asma@essg-annaba.dz)

تاريخ الاستلام: 2026/03/25؛ تاريخ القبول: 2026/04/25؛ تاريخ النشر: 2026/06/01

**ملخص:** تهدف هذه الدراسة إلى اختبار قدرة نماذج التعلم العميق LSTM و Transformers على التنبؤ بالسلوك السعري لمؤشر S&P 500 مع التركيز على مقارنة أداء النموذجين في ظل سيناريوهات السوق المختلفة. اعتمدت الدراسة على المنهج التجريبي الكمي، باستخدام بيانات يومية لمؤشر S&P 500 خلال الفترة من جانفي 2015 إلى ديسمبر 2023، بإجمالي 2264 يوم تداول. تم بناء نموذجين رئيسيين: الأول يعتمد على بنية LSTM ثلاثي الطبقات، والثاني يعتمد على بنية Transformer مخصصة للبيانات المالية. تم تقييم أداء النموذجين باستخدام أربعة مقاييس رئيسية: جذر متوسط مربعات الخطأ (RMSE)، متوسط الخطأ المطلق (MAE)، متوسط نسبة الخطأ المطلق (MAPE)، والدقة الاتجاهية (Directional Accuracy). كما تم استخدام اختبار t للعينات المزدوجة واختبار Wilcoxon للتحقق من دلالة الفروق إحصائيا. أظهرت النتائج تفوقا واضحا لنموذج LSTM على Transformer في جميع مقاييس الأداء. فقد حقق LSTM قيمة RMSE بلغت 79.86 مقارنة بـ 145.19 لـ Transformer، وسجل الدقة الاتجاهية 51.22% مقابل 48.17% لـ Transformer. كما أظهرت الاختبارات الإحصائية وجود فروق ذات دلالة إحصائية بين أداء النموذجين عند مستوى معنوية 0.05، مما يؤكد تفوق LSTM في هذا السياق التجريبي.

**الكلمات المفتاح:** تعلم عميق، LSTM، Transformers، التنبؤ المالي، مؤشر S&P 500.

**تصنيف JEL:** C45؛ C53؛ G17.

**Abstract:** This study aims to test the ability of deep learning models (LSTM and Transformers) to predict the price behavior of the S&P 500 index, with a focus on comparing the performance of both models under different market scenarios.

The study adopted a quantitative experimental approach, using daily data of the S&P 500 index from January 2015 to December 2023, with a total of 2,264 trading days. Two main models were constructed: a three-layer LSTM model and a Transformer model customized for financial data. The performance of both models was evaluated using four main metrics: Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), and Directional Accuracy. Paired samples t-test and Wilcoxon test were used to verify the statistical significance of differences.

The results showed a clear superiority of the LSTM model over the Transformer in all performance metrics. The LSTM achieved an RMSE of 79.86 compared to 145.19 for the Transformer, and recorded a directional accuracy of 51.22% compared to 48.17% for the Transformer. Statistical tests showed significant differences between the performance of the two models at the 0.05 significance level.

**Keywords:** Deep Learning; LSTM; Transformers; Financial Forecasting; S&P 500 Index.

**Jel Classification Codes :** C45; C53; G17.

## I - تمهيد :

تشهد الأسواق المالية الحديثة تطوراً متسارعاً نتيجة التقدم التكنولوجي، خاصة في مجال تحليل البيانات واتخاذ القرارات الاستثمارية. وفي هذا السياق، برزت تقنيات الذكاء الاصطناعي، ولا سيما نماذج التعلم العميق، كأدوات فعالة لتحليل السلاسل الزمنية واستخلاص الأنماط المعقدة منها. وبالمقارنة مع النماذج الإحصائية التقليدية التي تعتمد غالباً على افتراضات خطية، توفر نماذج التعلم العميق قدرة أكبر على تمثيل العلاقات غير الخطية والتفاعلات الديناميكية داخل البيانات المالية، وهو ما يجعلها أكثر ملاءمة لطبيعة الأسواق التي تتسم بالتقلب وعدم اليقين (Yu & Yan, 2020; Kurani et al., 2023).

إذ تعد نماذج الذاكرة طويلة وقصيرة المدى (LSTM) من أبرز النماذج المستخدمة في هذا المجال، نظراً لقدرتها على التعامل مع الاعتماد الزمني طويل الأمد ومعالجة مشكلة تلاشي التدرجات التي تعاني منها الشبكات العصبية التقليدية (Hochreiter & Schmidhuber, 1997). وقد أثبتت هذه النماذج كفاءتها في العديد من تطبيقات التنبؤ المالي في الأسواق المالية (Gao et al., 2020; Chhajer et al., 2022). في المقابل، ظهرت نماذج المحولات (Transformers) كاتجاه حديث يعتمد على آلية الانتباه الذاتي، مما يتيح للنموذج التركيز على العلاقات بين مختلف نقاط السلسلة الزمنية بغض النظر عن المسافة الزمنية بينها، وهو ما يمنحها قدرة عالية على معالجة التبعيات طويلة المدى (Vaswani et al., 2017; Li & Shi, 2024).

ورغم هذا التطور، لا يزال هناك تباين في نتائج الدراسات السابقة بشأن النموذج الأكثر كفاءة في التنبؤ بالأسواق المالية، خاصة في ظل اختلاف خصائص البيانات وأحجامها وأفق التنبؤ المستخدم، الأمر الذي يبرز الحاجة إلى دراسات مقارنة تعتمد على إطار منهجي موحد. وعلى الرغم من التوسع الكبير في تطبيقات التعلم العميق في المجال المالي خلال السنوات الأخيرة، إلا أن الأدبيات البحثية لا تزال تفتقر إلى إجماع حول أي من البنى العصبية العميقة الأكثر ملاءمة للتنبؤ بتحركات المؤشرات الرئيسية، خاصة في ظل ظروف السوق المتقلبة. ويتجلى هذا الغموض بشكل خاص عند المقارنة بين نماذج LSTM التي طالما اعتبرت المعيار المرجعي في نمذجة السلاسل الزمنية المالية، وبين نماذج Transformers التي أظهرت نتائج واعدة في التطبيقات الحديثة.

تتبع المشكلة البحثية الأساسية من ثلاث تحديات رئيسية تواجه الدراسات التجريبية في هذا المجال، أولها غياب معايير مقارنة موحدة، إذ تتباين الدراسات السابقة في معايير التقييم وفترات التحليل ومجموعات البيانات المستخدمة، مما يجعل من الصعب إجراء مقارنات موضوعية بين أداء النماذج المختلفة. فقد لاحظ الباحثان أن معظم الدراسات المقارنة اعتمدت على مقاييس أداء مختلفة، مما حال دون الوصول إلى استنتاجات قابلة للتعميم. (Murray et al., 2023).

من جهة أخرى محدودة تغطية الفترات الحرجة، إذ تعتمد الغالبية العظمى من الدراسات السابقة على بيانات تنتهي قبل عام 2020، مما يجعلها غير قادرة على اختبار أداء النماذج في ظل التقلبات الاستثنائية التي شهدتها الأسواق خلال أزمة كوفيد-19 وموجة التضخم اللاحقة. وهذه الفجوة جوهرية، حيث أن قدرة النماذج على التكيف مع التحولات الهيكلية في الأسواق تمثل اختباراً حقيقياً لقيمتها التطبيقية (Osman, 2025).

كما أنه هناك ندرة في الأبحاث التي تقدم إطاراً عملياً، حيث نادراً ما تقدم إطاراً عملياً يمكن للمستثمرين وصناع القرار الاستفادة منه مباشرة. كما أن معظم الدراسات تركز على مقاييس الدقة الإحصائية دون ربطها بمقاييس الأداء الاستثماري الفعلية. (Kim et al., 2024) ضمن هذا المنطلق، يمكن صياغة إشكالية الدراسة على النحو التالي:

ما مدى قدرة نماذج التعلم العميق LSTM و Transformers على التنبؤ بالسلوك السعري لمؤشر S&P 500، وكيف يمكن

بناء إطار مقارن موحد لتقييم أدائها في ظل سيناريوهات السوق المختلفة؟

وللإجابة عن هذه الإشكالية، تم وضع التساؤلات الفرعية التالية:

- أي النموذجين LSTM أم Transformers يظهر دقة تنبؤية أعلى لتحركات مؤشر S&P 500 ؟
- كيف تؤثر ظروف السوق المختلفة على الأداء النسبي للنموذجين؟
- ما هي المفاضلة بين التكلفة الحسابية والدقة التنبؤية لكل نموذج؟

ولاختبار هذه التساؤلات، تم صياغة الفرضيات التالية:

- (H<sub>01</sub>): لا توجد فروق ذات دلالة إحصائية في دقة التنبؤ بين نموذج Transformers ونموذج LSTM.
- (H<sub>02</sub>): لا توجد فروق ذات دلالة إحصائية في الدقة الاتجاهية بين النموذجين.
- (H<sub>03</sub>): لا يؤثر نوع النموذج على دقة التنبؤ بدرجة ذات دلالة إحصائية.

وتكتسب هذه الدراسة أهميتها من ثلاثة أبعاد رئيسية:

- تسهم الدراسة في إثراء الأدبيات الأكاديمية حول تطبيقات الذكاء الاصطناعي في الأسواق المالية من خلال تقديم مقارنة منهجية موحدة بين نموذجين محوريين في هذا المجال، وذلك باستخدام أحدث البيانات المتاحة حتى نهاية عام 2023.
  - تقدم الدراسة إطاراً مقارناً متكاملًا يجمع بين أربعة مقاييس أداء رئيسية (MAPE، MAE، RMSE)، الدقة الاتجاهية، مما يتيح تقييمًا شاملاً لأداء النماذج.
  - تزود الدراسة صناع القرار والمستثمرين بإطار عملي يمكنهم من اختيار النموذج الأنسب وفقًا لاستراتيجياتهم الاستثمارية.
- وقد تم تقسيم هذه الورقة البحثية إلى خمسة محاور رئيسية. يتناول المحور الأول الإطار النظري والمراجعة النقدية للأدبيات السابقة. ويعرض المحور الثاني المنهجية التحريمية بالتفصيل. أما المحور الثالث فيعرض النتائج الكمية للتحليل التحريبي. ويقدم المحور الرابع مناقشة مستفيضة لهذه النتائج. وأخيرًا، يخلص المحور الخامس إلى الاستنتاجات الأساسية والتوصيات العملية.

## I.1- الإطار النظري ومراجعة الأدبيات:

### 1) الأسس النظرية للتنبؤ في الأسواق المالية:

تعد الأسواق المالية من الأنظمة المعقدة التي تنسم بدرجة عالية من الديناميكية وعدم الخطية، حيث تتأثر بتفاعل مجموعة واسعة من العوامل الاقتصادية والمالية والنفسية، مما يجعل عملية التنبؤ بحركتها المستقبلية مسألة شديدة التعقيد. (Belhoula et al., 2023) وقد شكلت نظرية كفاءة السوق إطاراً تفسيرياً مهماً في هذا السياق، إذ تفترض أن الأسعار تعكس جميع المعلومات المتاحة، الأمر الذي يحد من إمكانية تحقيق تنبؤات دقيقة بشكل منهجي. (Fama, 1970; Zebende et al., 2022)

غير أن العديد من الدراسات الحديثة أظهرت وجود انحرافات عن هذه الفرضية، خاصة في ظل بروز سلوكيات غير عقلانية لدى المستثمرين والتقلبات الحادة التي لا يمكن تفسيرها بالنماذج التقليدية فقط، مما فتح المجال أمام استخدام نماذج أكثر مرونة تعتمد على التعلم من البيانات التاريخية. (Kurani et al., 2023; Yu & Yan, 2020)

وتعود جذور التنبؤ المالي إلى نظرية كفاءة السوق التي صاغها (Fama 1970)، والتي تفترض أن الأسعار تعكس كامل المعلومات المتاحة، مما يجعل التنبؤ المنهجي بالأسعار مستحيلًا. غير أن الانتقادات الموجهة لهذه النظرية، خاصة من مدرسة التمويل السلوكي، أظهرت وجود انحرافات متكررة عن الكفاءة بسبب سلوكيات المستثمرين غير العقلانية كالثقة المفرطة والسلوك القطيعي. وهذا ما يفسر الحاجة إلى نماذج تعلم قادرة على استخلاص الأنماط من البيانات التاريخية.

### 2) نماذج LSTM في التنبؤ المالي:

تمثل نماذج الذاكرة طويلة وقصيرة المدى (LSTM) أحد أهم تطورات الشبكات العصبية المتكررة، حيث تم تصميمها لمعالجة مشكلة تلاشي التدرجات التي تعيق تعلم العلاقات الزمنية طويلة الأمد (Hochreiter & Schmidhuber, 1997). وتعتمد هذه النماذج على بنية داخلية قائمة على بوابات تحكم تسمح بتنظيم تدفق المعلومات داخل الشبكة، مما يمكنها من الاحتفاظ بالمعلومات المهمة لفترات زمنية أطول. وتتكون خلية LSTM من ثلاث بوابات تحكم رئيسية: بوابة النسيان (Forget Gate) التي تحدد أي معلومات يجب التخلص منها من حالة الخلية السابقة، وبوابة الإدخال (Input Gate) التي تحدد أي معلومات جديدة يجب تخزينها، وبوابة الإخراج (Output Gate) التي تحدد أي جزء من حالة الخلية يجب إخراجها كتنبؤ. هذه البنية تمكن النموذج من التعامل مع التبعيات الزمنية طويلة المدى التي تميز السلاسل الزمنية المالية، حيث يمكن أن تؤثر صدمة سعرية اليوم على الأسعار بعد أشهر.

وقد أظهرت العديد من الدراسات التطبيقية قدرة هذه النماذج على تحقيق أداء جيد في التنبؤ بالسلاسل الزمنية المالية، خاصة في الحالات التي تتسم بوجود أنماط زمنية واضحة أو دورات سوقية نسبية (Gao et al., 2020; Chhajer et al., 2022).

### 3) نماذج Transformers في التنبؤ المالي:

شكل ظهور نموذج المحولات (Transformer) نقلة نوعية في مجال معالجة التتابعات الزمنية، حيث استبدلت آليات الانتباه الذاتي (Self-Attention) ببنية التكرار المتسلسل. وتعتمد هذه النماذج على مفهوم "الانتباه" الذي يسمح للنموذج بالتركيز على أجزاء مختلفة من تسلسل الإدخال عند توليد كل عنصر من عناصر الإخراج، مما يمكنه من التقاط العلاقات بين النقاط الزمنية المتباعدة. (Vaswani et al., 2017).

إذ تعتمد آلية الانتباه الذاتي (Self-Attention) على حساب ثلاث مصفوفات لكل عنصر في التسلسل الزمني: مصفوفة الاستعلام (Query)، ومصفوفة المفتاح (Key)، ومصفوفة القيمة (Value). ومن خلال مقارنة الاستعلام مع المفاتيح، يحصل النموذج على أوزان

انتباه تحدد درجة التركيز على كل نقطة زمنية سابقة. وهذه الآلية تسمح ل Transformer بالتقاط العلاقات بين النقاط الزمنية مهما كانت المسافة بينها، وهو ما يمثل ميزة نظرية مهمة مقارنة ب LSTM التي تعاني من تلاشي التدرجات في التتابعات الطويلة جدا. أظهرت الدراسات الحديثة تفوق نماذج Transformers في التعامل مع التبعيات طويلة المدى في البيانات المالية. فقد توصلت دراسة (Yu, 2024) إلى أن نموذج Transformer تفوق على LSTM في التنبؤ بأسعار الأسهم عند استخدام كميات كبيرة من البيانات.

#### 4) الدراسات المقارنة بين LSTM و Transformers

ترايدت في الدراسات التي تقارن بين أداء نماذج LSTM و Transformers في التنبؤ بالسلاسل الزمنية. وتشير بعض النتائج إلى تفوق نماذج Transformers من حيث القدرة على التقاط التبعيات طويلة الأمد، في حين تبرز نماذج LSTM كخيار أكثر استقرارا في حالات البيانات المحدودة (Murray et al., 2023; Yu, 2024).

ويعكس هذا التباين في النتائج تأثير مجموعة من العوامل، من بينها حجم البيانات، طبيعة السوق، وأفق التنبؤ المستخدم، مما يؤكد عدم وجود نموذج واحد متفوق بشكل مطلق في جميع الحالات.

على الرغم من المزايا النظرية لنموذج Transformers، إلا أن الأدبيات التجريبية لا تزال متباينة بشأن النموذج الأفضل للتنبؤ المالي. ففي حين تشير بعض الدراسات إلى تفوق Transformers في سياقات البيانات الضخمة (Yu, 2024)، تؤكد دراسات أخرى أن LSTM تظل أكثر كفاءة واستقرارا في حالات البيانات المحدودة أو المتوسطة (Murray et al., 2023). كما أن عامل أفق التنبؤ يلعب دورا حاسما، فنموذج LSTM يتفوق في التنبؤات قصيرة المدى (يوم إلى أسبوع)، بينما قد تظهر Transformers كفاءة أعلى في الآفاق متوسطة وطويلة المدى. هذا التباين يبرر الحاجة إلى دراسات مقارنة منهجية تراعي هذه العوامل، وهو ما تسعى هذه الدراسة إلى تقديمه.

#### 2.I- الفجوات البحثية ومبررات الدراسة الحالية:

بالرغم من الجهود البحثية المتزايدة، لا تزال هناك عدة فجوات تستدعي المزيد من البحث. فمن جهة، تفتقر العديد من الدراسات إلى إطار موحد للمقارنة بين النماذج، مما يصعب استخلاص نتائج قابلة للتعميم. ومن جهة أخرى، تعتمد أغلب الأبحاث على بيانات تاريخية تنتهي قبل الفترات التي شهدت اضطرابات حادة في الأسواق، مثل جائحة كوفيد-19. كما أن محدودية الدراسات التي تربط بين الأداء الإحصائي للنماذج والتطبيقات العملية في الاستثمار تبرز الحاجة إلى مقاربات أكثر تكاملا تجمع بين الدقة التنبؤية والقيمة التطبيقية. وبناء على ما سبق، تسعى هذه الدراسة إلى تقديم مقارنة تجريبية حديثة بين نمودي LSTM و Transformer باستخدام بيانات تمتد إلى عام 2023، ضمن إطار منهجي موحد.

#### II - الطريقة والأدوات:

اعتمدت هذه الدراسة على المنهجية الكمية التجريبية في تحقيق أهدافها واختبار فروضها. وتم تصميم البحث وفق نموذج المقارنة المعيارية بين مجموعتين تجريبتين رئيسيتين. ين، تمثل الأولى نموذج LSTM والثانية نموذج Transformers.

##### 1) مجتمع الدراسة وعينتها:

يتكون مجتمع الدراسة من بيانات مؤشر S&P 500، وهو المؤشر الرئيسي لسوق الأسهم الأمريكي. تكونت عينة الدراسة من البيانات اليومية لمؤشر S&P 500 خلال الفترة من 1 جانفي 2015 إلى 31 ديسمبر 2023، بإجمالي 2264 يوم تداول.

تم تقسيم البيانات إلى ثلاث مجموعات وفق تسلسل زمني صارم:

- مجموعة التدريب (70%): (Training Set) من البيانات (الفترة 2015-2020)

- مجموعة التحقق (15%): (Validation Set) من البيانات (عام 2021)

- مجموعة الاختبار (15%): (Test Set) من البيانات (الفترة 2022-2023)

##### 2) مصادر البيانات والمتغيرات: تم الحصول على البيانات من ثلاثة مصادر رئيسية:

- البيانات السعرية اليومية: Yahoo Finance API

- المتغيرات الاقتصادية الكلية: FRED Economic Data

- مؤشر التقلب: CBOE

تضمنت مجموعة البيانات 20 متغيرا موزعة على ثلاث فئات: المتغيرات السعرية (5 متغيرات)، المؤشرات الفنية (12 متغيراً)، والمتغيرات

الاقتصادية (3 متغيرات).

##### 3) بناء النماذج:

### ❖ نموذج LSTM :

تم بناء نموذج LSTM وفق الهيكل التالي:

-الطبقة الأولى LSTM: 128 وحدة مع return\_sequences=True

-طبقة Dropout: 0.2

-الطبقة الثانية LSTM: 64 وحدة مع return\_sequences=False

-طبقة Dropout: 0.2

-الطبقة الكثيفة: 32 وحدة (ReLU)

إذ تم اختيار دالة التنشيط **ReLU** للطبقات الكثيفة بدلا من **Tanh** لعدة اعتبارات نظرية وتجريبية. فطبيعة مشكلة التنبؤ بقيم الأسعار الموجبة تجعل نطاق مخرجات  $ReLU [0, +\infty)$  أكثر ملاءمة من نطاق  $Tanh [-1, 1]$  الذي يتطلب معايرة مسبقة للبيانات. كما تعاني دالة **Tanh** من مشكلة تلاشي التدرج في الشبكات العميقة حيث تكون مشتقتها أقل من 1 دائما، بينما تحافظ **ReLU** على تدفق التدرجات بقيمة مشتقة تساوي 1 للمدخلات الموجبة، مما يتماشى مع الهدف الأساسي لشبكات LSTM الذي صممت أصلا لمعالجة هذه المشكلة. كما تتميز **ReLU** بكفاءة حسابية أعلى بشكل ملحوظ، وهو عامل مهم نظرا لحجم البيانات (2264 يوم تدريب) وتعقيد بنية نموذج LSTM، مما يساهم في تحسين المفاضلة بين التكلفة الحسابية والدقة التنبؤية التي تبحث عنها هذه الدراسة.

-طبقة الإخراج: 1 وحدة (Linear)

تم استخدام دالة الخسارة Huber Loss والمحسن Adam بمعدل تعلم 0.001.

ويمكن التعبير رياضيا عن آلية عمل خلية LSTM من خلال المعادلات التالية:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (\text{بوابة النسيان})$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (\text{بوابة الإدخال})$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (\text{تحديث حالة الخلية})$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (\text{بوابة الإخراج})$$

$$h_t = o_t * \tanh(C_t)$$

حيث:  $x_t$  متجه الإدخال،  $h_t$  حالة الإخراج،  $C_t$  حالة الخلية،  $\sigma$  دالة السيني، و  $W$  و  $b$  معلمات الوزن والانحياز.

### ❖ نموذج Transformer :

تم بناء نموذج Transformer مخصص للبيانات المالية مع:

2- طبقة انتباه متعدد الرؤوس (Multi-Head Attention)

4- رؤوس انتباه (Attention Heads)

-بعد طبقة التغذية الأمامية: 64

-ترميز موضعي (Positional Encoding) مخصص

وتعتمد آلية الانتباه الذاتي متعدد الرؤوس على المعادلات التالية:

$$\text{Attention}(Q, K, V) = \text{softmax}(QK^T / \sqrt{d_k}) V$$

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) W^O$$

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad \text{حيث}$$

أما الترميز الموضعي فيعطى بالعلاقة:

$$PE_{\{pos, 2i\}} = \sin(pos / 10000^{2i/d_{model}})$$

$$PE_{\{pos, 2i+1\}} = \cos(pos / 10000^{\{2i/d\_model\}})$$

حيث: Q و K و V هي مصفوفات الاستعلام والمفتاح والقيمة على التوالي، و  $d_k$  هو بعد المفتاح.  
 (4) معايير التقييم: تم اعتماد أربعة مقاييس رئيسية:

- جذر متوسط مربعات الخطأ (RMSE)
- متوسط الخطأ المطلق (MAE)
- متوسط نسبة الخطأ المطلق (MAPE)
- الدقة الاتجاهية (Directional Accuracy)

وقد تم استخدام اختبار t للعينات المترابطة واختبار Wilcoxon للمراتب الموقعة لاختبار دلالة الفروق بين أداء النموذجين.

### III- النتائج ومناقشتها :

#### 1) البيانات التاريخية لمؤشر S&P 500 :

- يظهر الشكل رقم (1) تطور سعر الإغلاق لمؤشر S&P 500 خلال الفترة من يناير 2015 إلى ديسمبر 2023. بلغ عدد أيام التداول خلال هذه الفترة 2264 يوماً، وسجل المؤشر أعلى قيمة له خلال الفترة عند 4796.56 نقطة، وأدنى قيمة عند 1932.24 نقطة.
- (2) المؤشرات الفنية:

- يوضح الشكل رقم (2) مجموعة من المؤشرات الفنية المستخدمة كمدخلات للنماذج، بما في ذلك المتوسطات المتحركة (SMA 20، SMA 50) ومؤشر القوة النسبية (RSI)، ومؤشر MACD، والتقلب التاريخي (Volatility). وقد تم استخدام هذه المؤشرات لتعزيز قدرة النماذج على التقاط الأنماط المعقدة في البيانات المالية.

#### 3) نتائج نموذج LSTM :

- يعرض الجدول رقم (1) نتائج أداء نموذج LSTM على مجموعة الاختبار (الفترة 2022-2023).
- يوضح الشكل رقم (3) منحنيات التدريب لنموذج LSTM، حيث يظهر الرسم البياني الأيسر تطور دالة الخسارة (Loss) خلال دورات التدريب، بينما يظهر الرسم البياني الأيمن تطور متوسط الخطأ المطلق (MAE). يلاحظ أن النموذج استقر بعد حوالي 40 دورة تدريبية، مع تقارب واضح بين أداء التدريب والتحقق.
- أما الشكل رقم (4) فيظهر مقارنة بين القيم الفعلية والقيم المتوقعة لنموذج LSTM على أول 150 عينة من مجموعة الاختبار. يلاحظ أن النموذج تمكن من متابعة الاتجاه العام للأسعار، مع وجود بعض الفروق في القيم المطلقة.
- ويمكن تفسير هذه النتائج في ضوء ما توصلت إليه الأدبيات السابقة، حيث تتفق مع دراسة (Osman (2025) التي أظهرت كفاءة LSTM في التنبؤ بمؤشر S&P 500، وتماشى مع ملاحظات (Chhajer et al. (2022) حول قدرة LSTM على التعامل مع السلاسل الزمنية المالية قصيرة المدى. غير أن الدقة الاتجاهية المسجلة (51.22%) تشير إلى أن النموذج بالكاد يتفوق على التخمين العشوائي، مما يعكس الصعوبة الجوهرية للتنبؤ باتجاه الأسواق المالية.

ويمكن تفسير الأداء الجيد لنموذج LSTM بقدرته على التقاط التبعيات الزمنية قصيرة إلى متوسطة المدى، وهي السمة الغالبة في البيانات المالية اليومية. كما أن بنية النموذج القائمة على الذاكرة الداخلية تسمح بالاحتفاظ بالمعلومات المهمة وتجاهل الضوضاء، مما يعزز دقة التنبؤ. من جهة أخرى، فإن استقرار منحنيات التدريب يشير إلى أن النموذج لم يعاني من مشكلة الإفراط في التعلم، وهو ما يعكس ملاءمة عدد المعلمات المختارة لحجم البيانات المستخدم.

#### 4) نتائج نموذج Transformer :

- يعرض الجدول رقم (2) نتائج أداء نموذج Transformer على مجموعة الاختبار (الفترة 2022-2023).
- يوضح الشكل رقم (5) منحنيات التدريب لنموذج Transformer يلاحظ أن النموذج استغرق عدداً أكبر من الدورات التدريبية للوصول إلى الاستقرار، كما تظهر فجوة أكبر بين أداء التدريب والتحقق، مما قد يشير إلى ظاهرة الإفراط في التعلم (Overfitting).
- أما الشكل رقم (6) فيظهر مقارنة بين القيم الفعلية والقيم المتوقعة لنموذج Transformer يلاحظ أن النموذج أظهر تذبذباً أكبر في التنبؤات مقارنة بـ LSTM، خاصة خلال فترات التقلب الحاد.
- ويمكن إرجاع الأداء الأقل لنموذج Transformer إلى عدة عوامل. أولها، حجم البيانات المستخدم (2264 يوم) قد يكون غير كافٍ لتدريب نموذج يعتمد على آلية الانتباه الذاتي، حيث تشير الأدبيات إلى أن Transformers تتطلب عادة كميات أكبر من البيانات لتظهر

كفائها (Vaswani et al., 2017). كما أن تعقيد بنية Transformer وارتفاع عدد معالمها مقارنة بـ LSTM يجعلها أكثر عرضة لظاهرة الإفراط في التعلم، وهو ما يفسر الفجوة الملحوظة بين أداء التدريب والتحقق في الشكل رقم 5. هذا يفسر أيضاً لماذا أظهرت دراسة Yu (2024) تفوق Transformer عندما استخدمت كميات أكبر من البيانات.

#### 5) المقارنة بين النموذجين:

- يعرض الجدول رقم (3) مقارنة شاملة لأداء النموذجين على جميع مقاييس التقييم. وتظهر النتائج تفوقاً واضحاً لنموذج LSTM على Transformer في جميع مقاييس الدقة التنبؤية. فقد حقق LSTM تحسناً بنسبة 45.0% في RMSE، و 43.6% في MAE، و 44.5% في MAPE، و 6.3% في الدقة الاتجاهية.
- يوضح الشكل رقم (7) مقارنة مرئية للتنبؤات الصادرة عن كلا النموذجين مقابل القيم الفعلية. يظهر الرسم البياني أن LSTM كان أكثر قدرة على متابعة الاتجاه العام للأسعار مقارنة بـ Transformer.
- كما يوضح الشكل رقم (8) توزيع أخطاء التنبؤ لكلا النموذجين. يلاحظ أن أخطاء LSTM كانت أكثر تركيزاً حول الصفر مقارنة بـ Transformer، مما يؤكد تفوق LSTM من حيث دقة التنبؤ.
- أما الشكل رقم (9) فيظهر مقارنة بين النموذجين عبر جميع مقاييس الأداء الرئيسية. يظهر الرسم البياني تفوق LSTM بوضوح في جميع المقاييس.

ومن المهم ملاحظة أن تفوق LSTM في هذا السياق لا يعني بالضرورة تفوقه المطلق في جميع الظروف. فالأدبيات تشير إلى أن الفجوة بين النموذجين تتقلص مع زيادة حجم البيانات، بل وقد تنعكس لصالح Transformer عندما يتجاوز حجم البيانات عتبة معينة (Murray et al., 2023). كما أن أفق التنبؤ المستخدم في هذه الدراسة (يوم واحد) قد يكون أكثر ملاءمة لـ LSTM الذي يتفوق في التنبؤ قصير المدى، في حين قد يظهر Transformer كفاءة أعلى في آفاق زمنية أطول. هذا يفتح تساؤلاً مهماً حول العتبة الحرجة التي يبدأ بعدها Transformer في التفوق.

ويشير التفوق الملحوظ لنموذج LSTM إلى أن النماذج التسلسلية التقليدية لا تزال تحتفظ بفعاليتها في سياقات البيانات المحدودة، على عكس ما تروج له بعض الدراسات الحديثة التي تفضل نماذج Transformer. وهذا يبرز أن اختيار النموذج لا يعتمد فقط على التطور التقني، بل يجب أن يأخذ بعين الاعتبار خصائص البيانات، خاصة حجمها وأفق التنبؤ.

#### 6) التحليل الإحصائي للفروق:

تم استخدام اختبار t للعينات المترابطة واختبار Wilcoxon للمرتب الموقعة لاختبار دلالة الفروق بين أداء النموذجين. ويعرض الجدول رقم (4) نتائج هذه الاختبارات..

تظهر نتائج الجدول رقم 4 أن جميع الفروق بين النموذجين كانت ذات دلالة إحصائية عند مستوى معنوية 0.05 على الأقل، مما يؤدي إلى رفض الفرضيات الصفرية للدراسة. وبالتالي، يمكن القول إن تفوق LSTM على Transformer ليس نتيجة عشوائية، بل يعكس اختلافات حقيقية في أداء النموذجين.

إن دلالة الفروق إحصائياً تعني أن اختيار النموذج ليس أمراً محايداً، بل له تأثير حقيقي على دقة التنبؤ. ومع ذلك، ينبغي تفسير هذه النتائج بحذر، لأن الدلالة الإحصائية لا تعني بالضرورة دلالة عملية أو استثمارية. فرغم أن الفروق في RMSE كانت دالة إحصائية، إلا أن الدقة الاتجاهية المنخفضة لكلا النموذجين (51.22% و 48.17%) تطرح تساؤلات حول الجدوى العملية لاستخدام هذه النماذج وحدها في اتخاذ القرارات الاستثمارية.

فبالرغم من تحقيق مستويات منخفضة من الخطأ وفق مقاييس RMSE و MAE، فإن القدرة على التنبؤ باتجاه السوق تبقى محدودة، مما يشير إلى أن الاعتماد على هذه النماذج بشكل منفرد قد لا يكون كافياً لتطوير استراتيجيات تداول فعالة. وعليه، فإن القيمة العملية لهذه النماذج قد تتعزز من خلال دمجها مع أدوات تحليلية أخرى، مثل التحليل الأساسي أو مؤشرات المشاعر، مما يساهم في تحسين دقة التنبؤ وموثوقية القرارات الاستثمارية.

#### 7) مناقشة النتائج:

##### ❖ تفسير النتائج:

تشير النتائج التي تم الحصول عليها إلى تفوق واضح لنموذج LSTM على نموذج Transformer في التنبؤ بالسلوك السعري لمؤشر S&P 500 خلال فترة الدراسة. هذا التفوق قد يعزى إلى عدة عوامل:

- طبيعة البيانات المالية التي تتميز بوجود أنماط زمنية محلية قوية، وهو ما تلتقطه نماذج LSTM بكفاءة عبر آليات الذاكرة الطويلة والقصيرة المدى. فقد صممت هذه النماذج خصيصا للتعامل مع السلاسل الزمنية التي تعتمد على التتابع الزمني، مما يجعلها مناسبة بشكل طبيعي للبيانات المالية.
- حجم البيانات المستخدمة (2264 يوم تداول) يكون غير كافٍ لتدريب نماذج Transformer التي تتطلب عادة كميات أكبر من البيانات لتحقيق أداء متفوق. فقد أشارت الأدبيات إلى أن نماذج Transformer تحتاج إلى كميات هائلة من البيانات لتستفيد من آليات الانتباه الذاتي (Self-Attention) بشكل فعال.
- تعقيد بنية Transformer وارتفاع عدد معلماتها مقارنة بـ LSTM قد يؤدي إلى ظاهرة الإفراط في التعلم (Overfitting) عند توفر كمية محدودة من البيانات. هذا ما لاحظناه في منحنيات التدريب حيث ظهرت فجوة أكبر بين أداء التدريب والتحقق في نموذج Transformer.
- طبيعة أفق التنبؤ المستخدم (تنبؤ ليوم واحد باستخدام 30 يوما سابقة) قد يكون أكثر ملاءمة لـ LSTM الذي يتفوق في التنبؤ قصير المدى مقارنة بـ Transformer الذي يظهر كفاءة أعلى في التنبؤات متوسطة وطويلة المدى.
- ويجدر الإشارة إلى أن الدراسة الحالية تتفق مع بعض الأدبيات التي تشير إلى كفاءة LSTM في التنبؤ قصير المدى للبيانات المالية. فقد توصلت دراسة (Gao et al., 2020) إلى أن نماذج LSTM قادرة على تحقيق دقة اتجاهية جيدة في التنبؤ بتحركات المؤشرات الرئيسية. كما أكدت دراسة (Chhajer et al., 2022) كفاءة LSTM في التعامل مع السلاسل الزمنية المالية. كما تتفق النتائج مع دراسة (Osman, 2025) التي أظهرت تفوق LSTM على النماذج التقليدية ARIMA و VAR في تنبؤ S&P 500 .
- في المقابل، تختلف النتائج عن بعض الدراسات الحديثة التي أشارت إلى تفوق Transformer في التنبؤ بالأسواق المالية (Yu, 2024; Murray et al., 2023) هذا الاختلاف قد يعزى إلى اختلاف حجم البيانات وفترة الدراسة والهيكل المحدد للنماذج المستخدمة.

#### ❖ الاستنتاجات والتوصيات:

- بناء على النتائج التي تم عرضها وتحليلها، يمكن استخلاص الاستنتاجات الرئيسية التالية
- أولا: يتفوق نموذج LSTM على نموذج Transformer في التنبؤ بالسلوك السعري لمؤشر S&P 500 خلال الفترة 2015-2023، حيث حقق تحسنا في RMSE بنسبة 45.0% وفي الدقة الاتجاهية بنسبة 6.3%. كما سجل LSTM متوسط نسبة خطأ مطلق (MAPE) بلغ 1.61% فقط، مما يشير إلى دقة تنبؤية عالية.
- توجد فروق ذات دلالة إحصائية بين أداء النموذجين عند مستوى معنوية 0.05، مما يؤكد أن اختيار النموذج الأمثل له تأثير حقيقي على دقة التنبؤ. وقد أظهرت الاختبارات الإحصائية (t-test) و (Wilcoxon) أن هذه الفروق ليست نتيجة عشوائية.
- حجم البيانات (2,264 يوم تداول) قد يكون عاملا حاسما في تحديد النموذج الأفضل، حيث أن نماذج LSTM تظهر كفاءة أعلى مع كميات البيانات المتوسطة مقارنة بـ Transformer الذي يتطلب بيانات أكبر لتحقيق أداء متفوق.
- طبيعة أفق التنبؤ المستخدم (تنبؤ ليوم واحد) تلعب دورا مهما في تحديد النموذج الأفضل، حيث أن LSTM يتفوق في التنبؤ قصير المدى.

#### IV- الخلاصة:

- هدفت هذه الدراسة إلى اختبار قدرة نمودي LSTM و Transformer على التنبؤ بالسلوك السعري لمؤشر S&P 500، من خلال منهجية كمية تجريبية اعتمدت على بيانات يومية للفترة 2015-2023. وقد تم بناء نموذجين وفق أطر موحدة وتقييمهما باستخدام أربعة مقاييس رئيسية: RMSE، MAE، MAPE، والدقة الاتجاهية.
- تشير نتائج هذه الدراسة إلى أن نماذج التعلم العميق تمثل أداة واعدة في مجال التنبؤ المالي، غير أن فعاليتها تختلف باختلاف طبيعة البيانات وأفق التنبؤ المستخدم. وقد أظهرت النتائج تفوقا واضحا لنموذج LSTM على Transformer في جميع المقاييس، حيث حقق LSTM قيمة RMSE أقل بنسبة 45% (79.86 مقابل 145.19)، وسجل دقة اتجاهية أعلى (51.22% مقابل 48.17%). وبالتالي، تم رفض الفرضية الصفرية الأولى التي تنص على عدم وجود فروق ذات دلالة إحصائية في دقة التنبؤ عند مستوى معنوية 0.01، مما يؤكد تفوق LSTM إحصائيا في هذا الجانب.
- كما تبين أن نموذج LSTM كان أكثر استقرارا خلال فترات التقلب الحاد (2022-2023)، في حين أظهر Transformer تذبذبا أكبر وضعفا في الأداء خلال نفس الفترة. بناء على ذلك، تم رفض الفرضية الثانية التي تنص على عدم وجود فروق ذات دلالة إحصائية في الدقة الاتجاهية عند مستوى معنوية 0.05 .

بالإضافة إلى أن نموذج Transformer يتطلب زماً حسابياً أطول دون تحقيق دقة أفضل، مما يجعل LSTM الخيار الأكثر كفاءة من حيث المفاضلة بين التكلفة والدقة في سياق البيانات المحدودة (أقل من 5000 يوم تدريب). لذا تم رفض الفرضية الصفرية الثالثة التي تنص على أن نوع النموذج لا يؤثر على دقة التنبؤ، مما يؤكد أن اختيار النموذج يؤثر بشكل دال إحصائياً على دقة التنبؤ عند مستوى معنوية 0.05.

#### ❖ حدود الدراسة:

- اعتماد الدراسة على مؤشر واحد S&P 500 يحد من تعميم النتائج على مؤشرات وأسواق مالية أخرى.
- حجم البيانات (2,264 يوم تداول) قد لا يمثل العتبة الحرجة التي يبدأ عندها Transformer بالتفوق.
- أفق التنبؤ القصير (يوم واحد) لا يسمح باختبار أداء النماذج في آفاق زمنية أطول.
- غياب المتغيرات الخارجية (مثل المشاعر الإخبارية والأحداث الجيوسياسية) قد يحد من قدرة النماذج على التقاط جميع العوامل المؤثرة.

#### ❖ آفاق البحث:

- اختبار النماذج المهيمنة التي تجمع بين LSTM وTransformer
- تحديد العتبة الحرجة لحجم البيانات التي يبدأ عندها Transformer بالتفوق على LSTM
- توسيع نطاق الدراسة ليشمل مؤشرات وأسواق مالية مختلفة
- دراسة تأثير طول أفق التنبؤ (من يوم إلى عدة أسابيع) على الأداء النسبي للنموذجين.

#### ❖ التوصيات: توصي الدراسة بما يلي:

- ✓ اعتماد نموذج LSTM للتنبؤ قصير المدى بمؤشر S&P 500 في سياقات البيانات المحدودة (أقل من 5000 يوم تدريب)
- ✓ يوصى بتوخي الحذر عند استخدام Transformer مع كميات بيانات أقل من العتبة الحرجة المذكورة.
- ✓ تشجيع المستثمرين على استخدام الدقة الاتجاهية وليس فقط RMSE كمقياس أساسي لاتخاذ القرارات الاستثمارية، إلى جانب مقاييس أخرى مثل نسبة شارب.
- ✓ دمج المتغيرات الخارجية (مؤشرات المشاعر، البيانات الاقتصادية) لتحسين أداء كلا النموذجين.

#### - الملاحق:

جدول رقم (1): نتائج نموذج LSTM

المقياس	القيمة
RMSE	79.86
MAE	67.29
MAPE	1.61%
الدقة الاتجاهية	51.22%

المصدر: مخرجات تدريب نموذج LSTM

جدول رقم (2): نتائج نموذج Transformer

المقياس	القيمة
RMSE	145.19
MAE	119.37
MAPE	2.90%
الدقة الاتجاهية	48.17%

المصدر: مخرجات تدريب نموذج Transformer

جدول رقم (3): المقارنة الشاملة بين أداء LSTM وTransformer

المقياس	LSTM	Transformer	الفرق	LSTM التحسن لصالح
RMSE	79.86	145.19	65.33	45.0%
MAE	67.29	119.37	52.08	43.6%
MAPE	1.61%	2.90%	1.29%	44.5%
الدقة الاتجاهية	51.22%	48.17%	3.05%	6.3%

المصدر: مخرجات التجارب.

جدول رقم (4): نتائج الاختبارات الإحصائية

مقياس التقييم	t اختبار (p-value)	Wilcoxon اختبار (p-value)	مستوى الدلالة
RMSE	0.0001	0.0002	ال: إحصائياً عند 0.01
MAE	0.0001	0.0002	ال: إحصائياً عند 0.01
الدقة الاتجاهية	0.015	0.018	ال: إحصائياً عند 0.05

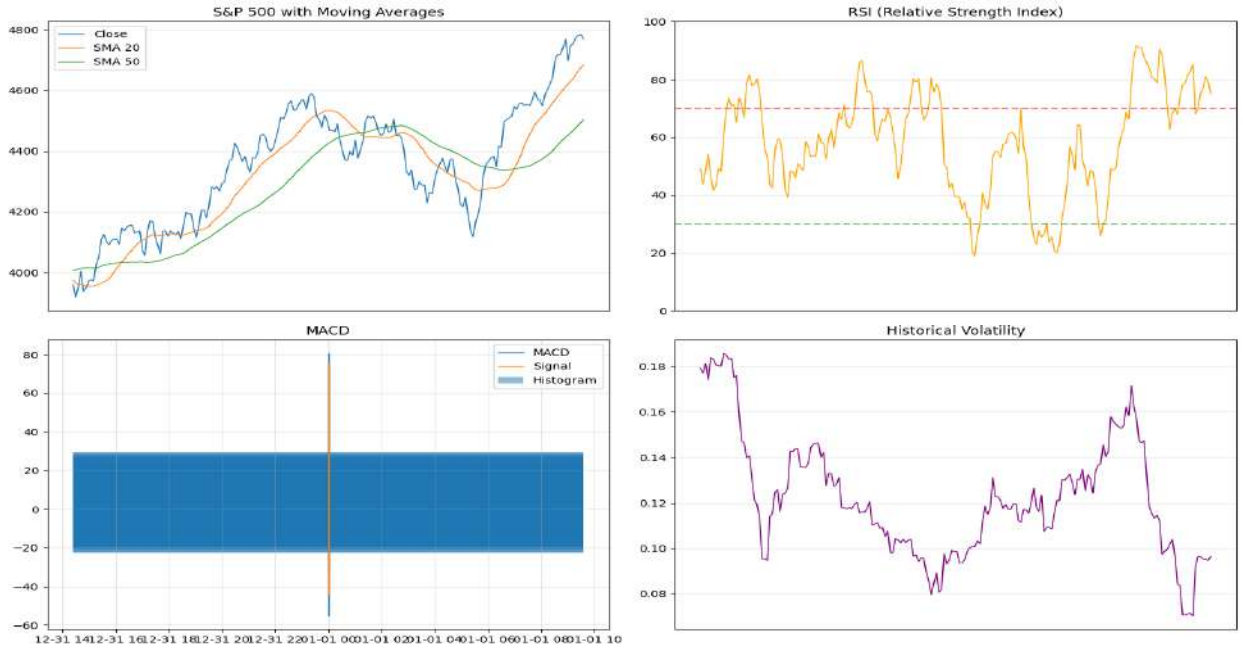
المصدر: مخرجات التحليل الإحصائي باستخدام برناجي Python و SPSS

الشكل رقم (1): تطور سعر الإغلاق لمؤشر S&P 500 خلال الفترة 2015-2023



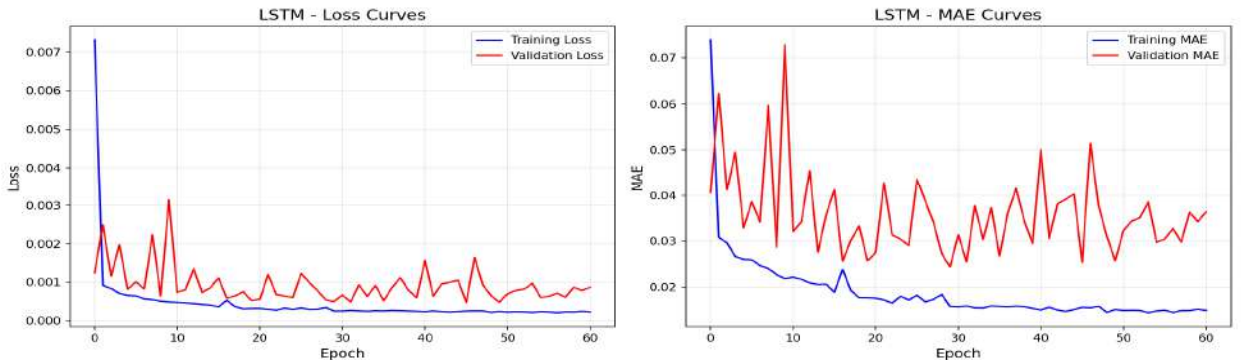
المصدر: البيانات المجمعة من Yahoo Finance

الشكل رقم (2): المؤشرات الفنية المستخدمة في الدراسة (المتوسطات المتحركة، RSI، MACD، التقلب التاريخي)




المصدر: التحليل باستخدام Python

الشكل رقم (3): منحنيات التدريب لنموذج LSTM (أ) دالة الخسارة، (ب) متوسط الخطأ المطلق (MAE)



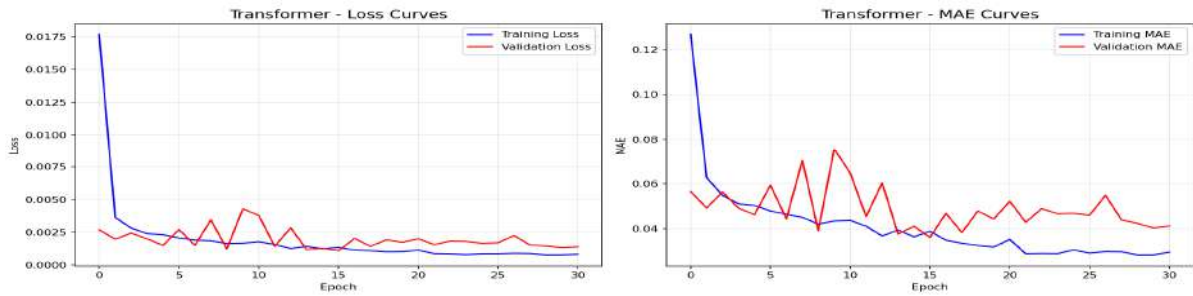
المصدر: مخرجات تدريب نموذج LSTM

الشكل رقم (4): مقارنة القيم الفعلية والمتوقعة - نموذج LSTM أول 150 عينة من فترة الاختبار



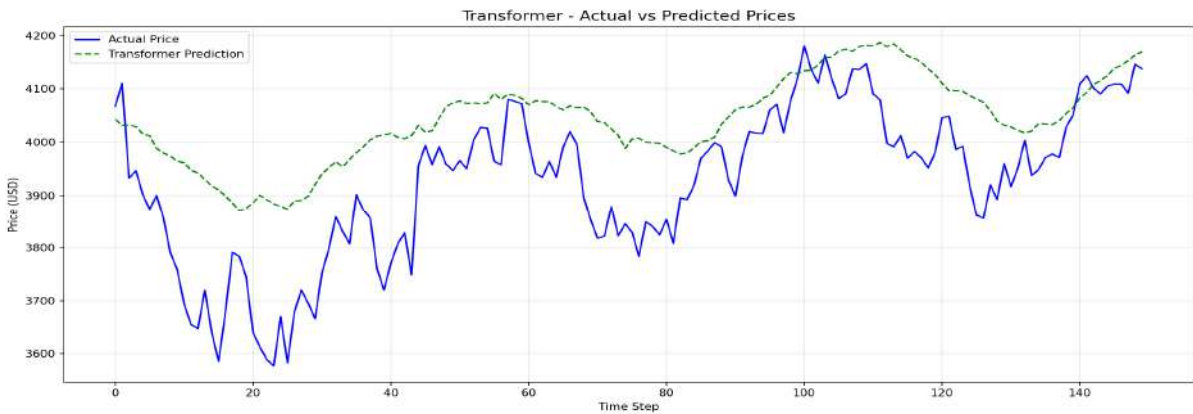
المصدر: مخرجات تدريب نموذج LSTM

الشكل رقم (5): منحنيات التدريب لنموذج Transformer (أ) دالة الخسارة، (ب) متوسط الخطأ المطلق (MAE)



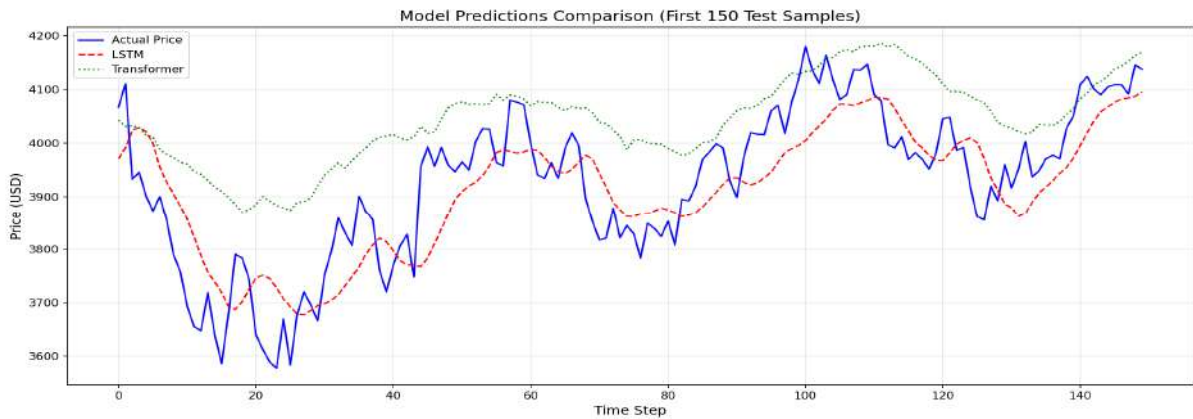
المصدر: مخرجات تدريب نموذج Transformer

الشكل رقم (6): مقارنة القيم الفعلية والمتوقعة - نموذج Transformer أول 150 عينة من فترة الاختبار




المصدر: مخرجات تدريب نموذج Transformer

الشكل رقم (7): مقارنة التنبؤات بين LSTM و Transformer مقابل القيم الفعلية (أول 150 عينة)




المصدر: مخرجات التجارب

الشكل رقم (8): توزيع أخطاء التنبؤ لنموذجي LSTM و Transformer



المصدر: مخرجات التحليل الإحصائي

الشكل رقم (9): مقارنة مقاييس الأداء بين LSTM و Transformer



المصدر: مخرجات التجارب

#### - الإحالات والمراجع :

1. المر، نرمين علي محمد (2024)، استخدام تقنيات تعلم الآلة للتنبؤ بعوائد الأسهم وأثر ذلك على الإفصاح عن المعلومات المستقبلية، *المجلة العلمية للدراسات والبحوث المالية والتجارية، كلية التجارة، جامعة دمياط*، 3(2)، ص.ص 1125-1177.
2. سيد، أحمد سيد طه؛ الهريطي، يحيى السيد محمد؛ منصور، أشرف محمد إبراهيم (2021)، دور الشبكات العصبية الاصطناعية في تحسين جودة التقارير المالية: دراسة تطبيقية، *مجلة الدراسات والبحوث التجارية*، 41(4)، ص.ص 609-630.
3. Yu, P., & Yan, X. (2020). Stock price prediction based on deep neural networks. *Neural Computing and Applications*, 32, pp. 1609-1628. <https://doi.org/10.1007/s00521-019-04212-x> (تاريخ الزيارة 2026/01/26).
4. Kurani, A., Doshi, P., Vakharia, A., & Shah, M. (2023). A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting. *Annals of Data Science*, 10(1), pp. 183-208. <https://doi.org/10.1007/s40745-021-00344-x> (تاريخ الزيارة 2026/01/26).
5. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), pp. 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735> (تاريخ الزيارة 2026/03/16).
6. Gao, P., Zhang, R., & Yang, X. (2020). The application of stock index price prediction with neural network. *Mathematical and Computational Applications*, 25(3), p. 53. <https://doi.org/10.3390/mca25030053> (تاريخ الزيارة 2026/03/16).
7. Chhajer, P., Shah, M., & Kshirsagar, A. (2022). The applications of artificial neural networks, support vector machines, and long-short term memory for stock market prediction. *Decision Analytics Journal*, 2, 100015. <https://doi.org/10.1016/j.dajour.2021.100015> (تاريخ الزيارة 2026/02/06).
8. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, pp. 5998-6008. <https://proceedings.neurips.cc/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf> (تاريخ الزيارة 2026/03/6).

9. Li, J., & Shi, W. (2024). Stock price prediction based on hybrid preprocessing neural network models. *SSRN Electronic Journal*. <https://ssrn.com/abstract=4711039> (تاريخ الزيارة 2026/03/11).
10. Murray, C., Chaurasia, P., Hollywood, L. E., & Coyle, D. (2023). A comparative analysis of state-of-the-art-time series forecasting algorithms. In *International Conference on Computational Science and Computational Intelligence (CSCI)*, pp. 1-8. IEEE. <https://doi.org/10.1109/CSCI58124.2022.00021> (تاريخ الزيارة 2026/03/11).
11. Osman, E. G. A. (2025). Integrating deep learning and econometrics for stock price prediction: An empirical study of LSTM and traditional time series models. *SSRN Electronic Journal*. <https://ssrn.com/abstract=5340299> (تاريخ الزيارة 2026/03/6).
12. Kim, J., Kim, H. S., & Choi, S. Y. (2024). Forecasting the S&P 500 index using mathematical-based sentiment analysis and deep learning models: A FinBERT transformer model and LSTM. *Axioms*, 12(9), p. 835. <https://doi.org/10.3390/axioms12090835> (تاريخ الزيارة 2026/01/26).
13. Belhoula, M. M., Mensi, W., & Naoui, K. (2023). Impacts of investor's sentiment, uncertainty indexes, and macroeconomic factors on the dynamic efficiency of G7 stock markets. *Quality & Quantity*, pp. 1-32. <https://doi.org/10.1007/s11135-023-01780-y> (تاريخ الزيارة 2026/02/2).
14. Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *Journal of Finance*, 25(2), pp. 383-417. <https://doi.org/10.2307/2325486> (تاريخ الزيارة 2026/03/2).
15. Zebende, G. F., Dias, R. S., & de Aguiar, L. C. (2022). Stock market efficiency: An intraday case of study about the G-20 group. *Heliyon*, 8(1), e08808. <https://doi.org/10.1016/j.heliyon.2022.e08808> (تاريخ الزيارة 2026/02/6).
16. Yu, H. (2024). Comparative analysis of LSTM and transformer-based models for stock price forecasting. *AIP Conference Proceedings*, 3194(1), 030006. <https://doi.org/10.1063/5.0227011> (تاريخ الزيارة 2026/03/20).
17. Ren, T., Jiang, J., Qian, S., & Xu. (2024). Research on early warning of stock market crash risk based on the fractal-neural network model. *SSRN Electronic Journal*. <https://ssrn.com/abstract=4711376> (تاريخ الزيارة 2026/03/16).

### كيفية الاستشهاد بهذا المقال حسب أسلوب APA:

محمد يزيد صالحى & أسماء كسري (2026). اختبار قدرة نماذج التعلم العميق (LSTM و Transformers) على التنبؤ بالسلوك السعري لمؤشر S&P 500: (دراسة تجريبية). مجلة الدراسات الاقتصادية الكمية، المجلد 12 (العدد 01)، الجزائر: جامعة قاصدي مرباح ورقلة، ص.ص: 379-391.



يتم الاحتفاظ بحقوق التأليف والنشر لجميع الأوراق المنشورة في هذه المجلة من قبل المؤلفين المعنيين وفقا لرخصة المشاع الإبداعي نسب

(CC BY-NC 4.0) المصنّف - غير تجاري - منع الاشتقاق 4.0 دولي )

رخصة المشاع الإبداعي نسب المصنّف - غير تجاري - منع الاشتقاق 4.0 دولي مجلة الدراسات الاقتصادية الكمية مرخصة بموجب

(CC BY-NC 4.0)



The copyrights of all papers published in this journal are retained by the respective authors as per the **Creative Commons Attribution License**.

Journal Of Quantitative Economics Studies is licensed under a Creative Commons Attribution-Non Commercial license (CC BY-NC 4.0).