

استخدام شبكة الذاكرة طويلة قصيرة المدى للتنبؤ بأسعار عملة البيتكوين

Using long short term memory network to predict bitcoin price

محمد روابلة*

مخبر تطوير المؤسسة الاقتصادية الجزائرية، جامعة ابن خلدون تيارت-الجزائر

mohammed.rouaba@univ-tiaret.dz

تاريخ النشر: 2024/12/15

تاريخ القبول للنشر: 2024/09/23

تاريخ الاستلام: 2024/07/02

ملخص:

هدفت هذه الورقة البحثية إلى التنبؤ بأسعار الإغلاق اليومية لعملة البيتكوين باستخدام نموذج مطور من الشبكات العصبية الاصطناعية والمتمثل في شبكة الذاكرة قصيرة طويلة المدى خلال الفترة الممتدة من 2014/09/17 – 2024/06/27. حيث تم بناء نموذج شبكة الذاكرة طويلة قصيرة المدى على منصة *google Colab* بواسطة لغة البرمجة *Python* من خلال مجموعة من المكتبات التابعة لهذه اللغة. وأظهرت نتائج هذه الدراسة بأن هناك قدرة تنبؤية عالية لشبكات الذاكرة طويلة قصيرة المدى بناء على مقاييس الأداء المعتمدة في هذه الورقة البحثية. الكلمات المفتاحية: التنبؤ بالأسعار، البيتكوين، شبكة الذاكرة طويلة قصيرة المدى، قرار الاستثمار. تصنيفات JEL: E30، C58.

Abstract:

This research paper aimed to predict the daily closing prices of Bitcoin using a developed model of artificial neural networks, represented by a Long-Short Term Memory (LSTM) network, during the period extending from 17/09/2014 - 27/06/2024. The long-short term memory model was built on the Google Colab platform using the Python programming language through a set of libraries belonging to this language. The results of this study showed that there is a high predictive ability for long-short term memory model based on the performance measures adopted by this research paper.

Keywords: Price prediction; Bitcoin; LSTM; Investment Decision.

Jel Classification Codes: C58، E30.

* المؤلف المراسل.

يحظى موضوع التنبؤ اليوم بأهمية بالغة في الاقتصاديات المالية، إذ يحاول المستثمرون والباحثون على حد سواء منذ أمد بعيد دراسة الظواهر المالية من خلال محاولة بناء نموذج فعال يساعد على فهم سلوكها ونمذجتها والتنبؤ بتطوراتها المستقبلية ويتم الاعتماد عليه بالشكل الذي يوجه المستثمرين لتحقيق أهدافهم واتخاذ أنسب القرارات المالية وينذر بالتالي المستثمرين باستشعار الخطر الناتج عن تقلباتها المفاجئة، ومواجهته بذلك من خلال معالجتها أو تفاديها ومعرفة أسباب حدوثها.

ولهذا الغرض استخدمت نماذج عديدة للتنبؤ بالظواهر المالية، تختلف فيما بينها من حيث استخدامها، نوعيتها وخصائص كل نموذج. حيث شاع في سنة 1976 استخدام نماذج تحليل السلاسل الزمنية العشوائية من قبل (Box and Jenkins)، والتي تعرف بنماذج ARIMA في تحليل وتفسير سلوكها والتنبؤ بها. وفي الوقت نفسه ظهرت دراسات وبحوث أخرى اهتمت باستخدام نماذج بديلة مستحدثة. حيث اقترح Engle في سنة 1982 أول نموذج يأخذ بعين الاعتبار الصفة العشوائية للسلاسل الزمنية، يعرف بنموذج ARCH، وسار على نهجه باحثون آخرون حيث قاموا من خلال أعمالهم البحثية بتحديثات واسعة على هذا النموذج، تعرف بنماذج التقلبات الشرطية، والتي تأخذ بعين الاعتبار القدوم المفاجئ وغير المتوقع للأحداث.

وكما هو معلوم، هذه النماذج لا تزال تعاني من قصور كبير، ولم ترق إلى المستوى المأمول، حيث وجهت لها العديد من الانتقادات، وأصبح من الضروري البحث عن نماذج أكثر تطوراً من أجل سد هذا النقص الموجود. ولا تزال هناك الكثير من المجهودات المبذولة في هذا المجال، حيث سمح التطور التكنولوجي بظهور برمجيات متقدمة تعتمد على القدرات الحاسوبية الكبيرة بتطوير نماذج تنبؤ جد متطورة. وقد اشتهرت في ذلك الشبكات العصبية الاصطناعية في حل العديد من المسائل الصعبة والمعقدة، إذ شهدت مع مطلع التسعينيات من القرن الماضي انتشار استخدامها على نطاق واسع في قياس وتحليل الظواهر المالية والتنبؤ بها. ومن بين الشبكات العصبية الاصطناعية التي اشتهرت لهذا الغرض نجد شبكات الذاكرة طويلة قصيرة المدى.

1.1. الإشكالية: يمكن عرض مشكلة الدراسة من خلال التساؤل التالي:

ما مدى دقة الشبكة طويلة قصيرة المدى في التنبؤ بأسعار عملة البيتكوين؟.

2.1. فرضيات الدراسة: للإجابة على إشكالية هذه الوجة البحثية تم صياغة الفرضية التالية:

- هناك قدرة تنبؤية عالية لشبكات الذاكرة طويلة قصيرة المدى بأسعار عملة البيتكوين.

3.1. أهمية الدراسة: تلخص أهمية الدراسة في النقاط التالية:

- تكمن أهمية الدراسة في كون الشبكات العصبية الاصطناعية قادرة على التعامل مع السلاسل الزمنية غير الخطية ذات الأنماط المختلفة والعشوائية دون اشتراطات مسبقة كما في الأساليب الإحصائية الأخرى التقليدية، وهذا من شأنه توفير الوقت والجهد والتكلفة اللازمة للتنبؤ.
- نظرا لما تقدمه التكنولوجيا المالية لا سيما فيما يتعلق بالأساليب الحديثة للذكاء الاصطناعي والتعلم الآلي من إمكانيات كبيرة في تحسين جودة الخدمات المالية ومن ذلك تحليل الأسواق المالية والتنبؤ بحركة الأسعار، أصبح من الأهمية دراستها واختبار مدى فعاليتها.

4.1. أهداف الدراسة: تضمنت الدراسة جملة من الأهداف تسعى إلى تحقيقها يمكن تخيصها في النقاط التالية:

- التعرف على الجوانب النظرية للشبكات العصبية الاصطناعية كإطار مفاهيمي، وتبسيط الضوء على استخداماتها في المجال المالي.
- التركيز على استخدام الأساليب الحديثة بدلا من الأساليب التقليدية في محاولة لتحسين دقة التنبؤ بأسعار عملة البيتكوين وتخفيض التكلفة اللازمة لذلك فضلا عن توفير الوقت والجهد.

2. الإطار النظري للدراسة

تعد الشبكات العصبية الاصطناعية من بين التقنيات الحديثة نسبيا، وذلك لقدرتها على تقليد سلوك الدماغ البشري من أجل أداء مهمة معينة، وتمثل الشبكات العصبية الاصطناعية أحد أنواع خوارزميات التعلم الآلي، ولها افتراضات أو قيود أقل مقارنة بأساليب القياس الأخرى وتعتبر فعالة في نمذجة العلاقات غير الخطية (Kim & Won, 2018, p. 26). ومبدأ عمل الشبكات العصبية الاصطناعية يركز على محاكاة الخلايا العصبية في الدماغ البشري والجهاز العصبي وبالرغم من عدم القدرة على المحاكاة بشكل تام إلا أنه بالإمكان إيجاد نظام حاسوبي يحاكي بعض خلايا الدماغ، أو يحاكي المفهوم العام لعمل الخلايا البيولوجية من خلال فهم كيفية تشكيل العمليات الحسابية في الدماغ ومن أمثلتها الإدراك الحسي والتمييز والتعلم بهدف الاستفادة من هذه الخصائص وتحويلها إلى صيغ رياضية قادرة على تحليل البيانات ومن ثم التنبؤ (Saleh, 2022, p. 187). ومن بين أنواع الشبكات العصبية الاصطناعية التي تستخدم بكثرة في التنبؤ في حالة السلاسل الزمنية نجد الشبكات العصبية المتكررة.


2.1. الشبكات العصبية المتكررة (Recurrent Neural Networks (RNNs

ظهرت الشبكات العصبية المتكررة RNN في ثمانينات القرن الماضي نتيجة لمجهودات العديد من الباحثين والعلماء في مجال التعلم الآلي والذكاء الاصطناعي، وتعتبر شبكة هوبفيلد (Hopfield, 1982) واحدة من الشبكات العصبية التكرارية الأولى التي قدمت، ثم تلتها بعد ذلك شبكة جوردن (Jordan, 1986) وشبكة إيلمان (Elman, 1990)، إلا أنها شهدت مؤخرا انتشار واسع لقدرتها على حل بعض المشاكل التي ترتكز على التسلسل الزمني، وعلى النقيض من أنواع الشبكات العصبية الأخرى تتميز RNN بوجود حلقات للتغذية العكسية (Feedback loops) مما يسمح لها بتخزين المعلومات عبر المسار الزمني، كما تعتمد RNN على مبدأ الذاكرة في نقل الاعتماديات المتسلسلة بواسطة أجزاء خاصة في الطبقة الخفية، وهذا ما يجعلها قادرة على التنبؤ بالأحداث المستقبلية بناء على الأحداث السابقة (Fouad et al., 2020, pp. 366-367).

الشكل 1 الموالي يعرض لنا هيكل RNN، ومن خلاله يتضح لنا أنه يتكون من ثلاثة عناصر أساسية، هي المدخلات ويرمز لها بـ (X)، والطبقة الخفية ويرمز لها بـ (H) وأخيرا المخرجات ويرمز لها بـ (Y)، ويتلخص مبدأ عمل RNN في تمرير المدخلات إلى الطبقة الخفية، والتي تقوم بدورها بتوليد اخراجين، الأول يتجه إلى طبقة المخرجات على شكل مخرج للشبكة، والثاني يتم تمريره على شكل متسلسل (Sequential) أو متجه (Vector) إلى عقدة أخرى أو العقد نفسها في الخطوة الزمنية اللاحقة مما يعد كإدخال للعقدة الآتية يحمل معلومات عن التنشيط السابق، إذ يتم جمع المعلومات الحالية مع التنشيط السابق (المخرجات في الخطوة الزمنية السابقة) في العقدة الحالية، وهذا ما يجعل الشبكة تتذكر المعلومات السابقة التي تقوم على أساسها ببناء التنبؤات المستقبلية، لهذا تستخدم RNN في التنبؤ بالسلاسل الزمنية بالإضافة إلى تطبيقات أخرى كثيرة، وتحتوي الطبقة الخفية في RNN دالة الظل الزائدي (Tanh) كدالة تنشيط من أجل المحافظة على البيانات في

المجال $[-1,1]$ ، كما توجد أوزان تربط بين الطبقات على غرار الأنواع الأخرى من الشبكات العصبية (Lazzeri, 2020, pp. 145-146).

الشكل 1: هيكلية الشبكة العصبية المتكررة RNN



Source: Lazzeri Francesca, Machine learning for time series forecasting with Python, John Wiley & Sons, 2020, p.147.

وبالرغم من مزايا RNN في قدرتها على نمذجة البيانات المتسلسلة، إلا أنها تواجه العديد من المشاكل في التعامل مع السلاسل الزمنية لا سيما السلاسل الزمنية التي تحتوي على مركبي الاتجاه والموسمية، ومن بين هذه المشاكل مشكلة انفجار (Exploding) أو تلاشي (Vanishing) قيمة الانحدار المتدرج (Joshi, 2020, p. 124)، إذ تتضمن حسابات التدرج في عملية تدريب RNN ضربات متكررة لمشتقة دالة الخطأ بالنسبة للأوزان وبهذا عندما تكون المشتقات صغيرة تؤدي عمليات الضرب المتكررة إلى اختفاء التدرج وهذا يجعل الشبكة تتوقف عن تحديث الأوزان وينتج عنه إيقاف عملية التدريب هذا من جهة، ومن جهة أخرى، عندما تكون قيمة المشتقات كبيرة، فإن عمليات الضرب المتكررة تؤدي لقيم (لا نهائية) وهذا بدوره ينتج عنه انفجار التدرج.

2.2. شبكة الذاكرة طويلة قصيرة المدى (Long Short Term Memory (LSTM

بالنظر لمشكلتي تلاشي التدرج أو انفجاره في RNN عند تطبيق خوارزمية الانتشار الخلفي عبر الزمن مما يجعل شبكة RNN عاجزة عن الاحتفاظ بالتبعية (المعلومات) لمدى طويل عبر الزمن، وكمحاوله لتفادي هذا العجز قدمت شبكة الذاكرة طويلة قصيرة المدى LSTM بواسطة (Schmidhuber and Hochreiter, 1997)، وتعد نموذجا محسنا من RNN، حيث تم تعديل بنية الشبكة بغرض جعلها قادرة على الاحتفاظ بالمعلومات المهمة لفترة زمنية مناسبة، وكذلك تحديد المعلومات الغير مهمة للتخلص منها (Rao & Gudivada, 2018, p. 282)، وتعتمد شبكة LSTM على آلية البوابات من أجل التحكم بالمعلومات المدخلة حيث تتكون من ثلاث بوابات وهي: بوابة النسيان (Forgetting Gate)، بوابة الإدخال (Input Gate) وبوابة الإخراج (Output Gate)، وتكون هذه البوابات عبارة دوال سينية (Sigmoid Function) تتحكم في مرور المعلومات عن طريق تنشيط القيم المدخلة في نطاق (0,1)، إذ أن قيمة التنشيط 1 تعني السماح بمرور المعلومات والاحتفاظ بها وعلى العكس من ذلك تعني قيمة 0 عدم السماح بمرورها (Patel et al., 2022, p. 131). وبهذا الاختلاف الجوهرى بين RNN و LSTM هو أن هذه الأخيرة تعمل على تقسيم قيمة التنشيط في الطبقة الخفية إلى حالتين مخفيتين، الأولى يطلق عليها الحالة الخفية (Hidden State) وهي نفسها في شبكة RNN ويتم استخدامها في تقدير قيمة المخرجات، والثانية يطلق عليها حالة الخلية (Cell State) يتم استخدامها لحفظ المعلومات المتسلسلة زمنياً إذ يشار إليها أحيانا بالذاكرة الداخلية، ويتم تقاسم هذين الحالتين في كل خطوة زمنية على طول مسار البيانات التي يتم ادخالها (Abdel-Basset et al., 2022, pp. 142-143). وفيما يلي توضيح لمبدأ عمل LSTM (Xiong, 2020, pp. 134-135):

❖ **بوابة النسيان:** تعمل بوابة النسيان على تحديد المعلومات المهمة التي يجب الاحتفاظ بها والمعلومات غير المهمة التي يجب التخلص منها عن طريق تمرير مجموع دمج المدخلات الحالية $X(t)$ مع قيمة الحالة الخفية للخطوة الزمنية السابقة $h_{(t-1)}$ إلى الدالة السينية (Sigmoid) ليتم ضرب قيمة التنشيط الناتجة من الدالة السينية مع حالة

الخلية للفترة الزمنية السابقة $C_{(t-1)}$ للتحكم بمرور المعلومات المضمنة في حالة الخلية $C_{(t-1)}$ أو التخلص منها، كما في المعادلة الآتية:

$$f(t) = \sigma(W_{(fn)} \cdot h_{(t-1)} + W_{(fx)} \cdot X_{(t)} + b_f)$$

❖ بوابة الإدخال: تعمل على تحديد المعلومات الجديدة التي يجب الاحتفاظ بها في حالة الخلية، حيث يتم تمرير نسخة من المدخلات الحالية $X_{(t)}$ مع الحالة الخفية للفترة الزمنية السابقة $h_{(t-1)}$ إلى الدالة السينية (بوابة الإدخال) ونسخة أخرى إلى دالة الظل الزائدي (Tanh)، ثم يتم ضرب القيمتين الناتجتين ببعض ليتم جمعها بعد ذلك مع $C_{(t-1)}$ القادمة من بوابة النسيان فيتم تحديث المعلومات المضمنة فيها والحصول على حالة الخلية للفترة الزمنية $C_{(t)}$ كما في المعادلات التالية:


$$\begin{aligned} i_{(t)} &= \sigma(W_{(ih)} \cdot h_{(t-1)} + W_{(ix)} \cdot X_{(t)} + b_i) \\ g_{(t)} &= \tanh(W_{(gh)} \cdot h_{(t-1)} + W_{(gx)} \cdot X_{(t)} + b_g) \\ C_{(t)} &= i_{(t)} \cdot g_{(t)} + f_{(t)} \cdot C_{(t-1)} \end{aligned}$$

❖ بوابة الإخراج: تعمل بوابة الإخراج على تحديد إخراج الشبكة للحالة الخفية $h_{(t)}$ ، حيث يتم من خلالها تمرير نسخة أخرى من المدخلات الحالية $X_{(t)}$ مع الحالة الخفية للفترة الزمنية السابقة $h_{(t-1)}$ إلى الدالة السينية، وفي الوقت ذاته يتم تمرير حالة الخلية $C_{(t)}$ إلى دالة الظل الزائدي ليتم بعد ذلك ضرب ناتج الدالتين ببعض للحصول على إخراج الشبكة (الحالة الخفية الجديدة $h_{(t)}$)، كما في المعادلات الآتية:

$$\begin{aligned} o_{(t)} &= \sigma(W_{(oh)} \cdot h_{(t-1)} + W_{(ox)} \cdot X_{(t)} + b_o) \\ h_{(t)} &= \tanh(C_{(t-1)}) \cdot o_{(t)} \end{aligned}$$

ويوضح الشكل الموالي البنية الهيكلية لشبكة الذاكرة الطويلة LSTM.

الشكل 2: البنية الهيكلية لشبكة الذاكرة الطويلة LSTM



Source: Ghosh et al., Stock price prediction using LSTM on Indian share market, Proceedings of 32nd International Conference on Computer Applications in Industry and Engineering, p:105.

3.2. مؤشرات تقييم أداء النموذج:

من خلال هذه الورقة البحثية نعتد على بعض مؤشرات الأداء التي تقيس لنا القدرة التنبؤية للنموذج وهي:

❖ متوسط الأخطاء المطلقة (MAE) Mean absolute error

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

حيث: $\hat{y}_t$ تمثل القيمة المقدرة لـ y في الفترة t .

y_t تمثل القيمة المشاهدة في الفترة t .

❖ متوسط الأخطاء المطلقة المئوية (MAPE) Mean absolute percentage error

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\%$$

❖ متوسط مربعات الأخطاء (MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

❖ الجذر التربيعي لمتوسط مربعات الأخطاء (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$


3. الإطار التطبيقي للدراسة

1.3. بيانات الدراسة

في هذه الورقة البحثية تم الاعتماد على أسعار الإغلاق اليومية لعملة البيتكوين والتي تم الحصول عليها من الموقع الإلكتروني finance.yahoo.com، حيث بلغت عدد المشاهدات 3572 مشاهدة والتي تغطي الفترة 2014/09/17 – 2024/06/27.

والشكل البياني الموالي يوضح تطور أسعار عملة البيتكوين خلال الفترة 2014/09/17 – 2024/06/27.

الشكل 3: تطور أسعار عملة البيتكوين خلال الفترة 2014/09/17 – 2024/06/27.



المصدر: من إعداد الباحث بالاعتماد على برنامج Python

من خلال الشكل البياني أعلاه نلاحظ أن سعر عملة البيتكوين شهد تطورات كبيرة حيث بلغت قيمته في بداية فترة الدراسة 457.33 دولار، وفي 2017/12/16 وصل إلى أول قمة بارزة له وبلغت 19497.40 دولار ليعود بعد ذلك سعره في الانخفاض، وفي سنة 2021 تضاعف سعره ليبلغ 65992.83 دولار في 2021/10/20 ثم بعدها شهد انخفاض في السعر ليعود إلى الزيادة في سنة 2024 بحيث في 2024/03/11 سجل مستوى قياسي له بـ 72123.91 دولار.

2.3. التنبؤ بأسعار عملة البيتكوين باستخدام منهجية LSTM:

الإطار العملي المستخدم للتنبؤ وفق هذه المنهجية موضح في الشكل الموالي:

الشكل 4: الإطار العملي للتنبؤ وفق منهجية LSTM



المصدر: من إعداد الباحث

❖ استيراد المكتبات اللازمة وتحميل البيانات

من أجل التنبؤ بأسعار عملة البيتكوين باستخدام LSTM برنامج Python نقوم في البداية بإستدعاء المكتبات الجاهزة المناسبة ومن أشهرها: pandas، matplotlib، seaborn، numpy، tensorflow، sklearn. ثم نقوم بعدها بتحميل ملف البيانات التي سنعمل عليها، والجدول الموالي يوضح جزء من هذه البيانات على برنامج Python:

جدول 1: بيانات الدراسة

Date	Open	High	Low	Close	Adj Close	Volume
2024-06-23	64248.964844	64491.703125	63180.796875	63180.796875	63180.796875	11170471802
2024-06-24	63173.351563	63292.527344	58601.699219	60277.414063	60277.414063	43152133651
2024-06-25	60266.281250	62258.261719	60239.750000	61804.640625	61804.640625	29201215431
2024-06-26	61789.675781	62434.136719	60695.187500	60811.277344	60811.277344	22506003064
2024-06-27	60811.226563	62293.863281	60619.578125	61682.753906	61682.753906	23075342336

المصدر: من إعداد الباحث بالاعتماد على برنامج Python

❖ تقسيم البيانات

تقسيم بيانات الدراسة إلى مجموعتين تتمثل المجموعة الأولى في مجموعة بيانات التدريب وقدرت نسبتها بـ 80% من مجموع المشاهدات بينما تمثلت المجموعة الثانية في مجموعة بيانات الاختبار بنسبة قدرها 20%، والهدف من تقسيم البيانات هو لاختبار قدرة نموذج شبكة LSTM في التعميم على البيانات التي لم يتدرب عليها، بحيث تستخدم عينة التدريب في التعلم واكتشاف أنماط وخصائص البيانات، فيما تستخدم عينة الاختبار لتقييم أداء النموذج ومدى قدرته على تعميم النتائج، وقد تم تقسيم بيانات الدراسة كما هو موضح في الجدول الموالي:


جدول 2: تقسيم بيانات الدراسة

مجموعة الاختبار	مجموعة التدريب	نسبة التقسيم
20%	80%	الفترة
2024/06/27 – 2022/07/13	2022/07/13 – 2014/09/17	المشاهدات
715	2857	

المصدر: من إعداد الباحث بالاعتماد على برنامج Python

يوضح الجدول 2 تقسيم بيانات الدراسة، إذ تم تخصيص 80% من البيانات للتدريب بواقع 2857 مشاهدة، والنسبة الباقية من البيانات أي 20% تم تخصيصها للاختبار بواقع 715 مشاهدة. والشكل البياني الموالي يوضح ذلك.

الشكل 5: بيانات التدريب وبيانات الاختبار



المصدر: من إعداد الباحث بالاعتماد على برنامج Python

❖ تطبيع (تقييس) البيانات Data Normalisation

من أجل تسهيل عملية معالجة البيانات من قبل شبكة LSTM نقوم بتقييس البيانات في النطاق [0,1] وذلك وفق المعادلة التالية:

$$x_{new} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

حيث: x_{new} سعر العملة بعد التقييس، x سعر الإغلاق اليومي للعملة، x_{min} القيمة الصغرى للقيم، x_{max} القيمة العظمى للقيم.

❖ إعادة تشكيل البيانات Data Reshaping

فمنهذه الخطوة نقوم بإعادة تشكيل البيانات وفقاً لتقنية النوافذ المنزلقة، وهي من التقنيات الشائعة في مجال التعلم الآلي والشبكات العصبية وتشبه إلى حد ما فكرة التأخيرات (التباطؤات) في علم الإحصاء، وتعتبر هذه الخطوة الأساس في تحويل السلسلة الزمنية لمشكلة تعلم خاضع للإشراف (Supervised Learning) بحيث يمكن التنبؤ بالخطوة الزمنية الموالية بالاعتماد على الخطوات الزمنية السابقة، وتقنية النوافذ المنزلقة تتطلب في البداية تحديد حجم النافذة الملائم لمشكلة الدراسة من حيث كمية البيانات وكيفية توزيعها، أي تحديد عدد التأخيرات في السلسلة الزمنية التي يمكن استخدامها لكل خطوة زمنية للتنبؤ بالخطوة الزمنية الموالية. وفي هذه الورقة البحثية سنستخدم ثلاث حالات للنوافذ المنزلقة حالة 7 مشاهدات، 30 مشاهدة، 60 مشاهدة ثم نختار النموذج الذي يحقق أفضل أداء.

3. تحديد معمارية شبكة LSTM

تعتبر مرحلة تحديد هيكل الشبكة العصبية من الأمور المهمة، إذ أن التخصيص الخاطئ لها لما تحويه من عدد الطبقات وعدد العقد بالإضافة إلى دوال التنشيط والخوارزميات التي يعتمد عليها في التحسين يؤدي إلى نتائج مظللة، لذلك يجب أن تتوافق مكونات الشبكة العصبية مع مشكلة البحث، إلا أنه لا يوجد معايير معينة بالإمكان الاعتماد عليها من أجل تحديد هذه المكونات.

بحيث تشير الدراسات إلى ضرورة إجراء محاولات تجريبية عديدة والاستدلال بمبدأ التجربة والخطأ في تحديد الهيكل الأمثل للشبكة العصبية الاصطناعية التي تلائم مشكلة الدراسة. وفيما يتعلق بشبكة LSTM المستخدمة في هذه الورقة البحثية تم إجراء عدة محاولات للوصول إلى الهيكل الأمثل، والذي يلائم مشكلة التنبؤ بأسعار عملة البيتكوين وقد تم التوصل إلى أن الهيكل الأمثل للشبكة الخاص ببيانات الدراسة يتألف من ثلاث طبقات كما هو موضح في الجدول 3 الموالي.

جدول 3: هيكلية شبكة LSTM

نوع الطبقة	الطبقة الأولى	الطبقة الثانية	الطبقة الثالثة
	LSTM Recurrent	LSTM	Dense Layer
عدد العقد	128	50	1
دالة التنشيط	Tanh	Tanh	Linear
خوارزمية التحسين	Adaptive Moment Estimation (Adam)		
دالة الخسارة	MeanSquaredError (MSE)		

المصدر: من إعداد الباحث

نموذج شبكة LSTM المقترح تضمن في الطبقة الأولى 128 عقدة (Neurons) بدالة تنشيط من نوع دالة الظل الزائدي (Tanh) وتحتوي هذه الطبقة على خاصية التسلسل المتكرر (RecurrentSequence) للمحافظة على سلسلة الإخراج للخطوات الزمنية السابقة، في حين أن الطبقة الثانية تحتوي على 50 عقدة بدالة تنشيط من النوع Tanh والطبقة الأخيرة

تحتوي على عقدة واحدة من النوع (Dense Layer) بدالة تنشيط خطية (Linear). وخوارزمية التحسين المستخدمة لتصحيح الأخطاء هي Adaptive Moment Estimation (Adam)

وتتميز هذه الخاصية بكونها أسرع في التعلم وتتطلب ذاكرة أقل بالإضافة إلى ذلك تعتبر مناسبة لحل المشاكل ذات البيانات الواسعة والتي تتسم بالتشويش العالي مما يجعلها ملائمة للتعامل مع السلاسل الزمنية غير المستقرة. كما تم أيضا استخدام متوسط مربعات الأخطاء (MSE) كمقياس لحساب دالة الخسارة (LossFunction) عند تدريب الشبكة.

4. التنبؤ والتحقق من دقة النموذج

يعد التحقق من أداء النموذج في مرحلة التدريب غير كاف، إذ يجب اختبار النموذج المدرب على بيانات خارج عينة التدريب للتأكد من كفاءته في التعميم بحيث يتم تقدير عينة الاختبار التي لم يسبق للنموذج التدريب عليها، ووفقا لذلك يتم ترشيح النموذج الأكثر دقة في مرحلة الاختبار للتنبؤ بأسعار عملة البيتكوين. والجدول الموالي يعرض نتائج تقييم النماذج الثلاثة المقترحة بعد عملية التقدير.


جدول 4: قيمة معايير الأداء للنماذج الثلاثة

المعايير	النموذج الأول Windows=7	النموذج الثاني Windows=30	النموذج الثالث Windows=60
MAE	616.3623	641.827	1304.592
MSE	1051285.2	1066886.4	4024658.5
RMSE	1025.322	1032.9019	1499.6693
MAPE	1.7286	1.8254	3.7433

المصدر: من إعداد الباحث بالاعتماد على برنامج Python

من خلال الجدول أعلاه نلاحظ أن النموذج الأول هو الأفضل الذي يعتمد على 7 مشاهدات كفترات تأخير، لأنه يتميز بمعايير خطأ دنيا والشكل المعروض أدناه يمثل نتائج التنبؤ الخاصة بهذا النموذج (النموذج الأمثل).

الشكل 6: نتائج التنبؤ باستخدام شبكة LSTM المثلى



المصدر: من إعداد الباحث بالاعتماد على برنامج Python

الشكل البياني أعلاه يعرض القيم الحقيقية والقيم التنبؤية لمجموعة بيانات الاختبار خلال الفترة الممتدة 2022/07/13 – 2024/06/27. حيث نلاحظ اقتراب القيم التنبؤية من القيم الحقيقية لأسعار الاغلاق لعملة البيتكوين مما يؤكد على القدرة التنبؤية العالية لهذا النموذج.

جاءت هذه الدراسة كمحاولة لتقييم أداء الشبكات العصبية الاصطناعية وبالتحديد شبكة LSTM في تحسين التنبؤ بأسعار عملة البيتكوين. وهذا خلال الفترة الممتدة 2014/09/17 – 2024/06/27. وأظهرت هذه الدراسة قدرة تنبؤية عالية لهذا النوع من الشبكات العصبية الاصطناعية.

وعليه من خلال هذه الورقة البحثية نقترح مجموعة من التوصيات نوردها فيما يلي:

- ضرورة اجراء المزيد من البحوث العلمية حول إمكانية التنبؤ بأسعار عملة البيتكوين باستخدام نماذج أخرى من الشبكات العصبية الاصطناعية كشبكة دالة الأساس الشعاعي RBF والشبكة العصبية التلافيفية CNN كما بالإمكان أيضا استخدام خوارزمية تعلم آلي أخرى كنموذج بايز NB، الغابات العشوائية RF، نموذج دعم المتجه SVM وغيرها من النماذج الأخرى.
- زيادة التعامل مع برامج التنبؤ المتطورة لأن التعقيد الكبير في المجال المالي وتطور تكنولوجيا المعلومات، وتصميم برامج حديثة تواكب هذه التطورات أصبح الشغل الشاغل للباحثين والمفكرين الماليين في حقل المالية لكون التعقيد الكبير في المجال المالي يدفعهم إلى استبدال أو دمج بعض الطرق التقليدية مع الطرق الحديثة لزيادة دقة التنبؤ في المستقبل.

6. قائمة المراجع:

1. Abdel-Basset, M., Moustafa, N., Hawash, H., & Ding, W. (2022). Deep Learning Techniques for IoT Security and Privacy (Vol. 997). Springer .
2. Fouad, M. M., Mahany, A., & Katib, I. (2020). Masdar: a novel sequence-to-sequence deep learning model for Arabic stemming. Intelligent Systems and Applications: Proceedings of the 2019 Intelligent Systems Conference (IntelliSys) Volume 2.
3. Ghosh, A., Bose, S., Maji, G., Debnath, N., & Sen, S. (2019). Stock price prediction using LSTM on Indian share market Proceedings of 32nd International Conference on Computer Applications in Industry and Engineering , Volume 63, 101 -110.
4. Joshi, A. V. (2020). Machine learning and artificial intelligence. Springer .
5. Kim, H. Y., & Won, C. H. (2018). Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models. Expert Systems with Applications, 103, 25-37 .
6. Lazzeri, F. (2020). Machine learning for time series forecasting with Python. John Wiley & Sons .
7. Patel, M., Padiya, J., & Singh, M. (2022). Fake news detection using machine learning and natural language processing. Combating fake news with computational intelligence techniques, 127-148 .
8. Rao, C., & Gudivada, V. N. (2018). Computational analysis and understanding of natural languages: principles, methods and applications. Elsevier .
9. Saleh, R. A. (2022). Comparison of some artificial neural networks for graduate students. Periodicals of Engineering and Natural Sciences, 10(3), 187-196 .
10. Xiong, R. (2020). Battery management algorithm for electric vehicles, Springer.