



Using Deep Learning Models to Predict Cryptocurrency Prices

Zahraa Kadhim Majeed¹, Haider Abbas Abdullah², Ameer Ali Khaleel³

استخدام نماذج التعلم العميق في التنبؤ بأسعار العملات المشفرة¹

زهراء كاظم مجيد^{1*}، حيدر عباس عبدالله²، امير علي خليل³

- 1.College of Administration and Economics, Department of Financial and Banking Sciences, University of Kerbala, Iraq-Karbala city, Iraq. zahraa.majeed@s.uokerbala.edu.iq * Corresponding Author
2. College of Administration and Economics, Department of Financial and Banking Sciences, University of Kerbala, Iraq-Karbala city, Iraq. haider.abbas@uokerbala.edu.iq
- 3.College of Administration and Economics, Department of Financial and Banking Sciences, University of Kerbala, Iraq-Karbala city, Iraq. ameer.ali@uokerbala.edu.iq

3.2.1. كلية الإدارة والاقتصاد، قسم العلوم المالية والمصرفية، جامعة كربلاء، العراق

1. * المؤلف المراسل



Article Information

Article History: DD/MM/YY

Received: 02/01/2026

Accepted: 15/02/2026

Available online: 03/03/2026

Keywords:

Deep learning, cryptocurrencies, Bitcoin, Long-term memory model, recurrent gate unit model

تاريخ الاستلام: 2026/01/02

تاريخ قبول النشر: 2026/02/15

تاريخ النشر: 2026/03/03

الكلمات المفتاحية

التعلم العميق، العملات المشفرة، البيتكوين، العملات العادية، نموذج الذاكرة طويلة المدى، نموذج وحدة البوابات المتكررة

Abstract DOI: <https://doi.org/10.71207/ijas.v22i87.5594>

The study aims to evaluate the effectiveness of deep learning models, specifically the Long and Short Term Memory (LSTM) model and the Gate Recurring Unit (GRU) model, in predicting the price of the cryptocurrency Bitcoin, based on a weekly time series over a period of ten years, from January 4, 2015 to December 29, 2024, with 522 observations. The Long and Short Term Memory Network (LSTM) model structure and the Gate Recurring Unit (GRU) model were constructed using the R programming language and a set of libraries belonging to this language, the most important of which is the Keras library, which is well-known in the field of machine learning. The study adopted an analytical approach to compare two models and choose the optimal model based on performance metrics, namely The study reached several conclusions, the most important of which is the superiority of the LSTM model over the GRU model in predicting Bitcoin prices. In light of this, the study presented several recommendations, the most important of which is relying on the Long Memory Network (LSTM) model in forecasting in future studies.

Citation: Kadhim Majeed, Zahraa, Abbas Abdullah, Haider, Ali Khaleel, Ameer. (2026). Using Deep Learning Models to Predict Cryptocurrency Prices, *Iraqi Journal for Administrative Sciences*, 22(87), 34- 56.

الافتتاحية: كاظم مجيد، زهراء، عباس عبدالله، حيدر، علي خليل، امير. (2026). استخدام نماذج التعلم العميق في التنبؤ بأسعار العملات المشفرة، *المجلة العراقية للعلوم الإدارية*، 22(87)، 34- 56.

المستخلص

تهدف الدراسة الى تقييم فعالية نماذج التعلم العميق، وتحديدًا نموذج الذاكرة الطويلة والقصيرة المدى (LSTM) ونموذج وحدة البوابات المتكررة (GRU)، في التنبؤ بأسعار العملة المشفرة المتمثلة في البيتكوين وذلك بالاعتماد على سلسلة زمنية اسبوعية لمدة عشر سنوات، من 4 يناير 2015 حتى 29 ديسمبر 2024، بواقع 522 مشاهدة لأسعار إغلاق البيتكوين الاسبوعية، تم بناء هيكلية نموذج (LSTM) ونموذج (GRU)، بواسطة لغة البرمجة R وباستعمال مجموعة من المكتبات التابعة لهذه اللغة أهمها مكتبة Keras المعروفة في مجال التعلم الآلي، إذ تم اختيار نماذج LSTM و GRU في هذه الدراسة استنادًا إلى قدرتهما العالية على نمذجة العلاقات الزمنية المعقدة والتعامل مع مشكلاتي التلاشي وتضخم التدرج. إذ انتهجت الدراسة أسلوبًا تحليليًا للمقارنة بين نموذجين و المفاضلة بينهما لترشيح النموذج الأمثل وفقًا لمقاييس الأداء المتمثلة بكل من متوسط الخطأ المطلق (MAE) ومتوسط مربع الخطأ (MSE) والجذر التربيعي لمتوسط مربع الخطأ (RMSE) وتوصلت الدراسة إلى عدة نتائج، أهمها تفوق نموذج LSTM على نموذج GRU في التنبؤ بأسعار البيتكوين وفي ضوء ذلك قدمت الدراسة عدة توصيات أهمها الاعتماد على نموذج شبكة الذاكرة الطويلة LSTM، في التنبؤ في الدراسات المستقبلية

¹ البحث مستل من أطروحة الدكتوراه: استخدام نماذج التعلم العميق في التنبؤ بأسعار العملات العادية والمشفرة

1. المقدمة Introduction

شهدت الأسواق المالية العالمية تحولاً واسع النطاق في العقد الأخير، برز بظهور فئة جديدة من العملات الرقمية المتمثلة في العملات المشفرة، في مقدمتها عملة البيتكوين (Bitcoin) والتي أحدثت ثورة في مفهوم النقود واللامركزية المالية. حيث يعد التنبؤ الدقيق بأسعار هذه العملات، تحدياً بالغ التعقيد وذا أهمية قصوى لصناع السياسات والمستثمرين، والمؤسسات المالية، نظراً للطبيعة غير الخطية والتقلبات العالية التي تتسم بها السلاسل الزمنية لأسعارها إذ لطالما اعتمدت محاولات التنبؤ بأسعار الأصول المالية على النماذج الاقتصادية القياسية ونماذج السلاسل الزمنية، مثل نماذج الانحدار الذاتي والمتوسطات المتحركة (ARIMA) ونماذج تقلب التباين المشروط ذاتي الانحدار (GARCH). إلا أن الدراسات الحديثة أظهرت محدودية هذه النماذج في التعامل مع البيانات المالية المعاصرة، لاسيما في الأسواق عالية التقلب مثل سوق العملات المشفرة، وذلك لاعتمادها على فرضيات الخطية والاستقرارية التي لا تتسجم مع السلوك الديناميكي المعقد، والضوضاء العالية، والاعتمادية الزمنية طويلة الأجل التي تميز أسعار البيتكوين. وقد أدى هذا القصور إلى ظهور فجوة واضحة بين التعقيد المتزايد لديناميكيات أسعار العملات المشفرة وقدرة النماذج التقليدية على استيعاب هذا التعقيد والتنبؤ به بدقة (Mendes, 2019) وفي هذا السياق، برزت نماذج التعلم العميق، و لاسيما نماذج الشبكات العصبية المتكررة المطورة مثل نموذج الذاكرة الطويلة والقصيرة المدى (LSTM) ونموذج وحدة البوابات المتكررة (GRU)، كبديل واعدة لما تمتلكه من قدرة عالية على التقاط الأنماط الزمنية غير الخطية والاعتمادات طويلة الأمد دون الحاجة إلى افتراضات صارمة حول شكل البيانات. وعليه، تسعى هذه الدراسة إلى سد فجوة بحثية قائمة من خلال تقييم الأداء التنبؤي لهذين النموذجين باستخدام سلسلة زمنية أسبوعية طويلة الأجل لأسعار إغلاق عملة البيتكوين تمتد لعشر سنوات، مع إجراء مقارنة منهجية بينهما بهدف تحديد النموذج الأكثر كفاءة في تمثيل ديناميكيات الأسعار المشفرة وتحسين دقة التنبؤ في الدراسات المستقبلية.

2. الجانب النظري للدراسة Theoretical side

2.1. التعلم العميق Deep learning يعد التعلم العميق مجالاً بحثياً جديداً في التعلم الآلي، إذ يهدف إلى بناء ومحاكاة الشبكة العصبية للدماغ البشري لتحليل وتعلم البيانات. هذا المجال يقلد آلية الدماغ البشري في تفسير البيانات مثل النصوص و الصور والصوت ، يستند مفهوم التعلم العميق إلى الأبحاث في الشبكات العصبية الاصطناعية، ولهذا يُطلق عليه أيضاً اسم الشبكات العصبية العميقة. يمتاز التعلم العميق بالبنية متعددة الطبقات، إذ يحتوي النموذج عادةً على خمس أو ست طبقات مخفية أو أكثر، مما يعكس عمق بنية النموذج (Wang et al., 2021:3) حيث ان مصطلح "العميق" في التعلم العميق يشير إلى السمة المعمارية التي تتجسد في استخدام عدد كبير من الطبقات المخفية في الشبكات العصبية الحديثة بالمقابل، في الشبكات العصبية البسيطة يوجد حد أقصى من طبقتين بين مدخلات ومخرجات الشبكة العصبية (Sharma et al., 2021:24) كما تتضمن هذه الشبكات العميقة خلايا عصبية أكثر تطوراً مقارنةً بالشبكات العصبية الاصطناعية التقليدية، حيث قد تعتمد على عمليات متقدمة مثل عمليات الالتفاف (Convolution) أو توظيف أكثر من دالة تنشيط ضمن الخلية العصبية الواحدة، بدلاً من الاكتفاء بدالة تنشيط بسيطة. وتُسهم هذه الخصائص في تمكين الشبكات العصبية العميقة من معالجة بيانات الإدخال الخام مباشرةً، واكتشاف التمثيلات والسمات الكامنة بصورة تلقائية دون الحاجة إلى هندسة يدوية للميزات (Janiesch et al., 2021:687) حيث يقدم التعلم العميق بنية حسابية عن طريق دمج عدة طبقات معالجة، بما في ذلك طبقات الإدخال والطبقات المخفية وطبقات الإخراج، لتعلم الأنماط من البيانات (Wang et al., 2021:3) وبذلك يمثل التعلم العميق تطبيقاً عملياً للشبكات العصبية الاصطناعية على مهام التعلم إذ يمكنه استغلال قدرات التعلم (التمثيل) المتقدمة للشبكات العصبية، والتي كانت تُعتبر فعالة فقط مع طبقة واحدة أو طبقتين وكمية صغيرة من البيانات في السابق (Zhang et al., 2018:3) كل نموذج تم إنشاؤه يجب أن يحقق مهمتين أساسيتين للتعلم العميق؛ استخراج المعلومات الدلالية من المدخلات وإنتاج مخرجات ذات مغزى (Mijwil, 2022:119)

2.2 نماذج التعلم العميق Deep learning models

1. شبكة الذاكرة الطويلة القصيرة المدى (LSTM) هي نوع خاص من الشبكات العصبية المتكررة (RNN) تستخدم في مجال التعلم العميق حيث تكون مزودة بعناصر إضافية لحفظ البيانات المتسلسلة العنصر المهم في LSTM هو حالة الخلية التي تنقل المعلومات عبر سلسلة التسلسل. هذه الحالة تعمل كذاكرة للشبكة. وبذلك يمكنها الاحتفاظ بالمعلومات السعرية ذات الأثر طويل الأجل، وهو ما يتلاءم مع طبيعة السلاسل الزمنية لأسعار البيتكوين التي تتسم باعتمادية زمنية ممتدة وتقلبات حادة. ولا تحمل حالة الخلية سوى المعلومات ذات الصلة في التسلسل، إذ يمكن اضافتها

او حذفها عبر البوابات. اذ تتعرف البوابات على المعلومات ذات الصلة التي يجب الاحتفاظ بها أو نسيانها خلال التدريب. لذلك، معلومات المراحل السابقة تؤثر على المراحل اللاحقة في التسلسل وبذلك يستطيع النموذج على تصفية الضوضاء السعيرية قصيرة الأجل والاحتفاظ فقط بالمعلومات ذات الصلة بالحركات السعيرية السابقة، مما يسهم في تحسين دقة التنبؤ. (Mendes, 2019:26) وبذلك تعد شبكات LSTM مناسبة تمامًا لتحليل وتعلم البيانات المتسلسلة، مثل تصنيف البيانات ومعالجتها والتنبؤ بها بناءً على بيانات السلاسل الزمنية، مما يميزها عن الشبكات التقليدية الأخرى وبالتالي، يمكن استخدام LSTM عندما تكون البيانات بتنسيق تسلسلي اذ يتم تطبيقها بشكل شائع في مجال تحليل السلاسل الزمنية، ومعالجة اللغة الطبيعية، والتعرف على الكلام (Sarker, 2021:160) قُدمت شبكة الذاكرة طويلة المدى بواسطة Schmidhuber and Hochreiter في عام 1997 حيث تُعد نموذجاً محسناً من الشبكات التكرارية حيث تم تعديل بنية الشبكة لغرض جعلها قادرة على الاحتفاظ بالمعلومات المهمة لمدة زمنية مناسبة وكذلك تحديد المعلومات الغير مهمة للتخلص منها (Hochreiter & Schmidhuber, 1997:2)

2. نموذج وحدة البوابات المتكررة GRU : تُعد وحدة البوابات المتكررة (GRU) من أنواع الشبكات العصبية المتكررة (RNN)، وهي تطوير لنموذج (LSTM) لكنها أبسط في البنية وأقل في المتطلبات الحسابية. وقد طوّرها Cho وزملاؤه عام (2014) بهدف تقليل عدد البوابات المستخدمة في النموذج وتحسين كفاءته في التدريب، مع الحفاظ على مستوى دقة مماثل تقريباً لنموذج (LSTM) في أداء المهام المختلفة (Nosouhian et al., 2021:2) كان الهدف من اقتراح وحدة (GRU) في المقام الأول لتحسين تعقيد وتكلفة الحوسبة لوحدة (LSTM) حيث تستخدم بوابتين فقط، ويمكنها تحقيق دقة مماثلة لوحدة (LSTM) الأكثر تعقيداً في بعض التطبيقات. تحتوي وحدة (GRU) على معلمات قابلة للتدريب أقل لأنها لا تحتوي على طبقات الإخراج الموجودة في (LSTM). (Nosouhian, et.al, 2021:2) حيث طُرح هذا النموذج كبديل لـ (LSTM)، على الرغم من قوة وحدات (LSTM)، إلا أن بنيتها تتضمن ثلاث بوابات وحالة خلية، مما يجعل النموذج معقداً وكثيف المعاملات. تُبسّط وحدة (GRU) بنية النموذج من خلال دمج بوابة النسيان وبوابة الإدخال في بوابة تحديث واحدة، مما يقلل عدد المعاملات ويحسن الكفاءة الحسابية (He et al., 2024:17) حيث يحتفظ بقدرته على النقاط التبعيات طويلة المدى ومعالجة مشكلة التدرج المتلاشي مع تقليل تعقيد النموذج. ومن أبرز الفروقات بين (GRU) و (LSTM) عدم وجود حالة خلية ذاكرة منفصلة. وبدلاً من ذلك، تستخدم (GRU) حالة مخفية تجمع بين دور كل من الحالة المخفية وحالة خلية الذاكرة في (LSTM) ويؤدي هذا التبسيط إلى بنية أكثر إحكاماً مما يجعل (GRU) خياراً جذاباً بشكل خاص في الاحتمالات التي تكون فيها الموارد الحسابية محدودة. (Shahinzadeh et al., 2024:7)

2.3 العملات المشفرة Cryptocurrencies

يُعزى تاريخ العملات المشفرة إلى عالم التشفير الأمريكي ديفيد تشاوم، الذي قام بتطوير أول نموذج للعملة المشفرة تحت اسم "ECash" وبالرغم من أن ECash لم تحقق انتشاراً كبيراً من حيث حجم المعاملات، إلا أنها تعد بداية لتأسيس مفهوم التداول باستخدام دفتر الأستاذ الإلكتروني (Rice, 2019:5) اذ قدم Chaum مفهوم "التوقيعات العمياء" الذي يسعى إلى إنشاء نظام نقدي رقمي يحافظ على الخصوصية ويحقق إتمام المعاملات بشكل مجهول (Chaum, 1983:203) وبالرغم من أن ابتكاراته لم تحظ بأبواب واسعة النطاق، إلا أنها كانت محورية في تصور ميزات الخصوصية التي تم دمجها لاحقاً في العملات المشفرة (Faez Hasan, 2023:65) ظهرت العملة المشفرة فقط في العالم الافتراضي أي ليس لها جنبه مادية كعملاتنا الحالية فهي تمثل أحد أشكال العملات الافتراضية (Faria, 2020:8) ومن الجدير بالذكر أن العملات المشفرة هي وليدة الثورة الرقمية التي حدثت من خلال العقود القليلة الماضية (Sanz, 2020:15) ظهر تطوير العملات المشفرة بحيث لا يتم تشغيلها غالباً بطريقة مركزية على عكس العملات الافتراضية التي يتم التحكم فيها مركزياً عن طريق مصمم الألعاب أو مشغل المنصة عبر الإنترنت (Peters et al., 2015:5) اذ تقع العملات المشفرة عند تقاطع الابتكار والتطوير المالي (Chohan, 2017:5) عادة ما يتم تقديم العملات المشفرة على أنها "ثورة"، ولكن يمكن وصفها بدقة أكثر بأنها مزيج بارع من أساليب الابتكار التكنولوجي والتصميمي والنقدي، فهي تبرز على أساس معادلة رياضية خوارزمية بأماكن الجميع التحقق منها، مما يعزز اعتماديتها وشفافيتها. كان الهدف الرئيسي لـ Satoshi Nakamoto هو تطوير نظام دفع إلكتروني غير خاضع لسيطرة أي سلطة مركزية. (أي يصدر بدون سلطة مركزية إدارية) وبعد سلسلة من الاختبارات والتطورات، نجح في إنشاء عملة رقمية لا مركزية تتميز بسرعتها في التداول، واستقلالها عن أي جهة حكومية ومجهولية الهوية. وهكذا، أسهمت العملة الرقمية تحولاً جذرياً في مفهوم الأموال التقليدية، اذ أصبحت للمرة

الأولى نظاماً لا مركزياً يمكن للجميع المشاركة فيه بحرية. (Faria, 2020:8) ومع التطور المتسارع لأسواق العملات المشفرة وتزايد ترابطها مع الأسواق المالية الأخرى، ازدادت تعقيد حركة أسعارها نتيجة خصائصها المتمثلة في التقلب العالي، وعدم الخطية، والتأثر السريع بالعوامل الاقتصادية والتقنية والسلوكية. وتعد هذه الخصائص سبباً رئيسياً في جعل التنبؤ بأسعار العملات المشفرة تحدياً علمياً حقيقياً، مما يستلزم الاعتماد على نماذج متقدمة قادرة على التعامل مع الطبيعة المعقدة وغير المستقرة لهذه الأسواق.

2.4. خصائص العملات المشفرة Characteristics of Cryptocurrencies

1. أصل رقمي تعتبر العملات المشفرة تمثيلات رقمية قابلة للتحويل، ومصممة بطريقة تمنع نسخها أو تكرارها تعرف بأصول التشفير وتتفق مع العملات التقليدية ببعض الخصائص أهمها مخزن للقيمة وسيلة للتبادل وقابلة للاستثمار ومن منظور التنبؤ بالسلاسل الزمنية، فإن كون العملات المشفرة أصولاً رقمية خالصة يجعل بيانات أسعارها متاحة بشكل منتظم ومهيكل زمنياً، الأمر الذي يسمح ببناء سلاسل زمنية مستمرة وقابلة للتحليل الإحصائي والتعلم العميق، ويعزز إمكانية نمذجة أنماطها السعرية والتنبؤ بحركتها المستقبلية.

(Revuelta, 2018:7)

2. قيمة غير جوهريّة يتمثل مصطلح العملات المشفرة (الافتراضية) إلى فقط العملات الموجودة في شكل إلكتروني، وليس لها شكل رسمي ومادي (Hillman, 2020:78) ما يجب عدم الخلط بينها وبين النقود الإلكترونية كالحساب المصرفي عبر الإنترنت، والذي يبرز المبلغ النقدي المحتفظ به في حساب محدد ومرتبطة بعملة مادية، وتؤدي هذه الطبيعة غير الجوهريّة إلى تقلبات سعرية مرتفعة وغير خطية، مما ينعكس على شكل السلاسل الزمنية لأسعار العملات المشفرة، ويجعلها أكثر تعقيداً مقارنة بالأصول التقليدية، وهو ما يستلزم استخدام نماذج تنبؤ قادرة على التقاط هذه اللاخطية والتغيرات المفاجئة في السلوك السعري. (Alsalmi et al., 2023:1)

3. الخصوصية عدم كشف الهوية يمكن للجمهور أن يلاحظ أن شخصاً ما يرسل مبلغاً إلى شخص آخر، ولكن من دون معلومات اذ تربط المعاملة بهوية تحديد الأطراف اذ تحافظ العملات المشفرة على الخصوصية من دون الحاجة للطرف الثالث الموثوق به من خلال إبقاء المفاتيح العامة مجهولة سواء العام أم الخاص، وتنعكس هذه الخاصية على السلاسل الزمنية لأسعار العملات المشفرة من خلال زيادة درجة عدم اليقين والمضاربة، إذ يصعب تتبع سلوك المستثمرين أو ربط تحركات الأسعار بعوامل أساسية واضحة، مما يؤدي إلى أنماط زمنية معقدة تتطلب نماذج تنبؤ مرنة قادرة على استيعاب هذا الغموض السلوكي. (Härdle et al., 2020:8)

4. مدعومة بقوانين العرض والطلب فقط تعمل العملات المشفرة على عكس العملات الورقية التقليدية، حيث تعمل وفقاً لمجموعة مختلفة من العوامل والمبادئ التي تحدد ديناميكيات قيمتها وأسعارها، حيث يتم تخزينها في محافظ الكترونية تسمح بإجراء عمليات الشراء والبيع التي يحتاجها المستخدم، وبشكل واضح تختلف العملة المشفرة على العملات التقليدية لعدم وجود هيئة تنظيمية مركزية، ويؤدي هذا الاعتماد المباشر على تفاعل قوى السوق إلى تقلبات سعرية حادة وغير منتظمة، تنعكس في شكل سلاسل زمنية تتسم بالتذبذب وعدم الاستقرار، مما يزيد من صعوبة التنبؤ باستخدام النماذج التقليدية، ويبرز الحاجة إلى نماذج تعلم عميق قادرة على التقاط الأنماط الديناميكية الناتجة عن تغيرات العرض والطلب. (Revuelta, 2018:7)

5. وقت التداول تجري عملية تداول العملات المشفرة على مدار الساعة وطوال أيام الأسبوع على عكس أسواق تداول الأصول التقليدية المختلفة، كما ان مصادر بياناتها اغلبها متاحة للجمهور ومفتوحة (Härdle et al., 2020:10) حيث ان إنجاز المعاملة يحتاج إلى وقت قصير مقارنة مع المعاملة الاعتيادية ويمكن تحويل الأموال وتداولها بسهولة في جميع أنحاء العالم، ويترتب على الاستمرارية الزمنية للتداول تكوّن سلاسل زمنية كثيفة ومتواصلة دون فترات توقف، الأمر الذي يؤدي إلى تداخل الأنماط قصيرة وطويلة الأجل في حركة الأسعار، ويجعل التنبؤ الزمني أكثر تعقيداً، لكنه في الوقت نفسه يوفر بيانات غنية يمكن استثمارها بكفاءة باستخدام نماذج تنبؤ متقدمة. (Bos, 2018:11)

2.5. أنواع العملات المشفرة Types of cryptocurrencies

1. عملة البيتكوين Bitcoin (BTC) تعتبر عملة (BTC) العملة المشفرة الرئيسية، وتم تحديد اختبارها عن باقي العملات المشفرة كونها أول عملة ظهرت للوجود (Malladi, 2023:2) ظهرت عملة (BTC) وسط الأزمة الاقتصادية المالية لعام 2008 الناجمة عن مشكلات الرهن العقاري في الولايات المتحدة، نتج عنه عدم ثقة واسعة النطاق في النظام المالي العالمي (Barrutia et al., 2019:276) اذ تم تبني بروتوكول Bitcoin تحت الاسم

المستعار Satoshi Nakamoto في ورقة بحثية تشريعية الى نظاماً يتم فيه إنشاء العملة الرقمية داخل شبكة نظير إلى نظير. يستند نظام Bitcoin على شبكة لامركزية للتأكد من المعاملات ودفتر حسابات عام يُعرف باسم blockchain لمنع الإنفاق المزدوج. كما يشار إلى المشاركين في الشبكة باسم عمال المناجم وهم مسؤولون عن تأكيد المعاملات ويكافونون بتلقي عملات Bitcoin جديدة. تم تعدين أول عملات Bitcoin باستخدام قوة الحوسبة لحل المشكلات الرياضية التي مازالت بحاجة إلى حل كجزء من عملية التأكيد (Wolfson, 2015:201)

2. **عملة الاثيريوم (ETH) Ethereum** تطورت عملة (ETH) منذ إصدارها في يوليو 2015، لتصبح منصة سلسلة الكتل الأكثر شعبية للعقود الذكية (Zou et al., 2021:39) وتطابق (ETH) إلى حد كبير عملة (BTC) ولكنها تسعى إلى أن تكون عقد ذكي مفتوح، حيث يمكن للمعاملات تنفيذ عقد ذكي بطرائق مختلفة على سلسلة الكتل، كتسليم الأموال الرقمية أو البيانات إلى عنوان العقد، إذا تم إكمال العقد الذكي بنجاح، فيمكنه تنفيذ عقود ذكية أخرى أو معالجة الكثير من المعاملات. (Rahardja, 2023:196)

3. **عملة لايتكوين (LTC) Litecoin** يمكن اعتبار لايتكوين (LTC) بمثابة "المعيار الفضي" للعملات المشفرة، حيث تعتبر أكثر العملات المشفرة استخداماً من قبل كلٍ من المعدّنين ومنصات التداول (Ahamad et al., 2013:44) كما تعد من أوائل العملات الرقمية البديلة، إذ أنشئت عام 2011 على يد (Charlie Lee)، وكان الهدف منها تقديم معاملات أسرع في التأكيد مقارنةً بعملة البيتكوين، وهو ما نال رضا المستخدمين الذين عانوا من بطء التحويلات. وتمكنت لايتكوين من تنفيذ ذلك من خلال اعتماد خوارزمية التجزئة "Script"، التي تسهل عملية التعدين وتجعلها متاحة لمعدّنين الأفراد وأكثر سهولة (Faez Hasan, 2023:65)

3. منهجية الدراسة Study Methodology

3.1 مشكلة الدراسة Study Problem

في ظل التقلبات الحادة وعدم الخطية التي تتسم بها السلاسل الزمنية لأسعار العملات المشفرة، ولاسيما عملة البيتكوين، تبرز تحديات كبيرة أمام نماذج التنبؤ التقليدية في تحقيق دقة تنبؤية مستقرة. وعلى الرغم من التقدم الملحوظ في نماذج التعلم العميق، ما زال هناك عدم وضوح علمي حول مدى الاختلاف في الأداء التنبؤي بين نماذج الشبكات العصبية المتكررة المتقدمة عند تطبيقها على هذا النوع من البيانات وعليه، تتمحور مشكلة هذه الدراسة حول قياس ومقارنة دقة وكفاءة نموذج شبكة الذاكرة الطويلة والقصيرة المدى (LSTM) ونموذج وحدة البوابات المتكررة (GRU) في التنبؤ بأسعار البيتكوين، اعتماداً على سلسلة زمنية أسبوعية طويلة الأجل، وذلك من خلال تقييم أدائهما باستخدام مقاييس الخطأ الإحصائية مثل متوسط الخطأ المطلق (MAE) ومتوسط مربع الخطأ (MSE) والجذر التربيعي لمتوسط مربع الخطأ (RMSE)، بهدف تحديد النموذج الأكثر ملاءمة للتعامل مع خصائص السلوك السعري المتقلب وغير الخطي للعملات المشفرة.

3.2 أهمية الدراسة The importance of the study

- تكمّن أهمية الدراسة من تلاقي بُعدين أساسيين هما التطور السريع في تقنيات الذكاء الاصطناعي والتعلم العميق من ناحية، والحاجة المتزايدة إلى أدوات دقيقة للتنبؤ بأسعار العملات في الأسواق المالية الرقمية من ناحية أخرى. مما يسمح بفهم كيفية استجابة كل نموذج لطبيعة البيانات المختلفة ومدى قدرته على التعميم في بيئات مالية مختلفة.
- تبرز أهمية الدراسة من خلال تقييم فعالية نماذج التنبؤ بشكل كمي وقابل للقياس، وذلك عبر مقارنة أداء نموذج شبكة الذاكرة الطويلة والقصيرة المدى (LSTM) ونموذج وحدة البوابات المتكررة (GRU) باستخدام مؤشرات أداء إحصائية واضحة، تشمل متوسط الخطأ المطلق (MAE)، ومتوسط مربع الخطأ (MSE)، والجذر التربيعي لمتوسط مربع الخطأ (RMSE).
- كما تسهم الدراسة في بيان مدى حساسية كل نموذج لخصائص السلاسل الزمنية لأسعار البيتكوين، من حيث التقلب وعدم الخطية والاعتمادية الزمنية طويلة الأجل، وذلك من خلال تحليل الفروق في قيم مؤشرات الأداء بين النموذجين، بما يسمح بتقييم قدرة كل نموذج على التعميم عند التعامل مع بيانات مالية عالية التقلب.

3.3 اهداف الدراسة Study objectives

- تقييم قدرة نموذج LSTM على التنبؤ بأسعار البيتكوين.
- تقييم قدرة نموذج GRU على التنبؤ بأسعار البيتكوين
- مقارنة أداء النموذجين لتحديد النموذج الأكثر دقة، وتحليل أسباب اختلاف الأداء بناء على خصائص البيانات وهيكلكل نموذج

3.4. مجتمع وعينة الدراسة Study community and sample

يتمثل مجتمع الدراسة في جميع البيانات لأسعار العملات المشفرة (الرقمية) ضمن الأسواق المالية العالمية ويمثل هذا المجتمع جميع السلاسل الزمنية التي تبين حركة أسعار العملات في الأسواق العالمية، اما عينة الدراسة فتكوّنت من سلسلة زمنية لأسعار عملة البيتكوين لمدة عشر سنوات من 4 يناير 2015 وحتى 29 ديسمبر 2024. اذ تم جمع البيانات على أساس أسبوعي لمدة (522) أسبوع (مشاهدة) حيث تمثل كل نقطة بيانات سعر الإغلاق في نهاية أسبوع التداول. ويعزى سبب هذا الاختيار إلى كون البيتكوين العملة المشفرة الأولى والأكبر من حيث القيمة السوقية، والأكثر تأثيراً في سوق الأصول الرقمية وشهرة. كما تمتاز سلسلته السعرية بالتقلب العالي، مما يجعلها حالة دراسية مثالية لاختبار قدرة نماذج التعلم العميق على التعامل مع البيانات غير المستقرة

3.5. المقاييس المستخدمة Measures used**1. المتغير المستقل (independent variable)**

- تم استخدام نموذج التعلم العميق كمتغير مستقل اذ تم اجراء عدة خطوات من تهيئة البيانات وتطبيق تحجيم القيم (Normalization) باستخدام طريقة Min-Max scaled لتسهيل عملية التعلم. وذلك بتحويل القيم الأصلية للبيانات إلى نطاق رقمي محدد وثابت (عادةً بين 0 و 1) وتعتمد على المعادلة التالية: (Xiong, 2020:42)

$$X_{New} = \frac{X - X_{min}}{X_{max} - X_{min}}$$
 ومن ثم تقسيم البيانات إلى بيانات تدريب (Training Set) بنسبة 80% وبيانات اختبار (Testing Set) بنسبة 20%.

2. تصميم النماذج (Model Design)

تصميم أو تحديد النماذج من خلال تحديد عدد طبقات في كل نموذج، وعدد العقد في كل طبقة. اذ اعتمدت الدراسة على اثنين من نماذج الشبكات العصبية المتكررة (Recurrent Neural Networks - RNNs) نموذج LSTM (Long Short-Term Memory) ونموذج GRU (Gated Recurrent Unit) لتقييم قدرتهما على التنبؤ بأسعار العملات عبر الزمن.

3. تدريب النماذج (Model Training)

تدريب الشبكة من خلال تحديد الخوارزمية المناسبة للتدريب، باستخدام دالة متوسط مربعات الخطأ (MSE) وفق خوارزمية التحسين (Adam Optimizer)

4. تقييم أداء النماذج (Model Evaluation)

تقييم أداء النماذج (Model Evaluation) يتم استخدام مجموعة من المعايير لتقييم أداء النموذجين، وهي: متوسط مربع الخطأ (Mean square error (MSE) والجذر التربيعي لمتوسط مربع الخطأ (Root Mean Square Error (RMSE) ومتوسط الخطأ المطلق (Mean Absolute Error (MAE)

5. التحليل المقارن (Comparative Analysis)

يتم إجراء مقارنة بين أداء النموذجين (LSTM و GRU) لتحديد النموذج الأكثر دقة في التنبؤ. الذي يحقق اقل قيمة في مؤشرات الدقة الإحصائية

6. المتغير التابع (Dependent Variable)

تم استخدام العملات المشفرة كمتغير تابع حيث تم استخراج الإحصاءات الوصفية على بيانات الأسعار بهدف توصيف خصائص السلسلة الزمنية من حيث الاتجاه العام والتقلب، وذلك باستخدام المؤشرات الأتية (المتوسط الحسابي، الوسيط، الحد الأدنى والاعلى، الانحراف المعياري، التفرطح، الالتواء، اختبار جارك بير)

3.6. فرضية الدراسة Study hypothesis

- الفرضية الرئيسية الأولى: عدم دقة نموذج Lstm ونموذج GRU في التنبؤ بأسعار العملات المشفرة المتمثلة بالبيتكوين
- الفرضية الرئيسية الثانية: لا يوجد تفوق في الاداء لأحد النموذجين (Lstm او GRU) في التنبؤ بأسعار العملات المشفرة

4. الدراسات السابقة

4.1. (رواية محمد, 2024)

عنوان الدراسة (استخدام شبكة الذاكرة طويلة قصيرة المدى للتنبؤ بأسعار عملة البيتكوين) هدفت الدراسة إلى التنبؤ بأسعار الإغلاق اليومية لعملة البيتكوين باستخدام نموذج مطور من الشبكات العصبية الاصطناعية، يتمثل في شبكة الذاكرة طويلة وقصيرة المدى (LSTM) خلال الفترة الممتدة من 17/09/2014 إلى 27/06/2024، وذلك بغرض تحسين دقة التنبؤ مقارنة بالأساليب التقليدية اعتمدت الدراسة على المنهج التطبيقي التحليلي باستخدام أدوات الذكاء الاصطناعي تم بناء نموذج LSTM على منصة Google Colab باستخدام لغة Python استخدمت مكتبات tensorflow، sklearn، numpy، pandas، matplotlib، seaborn حيث تم تقسيم البيانات إلى : 80% للتدريب و 20% للاختبار كما استخدمت معايير تقييم الأداء: MAE، MSE، RMSE، MAPE تمثل مجتمع الدراسة: بيانات أسعار الإغلاق اليومية لعملة البيتكوين في السوق العالمية. اما عينة الدراسة تضمنت سلسلة زمنية تتكون من 3572 مشاهدة يومية مأخوذة من موقع Yahoo Finance للفترة 17/09/2014 - 27/06/2024 أظهرت نتائج الدراسة أن شبكة الذاكرة الطويلة والقصيرة المدى (LSTM) تمتلك قدرة عالية على التنبؤ بأسعار البيتكوين بدقة كبيرة، اوصت الدراسة باجراء دراسات مستقبلية باستخدام نماذج ذكاء اصطناعي أخرى مثل الشبكات العصبية التلافيفية (CNN)، الشبكات ذات القاعدة الشعاعية (RBF)

4.2. دراسة (Awoke et al., 2021)

Bitcoin Price Prediction and Analysis Using Deep Learning Models

عنوان الدراسة : التنبؤ بسعر البيتكوين وتحليله باستخدام نماذج التعلم العميق. تهدف الدراسة الى التنبؤ بسعر البيتكوين بدقة أعلى باستخدام نماذج التعلم العميق، وتحديداً (LSTM) و (GRU) ومقارنة أداء النموذجين لمعرفة أيهما أكثر كفاءة في معالجة التقلب العالي في أسعار البيتكوين. تكون مجتمع الدراسة من جميع البيانات اليومية المتعلقة بأسعار البيتكوين المتاحة على موقع Kaggle اما العينة فتضمنت البيانات اليومية للبيتكوين للفترة من 1 يناير 2014 إلى 20 فبراير 2018 كما شملت العينة سبعة متغيرات : سعر الافتتاح، أعلى سعر، أدنى سعر، سعر الإغلاق، حجم التداول، والقيمة السوقية. اعتمدت الدراسة على المنهج التطبيقي التحليلي ونفذت التنبؤات تم بناء نموذج (LSTM) (GRU) ونفذت التنبؤات على العملات المشفرة الشائعة. حيث تم تقسيم البيانات إلى 80% للتدريب و 20% للاختبار كما استخدمت معايير تقييم الأداء جذر متوسط مربع الخطأ (RMSE) ومتوسط النسبة المئوية المطلقة للخطأ (MAPE) لتحديد أيهما يتمتع بدقة أفضل. تكشف الدراسة أن نموذج (GRU) هو الآلية الأفضل للتنبؤ بأسعار العملات المشفرة عبر السلاسل الزمنية حيث ان (GRU) أسرع في التدريب من (LSTM) حيث استغرق وقت التجميع (Compilation Time) وتوصلت الدراسة الى تطوير نماذج أكثر تقدماً وتعزيز دقة التنبؤ باستخدام معمارية أعمق وإضافة عوامل مؤثرة جديدة مثل النظام السياسي والعلاقات العامة وسياسة السوق وتوسيع نطاق الدراسة لتشمل عملات أخرى مثل الريبل والإيثريوم واللايتكوين

4.3. دراسة (Tanwar et al., 2021)

Deep learning-based cryptocurrency price prediction scheme with inter-dependent relations

مخطط التنبؤ بأسعار العملات المشفرة القائم على التعلم العميق مع العلاقات المترابطة هدفت الدراسة الى تطوير نموذج هجين مبني على تقنيات التعلم العميق (LSTM و GRU) لتوقع أسعار عملات (Litecoin) و (Zcash) مع الأخذ بعين الاعتبار التفاعلات مع العملة الأم (مثل Bitcoin). يتمثل المجتمع الأوسع للدراسة في جميع العملات المشفرة المتداولة في السوق. تمثلت عينة الدراسة من بيانات أسعار Litecoin و Zcash على مدى السنوات الخمس امتدت المدة الزمنية للعينة المستخدمة في الدراسة من 24 أغسطس، 2016، إلى 26 مايو، 2021. بإجمالي 1737 نقطة بيانات. أسلوب الدراسة يتضمن استخدام نموذج هجين يستند إلى تقنيتي LSTM و GRU تم جمع البيانات المالية من منصة Investing.com، حيث تم تضمين خمسة ميزات رئيسية (السعر، سعر الفتح، أعلى سعر، أقل سعر، وحجم التداول). قدم النموذج الهجين الذي يجمع بين تقنيات LSTM و GRU توقعات دقيقة لأسعار (Litecoin) و (Zcash) مقارنة بالنماذج الحالية تطبيق النموذج على عملات أخرى يُوصى بتطبيق النموذج الهجين على عملات مشفرة إضافية غير (Litecoin) و (Zcash)، مع التركيز على العملات ذات الترابطات المتعددة. هذا قد يزيد من فعالية النموذج ويوفر توقعات أدق للأسعار.

4.4. دراسة (Ammer & Aldhyani, 2022)

Deep Learning Algorithm to Predict Cryptocurrency Fluctuation Prices: Increasing Investment Awareness

خوارزمية التعلم العميق للتنبؤ بتقلبات أسعار العملات المشفرة: زيادة الوعي الاستثماري
تهدف الدراسة الى بناء نموذج LSTM للتنبؤ بتقلبات أسعار اربع عملات مشفرة هي
Ethereum, XRP, AMP, EOS

اعتمدت الدراسة على: المنهج التطبيقي باستخدام خوارزمية LSTM تم تقسيم البيانات الى 70% للتدريب و30% للأختبار وتم تقسيم النموذج بأستخدام مؤشرات MSE, RMSE, NRMSE, معامل الارتباط Pearson توصلت الدراسة الى ان نموذج LSTM قدم أفضل أداء في توقع أسعار جميع العملات الأربع، بدقة عالية وانخفاض كبير في أخطاء التنبؤ. كما لدى هذا القدرة على توفير الأساس لبيئة تداول حقيقية للمستثمرين للاستفادة منها في المستقبل القريب. أوصت الدراسة إنشاء نماذج تنبؤ دقيقة يمكن استخدامها لوضع توقعات لجميع العملات المشفرة
4.5. دراسة (Wu, 2024)

Review of deep learning models for crypto price prediction: implementation and evaluation

مراجعة نماذج التعلم العميق للتنبؤ بأسعار العملات المشفرة: التنفيذ والتقييم.

تهدف الدراسة الى تقييم نماذج جديدة من التعلم العميق، مثل شبكات الذاكرة الطويلة والقصيرة الأمد (LSTM)، الشبكات العصبية التلافيفية (CNN)، ونموذج (Transformers) لتوقع أسعار العملات المشفرة وإجراء تحليل لتقلبات أسعار أربع عملات مشفرة خلال جائحة COVID-19 ومقارنة الأداء بين النماذج أحادية المتغير ومتعددة المتغيرات لتقديم توقعات دقيقة لأسعار الإغلاق للعملات المشفرة تكون مجتمع الدراسة من الأسعار التاريخية لجميع العملات المشفرة اما عينة الدراسة تمثلت في أربع عملات مشفرة، وهي: بيتكوين (Bitcoin) والايثيريوم (Ethereum) ودوجكوين تضمن أسلوب الدراسة في هذا البحث استخدام نماذج التعلم العميق وأساليب إحصائية متقدمة لتوقع أسعار العملات المشفرة. اذ تم استخدام نماذج أحادية المتغير (univariate models) حيث يتم التنبؤ بأسعار كل عملة بشكل منفصل. وتم استخدام نماذج متعددة المتغيرات (multivariate models) حيث يتم دمج عوامل إضافية مثل أسعار الذهب وميزات أخرى لكل عملة (مثل الافتتاح، الأعلى، الأدنى، والإغلاق) لتحسين دقة التوقعات وتمت مقارنة أداء النماذج باستخدام مقاييس دقة مختلفة مثل الجذر التربيعي لمتوسط الخطأ و متوسط الخطأ المطلق ومتوسط النسبة المئوية للخطأ المطلق توصلت الدراسة ان نماذج التعلم العميق مع استراتيجيات متعددة المتغيرات توفر أعلى دقة في التنبؤ بأسعار العملات المشفرة تحسين النموذج متعدد المتغيرات بشكل أكبر باستخدام عوامل أكثر ارتباطاً لتحسين التوقعات

تُظهر الدراسات السابقة أن معظم البحوث التي تناولت التنبؤ بأسعار العملات المشفرة، ولاسيما البيتكوين، ركزت على استخدام نماذج التعلم العميق ضمن أطر زمنية قصيرة أو متوسطة، وبالاعتماد على بيانات يومية، مع اختلاف في طبيعة المتغيرات المدخلة ومقاييس التقييم المستخدمة. فعلى سبيل المثال، اعتمدت دراسة روابه (2024) على بيانات يومية وبمؤلف LSTM فقط، في حين قارنت دراسة Awoke et al. (2021) بين نمودي LSTM و GRU باستخدام بيانات يومية متعددة المتغيرات، وتوصلت إلى تفوق GRU من حيث سرعة التدريب والدقة في بعض الحالات. وعلى الرغم من القيمة العلمية لهذه الدراسات، إلا أنها لم تحسم بشكل قاطع أيّ النموذجين (LSTM) أم (GRU) أكثر كفاءة عند التعامل مع سلاسل زمنية طويلة الأجل وبوتيرة زمنية أقل كثافة (أسبوعية)، كما أن عدداً محدوداً منها اعتمد مقارنة منهجية مباشرة باستخدام مقاييس الخطأ الإحصائية الموحدة (MAE)، (MSE)، (RMSE) على فترة زمنية تمتد لعشر سنوات كاملة. ومن هنا، تتمثل الفجوة البحثية في غياب دراسات تطبيقية تقارن بين أداء LSTM و GRU باستخدام سلسلة زمنية أسبوعية طويلة الأمد لأسعار إغلاق البيتكوين، وبالاعتماد على مقاييس خطأ متجانسة تسمح بالحكم الموضوعي على دقة كل نموذج. وتسعى الدراسة الحالية إلى سد هذه الفجوة من خلال تقديم تحليل مقارنة دقيق يراعي خصائص البيانات غير الخطية والتقلب العالي للأسعار.

5. الجانب العملي للدراسة The practical side of the study

5.1. تحليل أسعار البيتكوين (BTC price)

الجدول التالي يتضمن الإحصاءات الوصفية والمؤشرات الإحصائية لأسعار البيتكوين:

جدول (1) الإحصاءات الوصفية والمؤشرات الإحصائية لأسعار البيتكوين

الاحتمالية	اختبار جاركة-بيرا	Kurtosis	التفرطح	Skewness	الانحراف المعياري	الحد الأعلى	Maximum	الحد الأدنى	Minimum	Median	المتوسط	Mean	المتوسط	الوصفية الإحصائية
0	156.664	0.920153	1.26058	22421.1	101418.	199.600	9681.05	20296.6	أسعار البيتكوين					

المصدر: اعداد الباحث بالاعتماد على مخرجات البرنامج الاحصائي SPSS V25

اعتمادا على نتائج الجدول يمكن توضيح الصورة حول أسعار عملة البيتكوين استنادا الى الإحصاءات الوصفية والمؤشرات الإحصائية وقيمها وكما يلي:

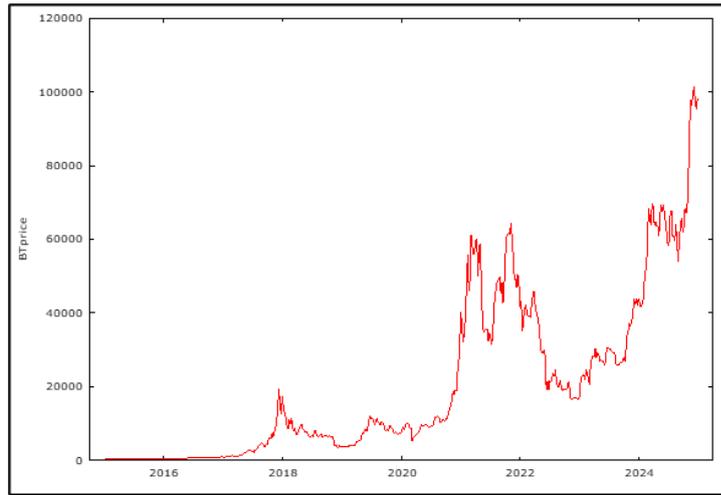
لقد أظهرت أسعار البيتكوين تباينًا حادًا وتقلبًا مرتفعًا، وهو ما يتضح من خلال المؤشرات المستخدمة فقد بلغت قيمة المتوسط الحسابي (20296.6) مما يشير إلى أن السعر المتوسط للبيتكوين خلال فترة الدراسة كان حوالي (20.297) بعبارة أخرى انها تعطي انطباعًا عامًا عن اتجاه السوق، لكن رغم ذلك فهي قد لا تكون دقيقة في ظل وجود قيم شاذة، خصوصًا أن قيمة الوسيط كان أقل منها بكثير حيث بلغت قيمته (9681.05) وهو ما يشير الى ان نصف القيم كانت أقل من (9681.05)، والنصف الآخر أعلى. ان الفارق بين المتوسط والوسيط الذي بلغت قيمته (10.615) يعني أن هناك قيمًا مرتفعة بشكل غير طبيعي دفعت المتوسط إلى الأعلى مما يشير إلى وجود توزيع للبيانات غير متماثل ومائل نحو اليمين. إضافة الى ذلك نجد ان الحد الأدنى للقيم بلغت قيمته (199.6) التي سجلت في بداية مرحلة العملة الرقمية مما يعني ان بدايات هذه العملة كانت قليلة الاستخدام الا انها تحولت بعد ذلك إلى أصل استثماري عالمي. كما ان الحد الأقصى للعملة بلغت قيمته (10141.8) وهي تمثل ذروة قيم البيتكوين. كما ان قيمة الانحراف المعياري بلغت (22421.1) وهيه قيمة مرتفعة تشير الى أن أسعار البيتكوين كانت متقلبة بشكل كبير ومما تجدر الإشارة اليه ان مؤشر الانحراف المعياري عادة ما يستخدم كمؤشر على درجة المخاطرة وكلما زادت قيمته زادت درجة عدم الاستقرار وصعوبة التنبؤ بالأسعار المستقبلية وهو مقارنة باليورو دولار يعطي انطباعا ان العملة الرقمية البيتكوين يمثل أصلًا عالي المخاطر. كما نجد ان مؤشر الالتواء بلغت قيمته (1.2606) وهو ما يشير إلى أن التوزيع منحرف بشكل إيجابي، بمعنى اخر وجود قيمًا عالية متطرفة دفعت التوزيع إلى اليمين مما يدل ماليًا الى إمكانية تحقيق مكاسب كبيرة، لكن هذه المكاسب غير مستمرة وغير مضمونة، وغالبًا ما تكون قليلة الحدوث. وفيما يتعلق بمؤشر التفرطح الذي بلغت قيمته (0.920) وهي قيمة أقل من 3 (التي تمثل التفرطح الطبيعي) التي تشير إلى أن التوزيع مفلطح أي أن القيم تتركز حول المركز بشكل أقل من التوزيع الطبيعي، وهذا قد يعني أن معظم تغيرات الأسعار كانت معتدلة، باستثناء بعض الطفرات. ان اختبار جاركة-بيرا الذي بلغت قيمته (156.664) بقيمة احتمالية مساوية الى الصفر حيث ان هذا الاختبار يقيس مدى انحراف وتفرطح التوزيع عن الشكل الطبيعي. بما أن القيمة الاحتمالية تساوي صفر أن الأسعار لا تتبع التوزيع الطبيعي. خلاصة لما سبق بما ان سعر البيتكوين يتميز بتقلبات حادة، وانحراف عالي إضافة الى وجود قيم شاذة ومتطرفة في قيمه، وعلى الرغم من وجود فرصة لتحقيق أرباح عالية، إلا أن مستوى المخاطرة مرتفع، إضافة الى ان التنبؤ بحركته المستقبلية يكون صعبا دون استخدام تقنيات متقدمة تأخذ بنظر الاعتبار الطبيعة غير الخطية وغير الطبيعية للتوزيع، وهنا تقترح استخدام طرقا تابعة للذكاء الاصطناعي المتمثلة بأنواع من الشبكات العصبية الاصطناعية ذات التعلم العميق وهما طريقتا LSTM و GRU.

5.2. التنبؤ بأسعار عملة البيتكوين Predicting Bitcoin Prices

1. تحليل اتجاهات أسعار البيتكوين (BTC) price Analyzing Bitcoin Price Trends

لقد تم رسم البيانات الخاصة بأسعار البيتكوين وكما موضح في ادناه حيث يبين الرسم البياني الزمني لأسعار البيتكوين للفترة الممتدة من عام 2015 إلى عام 2024 نمط سلوكي كثير التذبذب يتمثل في دورات سعرية متكررة من الارتفاع والانخفاض، ان هذا النمط يعكس طبيعة المضاربة العالية لهذا الأصل الرقمي. اذ يتضح انه في الفترة الزمنية الأولى الممتدة من 2015 حتى 2017 كان نمو الأسعار نموا تدريجيا طفيفا نسبيا، وفي عام 2017، أصبح

سعر البيتكوين أكثر تقلبًا. حيث في 13 أكتوبر 2017، تجاوز سعر البيتكوين 5000 دولار أمريكي لأول مرة، وفي 28 نوفمبر 2017، وصل إلى 10000 دولار أمريكي، وفي 18 ديسمبر 2017، شهدت الأسعار طفرة سعرية حادة في أواخر 2017، حيث بلغ السعر مستويات عالية وغير مسبوقة مقارنة بالأسعار التي قبلها حيث بلغ السعر ما يقارب 20.000 دولار، لكن بعد ذلك حصل انهيار حاد قد يعزى الى نتيجة يمكن ان نسميها بانفجار فقاعة البيتكوين اذا جاز التعبير (Mendes, 2019:29) مما نلاحظه من الرسم أيضا ان هذا السلوك قد ظهر أيضا في السنوات اللاحقة، اذ نلاحظ ان الأسعار قد أظهرت استقرارا نسبيا بين السنوات 2018 و 2020، وانخفضت في عام 2019 خلال فترة جائحة كوفيد-19، ثم بدئت مجددا في موجة صعود جديدة خلال عام 2021 اذ تجاوزت حاجز 60.000 دولار حيث ظهرت زيادة الطلب المؤسسي واهتمام الأسواق التقليدية بالأصول الرقمية. وبين عام 2022 وحتى عام 2024، ارتفعت أسعار البيتكوين بشكل غير مسبوق متجاوزة حاجز 100.000 دولار مع وجود انخفاض ايضا وهو ما يعكس إما موجة مضاربة جديدة أو استجابة السوق لظروف اقتصادية مثل ارتفاع معدلات التضخم العالمي أو تزايد تبني الأصول الرقمية كأدوات بديلة. ان هذا النمط الغير خطي في حركة السعر يشير إلى أن البيتكوين قد يكون خاضعا لقوى عرض وطلب تتأثر بمجموعة عوامل قد تكون عوامل نفسية أو سياسية أو تقنية أكثر مما ان تكون خاضعة الى أساسيات اقتصادية تقليدية. ان الشكل البياني يبين أيضا وجود موجات تناوبت بين الطمع بالحصول على أرباح والخوف من الخسارة مما كشف عن خصائص لدورة السوق (Market Cycles) لهذا الأصل، هذا السلوك غير الخطي فتح الباب أمام استخدام نماذج إحصائية متقدمة مثل الشبكات العصبية ذات التعلم العميق مثل طريقة LSTM و GRU لغرض الكشف عن طبيعة هذا السلوك وتقديم تنبؤات دقيقة حوله. خلاصة لما سبق نستنتج من خلال النتائج أن البيتكوين على الرغم من كونه أصلا ماليا رقميا حديث النشأة الا انه يعكس بعض الخصائص السلوكية المركبة التي تتداخل معها ديناميكيات نفسية للمستثمرين اضافة الى متغيرات اقتصادية عالمية وبالتالي فان هذا التداخل يجعل منه حالة دراسية مميزة ضمن الاقتصاد والتمويل الحديث



المصدر من اعداد الباحث بالاعتماد على مخرجات برنامج R

شكل (1) رسم القيم الحقيقية لسلسلة البيانات

2. التنبؤ بأسعار البيتكوين باستخدام نموذج شبكة الذاكرة الطويلة LSTM تُعتبر نماذج LSTM وما يُشتق منها، إلى جانب عدد كبير من النماذج الهجينة، من النماذج الأكثر شيوعاً في مجال التنبؤ بالسلاسل الزمنية المالية. وبما أن LSTM تستفيد بطبيعتها من الخصائص الزمنية للإشارات في السلاسل الزمنية، فإن استخدامها في التنبؤ المالي يُعد قراراً مدروساً وفعالاً (Leong, 2023:48) يتطلب التنبؤ بأسعار العملات اتباع مجموعة من الخطوات وكالاتي

5.2.2.1. تقسيم البيانات في هذه الخطوة تم تجزئه البيانات على بيانات تدريب بنسبة (80%) وبيانات اختبار بنسبة (20%) والهدف من تقسيم البيانات هو لاختبار قدرة نموذج شبكة الذاكرة الطويلة في التعميم على البيانات التي لم يتدرب عليها، إذ تستخدم عينة التدريب في التعلم واكتشاف الأنماط وخصائص البيانات، بينما تساهم عينة الاختبار في تقييم الاداء للنموذج وقياس قدرته على التعميم، وقد تم تقسيم بيانات أسعار البيتكوين وفق الجدول الآتي:

جدول (2) تقسيم بيانات أسعار البيتكوين

عينة الاختبار	عينة التدريب	
20%	80%	نسبة التقسيم
(2024 /12/29) الى (2023 /1/8)	(2023 /1/1) الى (2015 /1/4)	الفترة
104	418	المشاهدات

المصدر: اعداد الباحث بالاعتماد على مخرجات برنامج R

ويوضح الجدول (2) تقسيم بيانات الدراسة، إذ تم تخصيص 80% من البيانات بوصفها عينة تدريب حيث كانت عينة التدريب للفترة من (2015 /1/4) الى (2023 /1/1) بواقع 418 مشاهدة، فيما كانت عينة الاختبار للفترة (2023 /1/8) الى (2024 /12/29) بواقع 104 مشاهدة، ذ تمثل المشاهدات فترة الدراسة الكاملة.

5.2.2.2. تحديد معمارية شبكة الذاكرة الطويلة يعد تحديد معمارية الشبكات العصبية من الأمور الجوهرية في أدائها ونتائجها النهائية، إذ يمكن أن يؤدي التخصيص الخاطئ لما تحتويه من طبقات وعقد فضلاً عن دوال التنشيط و خوارزميات التعلم إلى نتائج عكسية. إذ تعتبر عملية تحديد هيكلية الشبكة معقدة للغاية نظراً لعدم وجود معايير محددة يمكن الاعتماد عليها في تحديد تلك المكونات، حيث تشير الأدبيات إلى ضرورة إجراء عدة محاولات تجريبية والاستدلال بمبدأ التجربة والخطأ في تحديد هيكلية الشبكات العصبية الاصطناعية التي تناسب البيانات المستخدمة والتي تتمثل في أسعار العملات. وفيما يرتبط بشبكة الذاكرة الطويلة المستخدمة تم بناء معمارية شبكة LSTM متعددة الطبقات، ثم تم تدريبها باستخدام دالة متوسط مربعات الخطأ (MSE) وفق خوارزمية التحسين (Adam Optimizer)، إذ تعد خوارزمية التحسين (Adam)، واحدة من أكثر خوارزميات التحسين شيوعاً وفعالية في مجال التعلم العميق (Deep Learning) والتعلم الآلي (Machine Learning). تم تقديم الخوارزمية لأول مرة في عام 2014 من قبل Jimmy Ba & Diederik P. Kingma. في ورقتهم البحثية الرائدة بعنوان dam: A Method for Stochastic Optimization (Kingma, 2015:1) بعد ذلك تم تقييم أداء النموذج من خلال معايير متوسط مربع الخطأ MSE والجذر التربيعي لمتوسط مربع الخطأ RMSE ومتوسط الخطأ المطلق MAE. ان المخرجات المعروضة ادناه تمثل ملخصاً للبنية المعمارية لنموذج الشبكة العصبية المتكررة (RNN) المبنية باستخدام LSTM. ففي إطار توقع أسعار عملة البيتكوين، تم تصميم نموذج تنبؤي يعتمد على LSTM ، حيث ان تفاصيل بنية هذا النموذج التي تتكون من ثلاث طبقات متسلسلة رئيسية كما هي موضحة في الجدول التالي:

جدول (3) المكونات التفصيلية لبنية نموذج LSTM

دالة التنشيط Activation	المعلمة Param	المخرجات Output Shape	عدد العقد (Neurons)	نوع الطبقة	
sigmoid	40800	(None, 48, 100)	100	lstm_45 (LSTM)	الطبقة الأولى
Tanh	30200	(None, 50)	50	lstm_44 (LSTM)	الطبقة الثانية
Linear	51	(None, 1)	1	dense_25 (Dense)	الطبقة الثالثة
(277.54 KB) 71051					اجمالي المعلمات
(277.54 KB) 71051					المعلمات القابلة للتدريب
(Adam Optimizer)					خوارزمية التحسين (Optimizer)
Mean Squared Error (MSE) متوسط مربع الخطأ					دالة الخسارة (Loss)

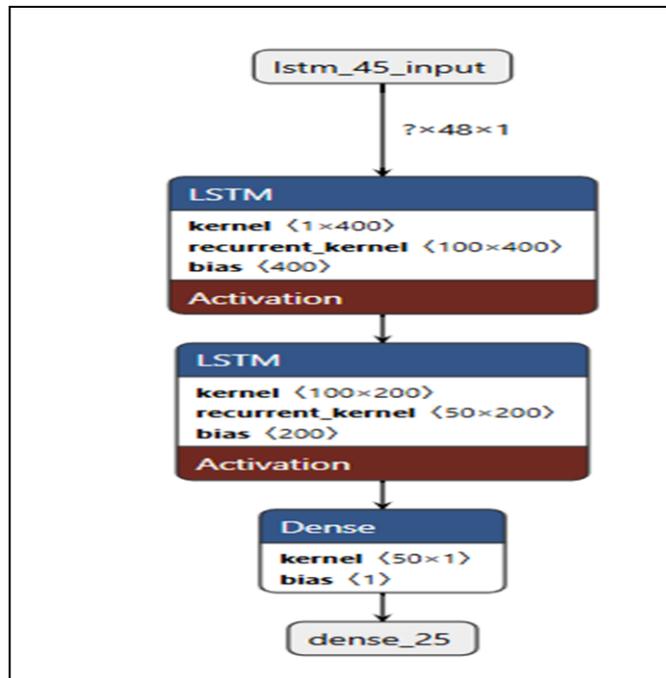
الجدول من اعداد الباحث بالاعتماد على مخرجات برنامج R

يتبين من النتائج في الجدول أعلاه ان الطبقة الأولى وهي (lstm_45 (LSTM) وهذه الطبقة تعتبر المدخل الأساسي للنموذج، حيث انها تستقبل تسلسل زمني مكون من 48 نقطة (أي 48 قيمة لسعر البيتكوين التي تمثل قيم سنة كاملة تقريباً) بعد ذلك يتم معالجة كل نقطة زمنية عبر 100 وحدة عصبية من نوع LSTM ، ما يؤدي إلى إنتاج مصفوفة مخرجات بحجم (100 × 48) بحيث يبلغ عدد المعاملات القابلة للتعلم في هذه الطبقة 40.800، تشير هذه المعاملات إلى الأوزان المرتبطة بأربع بوابات لكل خلية LSTM بوابة الإدخال، بوابة النسيان، بوابة الإخراج، والبوابة المرشحة (candidate) هذه البوابات تعد أساس الية عمل نموذج LSTM. يأتي دور الطبقة الثانية (LSTM) lstm_44 بعد انتهاء مهمة الطبقة الأولى حيث ان هذه الطبقة تقوم بمهمة استقبال المخرجات المتولدة من الطبقة الأولى (100 × 48) ثم بعد ذلك تقوم بضغطها إلى متجه واحد مكون من 50 وحدة فقط، وهذا الاجراء يعد تلخيص مدمج للأنماط الزمنية المكتشفة. ان عدد المعاملات القابلة للتعلم في هذه الطبقة بلغ 30.200، وهي تمثل

الأوزان اللازمة لمعالجة 100 مدخل وتوليد 50 وحدة عصبية جديدة، مع اعتبار وجود أربع بوابات لكل خلية LSTM. اما الطبقة الثالثة (Dense) dense_25 في هذه المعمارية فهي تمثل الطبقة النهائية في النموذج، ومهمة هذه الطبقة هي قيامها بتحويل متجه المخرجات الناتج من الطبقة الثانية الذي طوله 50 وحدة عصبية إلى قيمة عددية واحدة تمثل التوقع المستقبلي لسعر البيتكوين حيث تعتمد هذه الطبقة على دالة تنشيط خطية لاستخراج القيم النهائية. وتحتوي على 51 معلمة منها 50 وزناً لكل مدخل، بالإضافة إلى قيمة التحيز وهو ما يبين أن النموذج قد تم تدريبه بالكامل مما يمنحه مرونة أكبر في تعلم الأنماط الدقيقة والمعقدة ضمن بيانات البيتكوين.

فيما سبق لاحظنا استخدام طبقتين من LSTM متبوعتين بطبقة كثيفة وهو ما يعد خطوة مهمة نحو تحسين دقة التنبؤ حيث تسمح هذه البنية العميقة للنموذج بالتمييز بين الضوضاء والتقلبات الحادة التي تتسم بها عملة البيتكوين والتعرف على العلاقات الزمنية بعيدة المدى، وهذا الامر يجعل النموذج أكثر تكيفاً مع الطبيعة الديناميكية المتنوعة للسوق. وفيما يتعلق بدوال التنشيط فقد تم استخدام دوال التنشيط التالية في الطبقات المختلفة من معمارية شبكة LSTM:

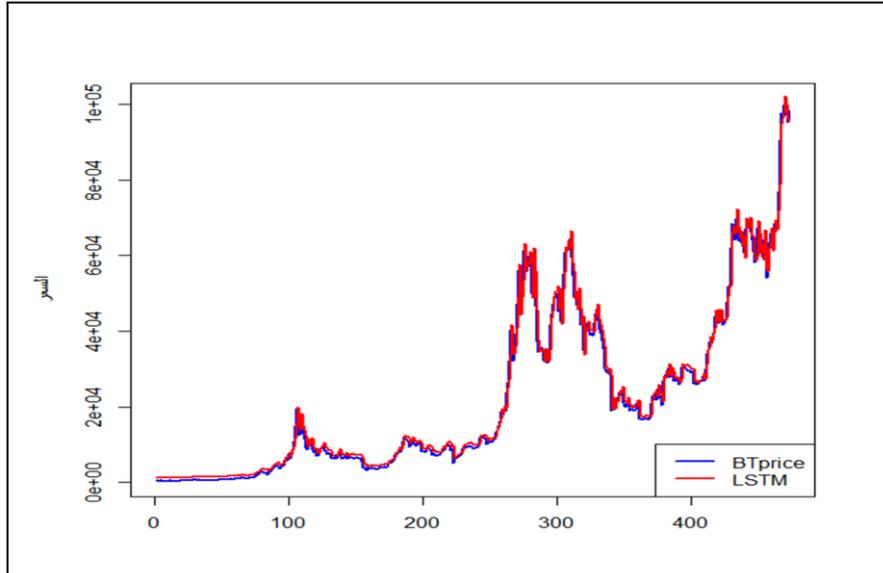
- تم استخدام دالة تنشيط sigmoid لغرض تفعيل البوابات الثلاثة (بوابة النسيان، بوابة الإدخال، وبوابة الإخراج)، وهذه الدالة تحول القيم لتصبح فيما بين 0 و 1، وهو ما يسمح بالتحكم في مقدار المعلومات التي يتم تمريرها أو نسيانها.
- تم استخدام دالة التنشيط tanh لغرض تحديث قيم الحالة الداخلية للخلية (cell state)، حيث تستخدم هذه الدالة لاحتساب القيم الجديدة التي ستضاف إلى الذاكرة، مما يضمن وجود تمثيل غير خطي.
- وفي الطبقة الثالثة التي تمثل طبقة الكثافة (Dense) التي تتكون من وحدة واحدة فقط تستخدم لاحتساب القيمة التنبؤية النهائية. هذه الطبقة تستخدم دالة تنشيط خطية (Linear Activation) بشكل افتراضي، بمعنى اخر انه لا يتم تطبيق أي دالة تحويل على القيمة الناتجة، ويعود السبب في ذلك الى كون مهمة النموذج في هذه الحالة هي التنبؤ بقيمة عددية.
- يتضمن مجمل النموذج 71,051 معاملاً قابلاً للتعلم، وهذه المعاملات تحدث جميعها أثناء عملية التدريب باستخدام خوارزمية التحسين المسماة "Adam" وقد تم تصميم النموذج بدون أي طبقات مجمدة لا يتم فيها تدريب المعاملات (non-trainable) وهو ما يعطي النموذج المرونة في التكيف الكامل مع خصائص البيانات وتعلم الأنماط الزمنية الدقيقة الكامنة فيها. ومما تجدر الإشارة اليه ان استخدام بنية متدرجة مكونة من طبقتي LSTM يسمح للنموذج بتعلم كل من العلاقات الزمنية القصيرة والطويلة الأمد، وهذا الامر يعطي النموذج قدرة تنبؤية قوية في تحليل السلاسل الزمنية المعقدة المتمثلة بأسعار البيتكوين. وان الشكل البياني التالي يوضح معمارية شبكة LSTM



المصدر: اعداد الباحث اعتماد على مخرجات برنامج R

شكل (2) معمارية شبكة LSTM المستخدمة في عملية التنبؤ بأسعار البيتكوين

بعد تحديد المعمارية المناسبة لشبكة LSTM واحتساب وتدريب معاملاتها واوزانها تم بعدها احتساب القيم التنبؤية للاسعار ورسمت هذه القيم مع القيم الحقيقية لمجموعة بيانات التدريب والاختبار وضمنت الرسومات في الشكل التالي الذي يوضح القيم الحقيقية والتنبؤية باستخدام شبكة LSTM:



المصدر: اعداد الباحث اعتماد على مخرجات برنامج R

شكل (3) القيم التنبؤية مع القيم الحقيقية لأسعار البيتكوين

- بالاعتماد على الشكل البياني أعلاه، نلاحظ أن نموذج شبكة LSTM قدّم تنبؤات قريبة من القيم الفعلية لأسعار البيتكوين، وهو ما يعكس قدرة هذا النموذج على التقاط الأنماط الزمنية الكامنة في البيانات بشكل فعال. يشير هذا التقارب إلى جودة التنبؤات التي يمكن أن تحققها شبكة LSTM، خاصة في بيئة مالية تتسم بالتقلب وعدم الاستقرار.

5.2.2.3. تقييم أداء النموذج لغرض تقييم دقة النموذج بشكل كمي، تم احتساب متوسط مربعات الخطأ Absolute Error (MAE) والجذر التربيعي لمتوسط مربع الخطأ (RMSE) ومتوسط الخطأ المطلق Mean Absolute Error (MSE) وكما هو موضح في الجدول التالي:

جدول (4) معايير المقارنة ومقدراتها المحسبة وفق طريقة LSTM لاسعار البيتكوين

معايير المقارنة	متوسط مربعات الخطأ	الجذر التربيعي لمتوسط مربع الخطأ	متوسط الخطأ المطلق
قيمة المعيار	MSE	RMSE	MAE
	6443728	2538.45	1699.129

المصدر: اعداد الباحث اعتماد على مخرجات برنامج R

يشير الجدول أعلاه إلى أن متوسط الخطأ المطلق (MAE) البالغ (1,699 دولار) لنموذج LSTM يعادل نحو 1.7% من متوسط سعر البيتكوين خلال فترة الدراسة. ويُعد هذا الانحراف محدودًا نسبيًا في ضوء التقلب العالي الذي يميز سوق العملات المشفرة، حيث قد تشهد الأسعار تغيرات تفوق هذه النسبة خلال فترات زمنية قصيرة. في حين مقياس الجذر التربيعي لمتوسط مربع الخطأ (RMSE) يشير إلى أن الانحراف المعياري للأخطاء يبلغ حوالي (2,538,45) دولار. هذه القيمة هي المقياس الأكثر شيوعاً لتقييم دقة النموذج، وتدل على أن النموذج يقدم تنبؤات بمتوسط خطأ يقع في هذا المجال. كما تُعتبر المقارنة بين قيمتي RMSE و MAE مؤشراً هاماً على توزيع الأخطاء حيث، نلاحظ أن قيمة RMSE (2,538,45) أعلى بشكل ملحوظ من قيمة MAE (1,699,13). فإن الفرق الواضح بين RMSE و MAE (حوالي 839 دولار) يشير إلى أن النموذج يعاني من أخطاء تنبؤ كبيرة نسبياً في بعض النقاط الزمنية (القيم الشاذة). هذا الأمر شائع في التنبؤ بأسعار الأصول المالية شديدة التقلب مثل البيتكوين. يشير الجدول ادناه احتساب القيم التنبؤية المستقبلية لفترة 5 قيم مستقبلية باستخدام نموذج LSTM وضمنت النتائج الآتي:

جدول (5) القيم التنبؤية المستقبلية لسلسلة البيتكوين وفق نموذج LSTM

التاريخ	القيم التنبؤية Prediction	Obs
2025/1/5	98186.56	1
2025/1/12	95420.56	2
2025/1/19	94119.64	3
2025/1/26	92638.52	4
2025/2/2	90717.73	5

المصدر: اعداد الباحث اعتماد على مخرجات برنامج R

تمثل القيم أعلاه ناتج عملية التنبؤ بسعر البيتكوين لخمس فترات زمنية مستقبلية باستخدام النموذج العميق LSTM حيث نلاحظ أن القيم التنبؤية تتناقص تدريجياً، مما يشير إلى أن النموذج يتوقع اتجاهًا تنازلياً في سعر البيتكوين خلال الفترات الخمس المقبلة مما قد يعكس أنماطاً في البيانات مثل نهاية دورة ارتفاع أو بداية تعديل للأسعار.

3. التنبؤ بأسعار البيتكوين باستخدام نموذج وحدة البوابات المتكررة GRU : يعتمد نموذج GRU على بنية متقدمة من الشبكات العصبية التكرارية من نوع GRU (Gated Recurrent Unit)، وهي تختلف عن بنية LSTM، حيث تمتاز بعدم تضمينها بوابة نسيان أو إخراج انما تعتمد على بوابتين أساسيتين هما بوابة التحديث التي تتحكم في تمرير المعلومات من الماضي إلى الحاضر، وبوابة إعادة الضبط التي تسمح للنموذج بتجاهل المعلومات غير الضرورية عند الحاجة إضافة الى مكون يدعى بالحالة الجديدة (Candidate state) مما يجعل GRU أقل تعقيداً من LSTM في التدريب مع الاحتفاظ بفعالية الأداء في معالجة البيانات الزمنية. وكما في نموذج LSTM فإن التنبؤ باستخدام وحدة البوابات التكرارية GRU يتطلب المرور بعدد من الخطوات وهي كالآتي

5.2.3.1 تقسيم البيانات تم في هذه الخطوة تجزئة بيانات أسعار البيتكوين على بيانات تدريب بنسبة (80%) وبيانات اختبار بنسبة (20%)، وكما موضح في الجدول ادناه.

جدول (6) تقسيم بيانات أسعار البيتكوين

عينة الاختبار	عينة التدريب	نسبة التقسيم
20%	80%	نسبة التقسيم
(2024/12/29) الى (2023/1/8)	(2023/1/1) الى (2015/1/4)	الفترة
104	418	المشاهدات

المصدر: اعداد الباحث

5.2.3.2 تحديد معمارية شبكة GRU تم بناء معمارية شبكة GRU لغرض استخدامها في تحليل في تحليل بيانات أسعار البيتكوين ثم تم تدريبها باستخدام دالة متوسط مربعات الخطأ (MSE) وفق خوارزمية التحسين (Adam Optimizer)، بعد ذلك تم تقييم أداء النموذج من خلال معايير MSE و RMSE و MAE. ان المخرجات المعروضة ادناه تمثل ملخصاً للبنية المعمارية لنموذج الشبكة العصبية المتكررة (RNN) المبنية باستخدام GRU. تم تصميم نموذج تنبؤي يعتمد على GRU حيث ان تفاصيل بنية هذا النموذج التي تتكون من ثلاث طبقات متسلسلة رئيسية هي كما موضحة في الجدول التالي:

جدول (7) المكونات التفصيلية لبنية نموذج GRU

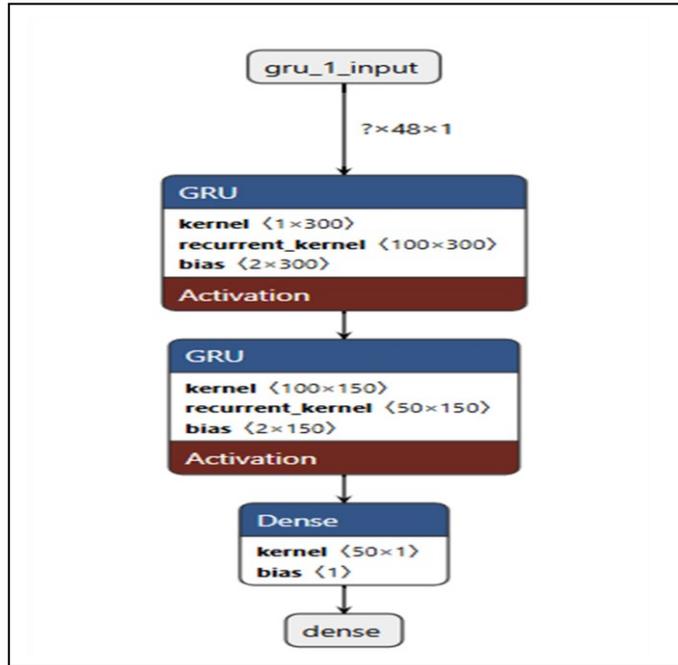
دالة التنشيط (Activation)	المعلمة Param	المخرجات Output Shape	عدد العقد (Neurons)	نوع الطبقة	
sigmoid	30900	(None, 48, 100)	100	gru 45 (GRU)	الطبقة الأولى
Tanh	22800	(None, 50)	50	gru 44 (GRU)	الطبقة الثانية
Linear	51	(None, 1)	1	dense_25 (Dense)	الطبقة الثالثة
53751 (209.96 KB)					اجمالي المعلمات
53751 (209.96 KB)					المعلمات القابلة للتدريب

(Adam Optimizer)	خوارزمية التحسين (Optimizer)
Mean Squared Error (MSE) متوسط مربع الخطأ	دالة الخسارة (Loss)

الجدول من اعداد الباحث بالاعتماد على مخرجات برنامج R

تتكون بنية معمارية GRU من الطبقة الأولى (gru_45) التي تتضمن 100 وحدة عصبية مخفية وهي تعالج تسلسلا زمنيا بطول 48 قيمة التي يبلغ عدد المعاملات فيها (30,900)، تنشأ من حساب الأوزان المرتبطة بكل من بوابة التحديث، وبوابة إعادة الضبط إضافة الى الحالة الجديدة، تشمل الأوزان للمدخلات والحالات السابقة، إضافة إلى الحد الثابت او التحيز (bias). اما الطبقة الأخرى فهي الطبقة الثانية (gru_44) التي تستلم ناتج الطبقة السابقة تقوم بتكثيف المعلومات إلى تمثيل أحادي الأبعاد مكون من (50) عنصراً حيث يبلغ عدد المعاملات في هذه الطبقة (22,800)، وهي تؤدي دور تلخيص السلسلة الزمنية وتمثيل الخصائص إلى الطبقة الأخيرة. والطبقة الثالثة (dense_25) هي طبقة إخراج كثيفة تقوم بتحويل القيم المستلمة من الطبقة الثانية إلى قيمة عددية واحدة (يمثل السعر المتوقع) بعدد معاملات يبلغ 51 معاملا (50 وزناً + 1 تحيز). ان العدد الإجمالي للمعاملات القابلة للتعلم في النموذج بلغ (53,751)، كلها قابلة للتحديث أثناء التدريب، وهو ما يشير إلى بنية متوازنة تجمع بين القوة والكفاءة الحسابية.

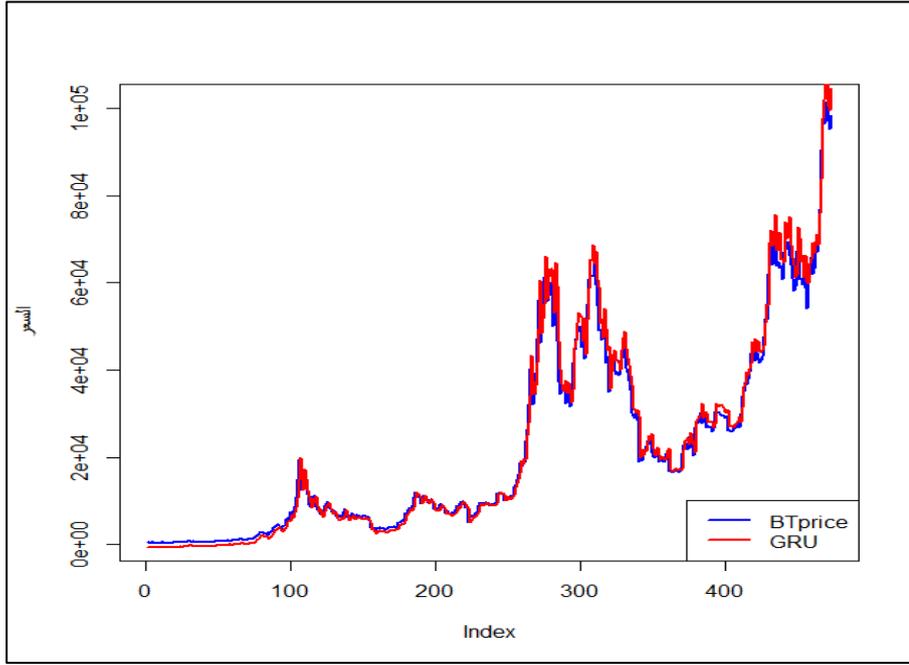
من خلال ما سبق يتبين ان أهمية هذه المعمارية تكمن في قدرتها على الاحتفاظ بالمعلومات المهمة عبر الزمن من خلال بوابة التحديث ثم تصفية المعلومات غير المفيدة من خلال بوابة إعادة الضبط. وبالتالي اعطاء تمثيل مخفي فعال يخدم أغراض التنبؤ الدقيقة. اما فيما يخص دوال التنشيط فقد تم دالة التنشيط من نوع tanh في بناء الحالة الجديدة (candidate state)، بينما تم استخدام دالة sigmoid في حساب بوابتي التحديث (update gate) وإعادة الضبط (reset gate)، ان هذا التكامل بين بنية GRU ودوال التنشيط المطبقة يجعل النموذج مناسباً لتطبيقات التنبؤ بالسلاسل الزمنية ذات البنية غير الخطية والتقلبات العالية المتمثلة بأسعار البيتكوين. وان الشكل البياني التالي يوضح معمارية شبكة GRU المستخدمة في عملية التنبؤ وفق ما تم شرحه سابقاً:



المصدر: اعداد الباحث اعتماد على مخرجات برنامج R

شكل (4) معمارية شبكة GRU المستخدمة في عملية التنبؤ بأسعار البيتكوين

بعد تحديد المعمارية المناسبة لشبكة GRU واحتساب وتدريب معاملاتهما واوزانها تم بعدها احتساب القيم التنبؤية للأسعار ورسمت هذه القيم مع القيم الحقيقية وضمنت الرسومات في الشكل التالي الذي يوضح القيم الحقيقية والتنبؤية باستخدام شبكة GRU:



المصدر: اعداد الباحث اعتماد على مخرجات برنامج R

شكل (5) القيم التنبؤية مع القيم الحقيقية لاسعار البيتكوين

الشكل أعلاه يبين رسم أسعار البيتكوين (BTC price) ومخرجات التنبؤ باستخدام نموذج GRU، حيث يلاحظ وجود تقارب بينهما خصوصاً في الاتجاهات العامة، مما يدل على قدرة GRU في تحديد الأنماط والتقلبات في السلسلة الأصلية. نلاحظ أيضاً أن نموذج GRU تابع الاتجاه التصاعدي للبيتكوين مما يعزز دقته التنبؤية وقدرة النموذج على محاكاة التحركات الحادة في سوق متقلب مثل البيتكوين.

5.2.3.3. تقييم أداء النموذج لغرض تقييم دقة النموذج بشكل كمي، تم احتساب متوسط مربعات الخطأ (MSE) والجزر التربيعي لمتوسط مربع الخطأ (RMSE) ومتوسط الخطأ المطلق Mean Absolute Error (MAE) وكما هو موضح في الجدول التالي:

جدول (8) معايير المقارنة ومقدراتها المحتمسبة وفق طريقة GRU لأسعار البيتكوين

متوسط الخطأ المطلق MAE	الجزر التربيعي لمتوسط مربع الخطأ RMSE	متوسط مربعات الخطأ MSE	معييار المقارنة قيمة المعييار
1933.518	2913.278	8487191	

الجدول من اعداد الباحث بالاعتماد على مخرجات برنامج R

يشير الجدول أعلاه إلى أن متوسط الخطأ المطلق (MAE) البالغ (1933,518 دولار) لنموذج GRU يعادل بمقدار 1,934 من متوسط سعر البيتكوين خلال فترة الدراسة. ويُعد هذا الانحراف محدوداً نسبياً في ضوء التقلب العالي الذي يميز سوق العملات المشفرة، حيث قد تشهد الأسعار تغيرات تفوق هذه النسبة خلال فترات زمنية قصيرة. في حين مقياس الجزر التربيعي لمتوسط مربع الخطأ (RMSE) يوضح إلى أن الانحراف المعياري للأخطاء يبلغ حوالي (2913,278) دولار. هذه القيمة هي المقياس الأكثر شيوعاً لتقييم دقة النموذج، وتدل على أن النموذج يقدم تنبؤات بمتوسط خطأ يقع في هذا النطاق.

كما تُعتبر المقارنة بين قيمتي RMSE و MAE مؤشراً هاماً على توزيع الأخطاء. حيث، نلاحظ أن قيمة RMSE (2,913.28) أعلى بشكل ملحوظ من قيمة MAE (1,933.52).

فإن الفرق الواضح بين RMSE و MAE (حوالي 980 دولار) هذا يؤكد أن نموذج GRU، شأنه شأن LSTM، يعاني من أخطاء تنبؤ كبيرة نسبياً في بعض النقاط الزمنية (القيم الشاذة)، مما يدل على حساسية النموذج للتقلبات الحادة في أسعار البيتكوين.

ظهرت نتائج الدراسة الحالية أن نموذج شبكة الذاكرة الطويلة والقصيرة المدى (LSTM) حقق قيمة أقل لمقاييس الخطأ الإحصائية مقارنة بنموذج وحدة البوابات المتكررة (GRU)، وتتفق هذه النتائج مع ما توصلت إليه دراسة روباة (2024) ودراسة (Ammer & Aldhyani (2022)، اللتين أظهرتا تفوق نموذج LSTM في التنبؤ بأسعار العملات المشفرة، مع انخفاض ملحوظ في قيم MAE و RMSE، مما يعكس قدرة هذا النموذج على تمثيل الاعتمادات الزمنية طويلة الأجل بكفاءة أعلى. في المقابل، تختلف نتائج الدراسة الحالية جزئياً مع نتائج دراسة Awoke et al. (2021)، التي أشارت إلى تفوق نموذج GRU في بعض تطبيقات التنبؤ بأسعار البيتكوين باستخدام بيانات يومية متعددة المتغيرات، حيث سجل النموذج أخطاء تنبؤية أقل وسرعة تدريب أعلى مقارنة بـ LSTM. كما أن الدراسات الهجينة مثل Tanwar et al. (2021) ركزت على دمج النموذجين دون المفاضلة الصريحة بينهما ضمن إطار زمني طويل الأجل.

ويمكن تفسير أوجه التشابه والاختلاف بين نتائج الدراسة الحالية ونتائج الدراسات السابقة بعدة عوامل منهجية وتقنية. فمن جهة، يُعزى تفوق نموذج LSTM في هذه الدراسة إلى قدرته العالية على الاحتفاظ بالمعلومات الزمنية طويلة الأجل من خلال حالة الخلية (Cell State)، وهو ما يتلاءم مع طبيعة البيانات الأسبوعية الممتدة لعشر سنوات، حيث تكون الاتجاهات طويلة الأمد أكثر أهمية من التقلبات قصيرة الأجل. ومن جهة أخرى، فإن تفوق نموذج GRU في بعض الدراسات السابقة، مثل Awoke et al. (2021)، يمكن إرجاعه إلى استخدام بيانات يومية عالية التردد ومتعددة المتغيرات، حيث يكون تقليل عدد المعاملات وسرعة التدريب عاملين مؤثرين في تحسين الأداء، مما يمنح (GRU) ميزة نسبية في هذا السياق. كما أن اختلاف الفترة الزمنية، وتواتر البيانات (يومي مقابل أسبوعي)، وطبيعة المتغيرات المدخلة، ونوع دالة الخسارة، وخوارزمية التحسين المستخدمة، كلها عوامل تؤثر بشكل مباشر في قيم مقاييس الخطأ (MAE، MSE، RMSE)، وتفسر التباين في نتائج الدراسات. وبناءً على ذلك، تؤكد نتائج الدراسة الحالية أن اختيار النموذج الأمثل لا يعتمد على هيكله فقط، بل على مدى توافقه مع خصائص البيانات الزمنية المستخدمة.

والجدول ادناه يوضح احتساب القيم التنبؤية المستقبلية لفترة 5 قيم مستقبلية باستخدام نموذج GRU المقدر كما موضح في الاتي:

جدول (9) القيم التنبؤية المستقبلية لبيانات سلسلة البيتكوين وفق نموذج GRU

التاريخ	القيم التنبؤية Prediction	Obs
2025/1/5	100278.8	1
2025/1/12	102671.3	2
2025/1/19	112020.8	3
2025/1/26	120382.6	4
2025/2/2	119951.8	5

الجدول من اعداد الباحث بالاعتماد على مخرجات برنامج R

تمثل القيم أعلاه ناتج عملية التنبؤ بسعر البيتكوين لخمس فترات زمنية مستقبلية باستخدام نموذج الشبكات العصبية العميقة من نوع GRU إذ يتبين وجود نمط تصاعدي في الأسعار خلال الفترات الثلاث الأولى، حيث يرتفع السعر من (100.278) إلى ما يزيد عن (120.000)، مما يعكس توقع النموذج لاستمرار الاتجاه الصاعد للسوق في الأجل القصير. بعد ذلك تبدأ القيم بالتباطؤ وتتنخفض القيمة التنبؤية في الفترة الخامسة مما يشير إلى بداية مرحلة استقرار سعري. يعكس هذا النمط السعري قدرة نموذج GRU على تحديد خصائص دورات السوق السابقة ومحاولة تعميمها على التنبؤات المستقبلية.

وعليه فإن التحقق من إمكانية التنبؤ بأسعار العملات المشفرة عينة الدراسة باستخدام نماذج التعلم العميق LSTM و GRU لذا نرفض فرضية الدراسة الأولى التي تنص على (عدم دقة نموذج Lstm ونموذج GRU في التنبؤ بأسعار العملات المشفرة المتمثلة بالبيتكوين)

4. مقارنة بين نموذج LSTM ونموذج GRU لأسعار البيتكوين ان الجدول التالي يبين خلاصة نتائج النموذجين والمقارنة بينهما استنادا الى القيم الحقيقية لاسعار البيتكوين:

جدول (10) القيم الحقيقية والقيم التنبؤية المستقبلية وحدود الثقة والاختفاء الناتجة

المقارنة Compare	GRU Error	LSTM Error	95% interval	std. error	نموذج GRU	نموذج LSTM	القيم الحقيقية TRUE	التاريخ Obs
LSTM	5666.8	3574.56	(93800.0, 103396.)	2448.1	100279	98186.6	94612	1/5/2025
LSTM	8135.2	884.46	(91410.8, 105883.)	3691.94	102671	95420.6	94536.1	1/12/2025
GRU	7277.9	10623.26	(89566.5, 107740.)	4636.15	112021	94119.6	104743	1/19/2025
LSTM	19734.6	8009.48	(88029.1, 109279.)	5420.96	120383	92638.5	100648	1/26/2025
LSTM	23503.9	5730.17	(86686.5, 110622.)	6106.03	119952	90717.7	96447.9	2/2/2025

الجدول من اعداد الباحث بالاعتماد على مخرجات برنامج R

يبين الجدول أعلاه مقارنة القيم الحقيقية (TRUE) مع القيم المتنبئ بها باستخدام نمودي LSTM و GRU لمدة خمسة أسابيع مستقبلية، باستخدام مؤشر الخطأ المطلق (Error)، كذلك تم حساب فترة الثقة 95% وقد تم اختيار النموذج الأفضل في كل أسبوع استنادا الى أقل خطأ مطلق ولخصت نتيجة المقارنة في العمود الأخير compare. ان نتيجة المقارنة تشير الى ان نموذج LSTM كانت له الأفضلية في 4 من أصل 5 أسابيع وهي الأسابيع 1 و 2 و 4 و 5، وان أداء هذا النموذج كان أكثر استقرارا. بينما كانت الأفضلية لنموذج GRU في أسبوع واحد فقط هو 3. وفيما يتعلق بالخطأ المعياري (std. error) فقد لاحظ انه يرتفع تدريجياً وهو ما يشير الى التراجع في دقة التقديرات وهو امر طبيعي ومنطقي حيث انه من المعروف ان التنبؤات تقل دقتها كلما ابتعدت الفترة الزمنية للتنبؤ.

نستنتج مما سبق انه بالرغم من ان GRU قد أعطت دقة أعلى في بعض المواضع الا ان نموذج LSTM كان اكثر تفوقا واستقرارا وموثوقية إجمالاً فيما يخص هذه العينة من الدراسة. اذ انه نموذج LSTM يقدم دقة تنبؤية أعلى عند التعامل مع سلاسل زمنية طويلة الأمد، مقابل تكلفة حسابية أعلى. في حين أن نموذج GRU قد يكون خياراً أكثر كفاءة في البيانات التي تتطلب سرعة تدريب أعلى أو موارد حسابية محدودة، مع أداء تنبؤي قريب نسبياً. وبناءً على ذلك، لا يُنظر إلى تفوق LSTM بوصفه تفوقاً مطلقاً، وإنما تفوقاً مرتبطاً بسياق البيانات وأفق التنبؤ.

لذا نرفض فرضية الدراسة الثانية التي تنص على (لا يوجد تفوق في الاداء لأحد النماذجين (GRU او Lstm) في التنبؤ بأسعار العملات المشفرة)

6. الاستنتاجات والتوصيات Conclusions and recommendations

6.1. الاستنتاجات Conclusions

1. يتميز سعر البيتكوين بتقلبات مرتفعة حادة، وانحراف عالي وتوزيع غير طبيعي، ما يجعله أصلاً عالي المخاطرة وغير مناسب للنماذج التقليدية إضافة الى وجود قيم شاذة ومتطرفة في قيمته، وعلى الرغم من وجود فرصة لتحقيق أرباح عالية، إلا أن مستوى المخاطرة مرتفع، إضافة الى ان التنبؤ بحركته المستقبلية يكون صعباً دون استخدام تقنيات متقدمة تأخذ بنظر الاعتبار الطبيعة غير الخطية وغير الطبيعية للتوزيع.
2. على الرغم من كون البيتكوين أصلاً مالياً رقمياً حديث النشأة إلا انه يعكس بعض الخصائص السلوكية المركبة التي تتداخل معها ديناميكيات نفسية للمستثمرين إضافة الى متغيرات اقتصادية عالمية وبالتالي فان هذا التداخل يجعل منه حالة دراسية مميزة ضمن الاقتصاد والتمويل الحديث.
3. قَدِّم نموذج شبكة LSTM تنبؤات قريبة من القيم الفعلية لأسعار البيتكوين، وهو ما يعكس قدرة هذا النموذج على التقاط الأنماط الزمنية الكامنة في البيانات بشكل فعال. كما بين أن القيم التنبؤية تتناقص تدريجياً، مما يشير إلى أن النموذج يتوقع اتجاهًا تنازلياً في سعر البيتكوين خلال الفترات الخمس المقبلة مما قد يعكس أنماطاً في البيانات مثل نهاية دورة ارتفاع أو بداية تعديل للأسعار.
4. تكمن أهمية معمارية شبكة GRU في قدرتها على الاحتفاظ بالمعلومات المهمة عبر الزمن من خلال بوابة التحديث ثم تصفية المعلومات غير المفيدة من خلال بوابة إعادة الضبط، وبالتالي اعطاء تمثيل مخفي فعال يخدم أغراض التنبؤ الدقيقة. وكذلك وجود قدرة لنموذج GRU في تحديد الأنماط والتقلبات في السلسلة الأصلية وتحديد خصائص دورات السوق السابقة ومحاولة تعميمها على التنبؤات المستقبلية.
5. أن نموذج LSTM يتفوق على GRU في التنبؤ بأسعار البيتكوين في هذا البحث، وقد يعود هذه الأفضلية إلى قدرة LSTM الأعلى على التعامل مع العلاقات الزمنية الطويلة داخل بيانات السلاسل الزمنية، خاصة في حالة وجود تقلبات سعرية شديدة.

6.2. التوصيات recommendations

1. نظراً لطبيعة البيتكوين غير الخطية وتوزيعه غير الطبيعي، يوصى بالبحث في نماذج هجينة تدمج الشبكات العصبية المتكررة المتقدمة (مثل LSTM و GRU) مع تقنيات أخرى أو أساليب إحصائية أو اقتصادية أخرى لإنتاج نماذج هجينة أكثر قدرة على التعامل مع القيم الشاذة وتقديم تنبؤات أكثر دقة.
2. يوصي البحث بدمج متغيرات اقتصادية عالمية مثل أسعار الفائدة، التضخم، مؤشرات السيولة، وحجم التداول العالمي، أو متغيرات نفسية وسلوكية للمستثمرين، لفهم التأثيرات الحقيقية على كل من أسعار البيتكوين، وربط التنبؤات بسياق اقتصادي أوسع.
3. يُنصح بتوسيع أفق التنبؤ المستقبلي لأسعار البيتكوين على فترات زمنية أطول وتقسيمها إلى فترات ذات خصائص سوقية مختلفة (صعود، هبوط، استقرار)، كما يُوصى بمقارنة أداء شبكتي LSTM و GRU مع معماريات أخرى متخصصة في السلاسل الزمنية.
4. إجراء دراسات مقارنة أكثر شمولية بين فئات الأصول (عملات رقمية، عملات أجنبية، أسهم، سلع) باستخدام نفس الإطار النموذجي (LSTM)، (GRU) لتوسيع القدرة على تعميم النتائج ولتعزيز فهم العلاقات الديناميكية بين الأسواق المالية الحديثة والتقليدية وتحديد النماذج الأمثل لكل منها.
5. نظراً لتفوق شبكة LSTM على GRU في التنبؤ بكلما بأسعار البيتكوين، يوصى باعتماد LSTM كنموذج أساسي (Baseline Model) في التنبؤ في الدراسات المستقبلية التي تتناول سلاسل زمنية مالية تتميز بتقلبات عالية وتعتمد على الذاكرة طويلة الأمد، مع إمكانية تعديل بنية نموذج البوابات (Gates) لتحسين الأداء.

شكر وتقدير: يتقدم المؤلفون بالشكر والعرفان لكل من ساعدهم في انجاز هذا البحث من توفير بيانات.

التمويل لم تقوم اية جهة بتقديم تمويل لدعم هذا البحث.

مساهمة المؤلف: ساهمت الباحثة زهراء كاظم مجيد في انجاز الجانب النظري والعملي وتحليل البيانات، ساهم الدكتور حيدر عباس عبد الله في توفير البيانات واجراء التعديلات على الجانب النظري والعملي، وساهم الدكتور امير علي خليل في اجراء التعديلات على المنهجية والجانب النظري ومراجعة الجانب العملي .

الذكاء الاصطناعي التوليدي والتقنيات المدعومة بالذكاء الاصطناعي في عملية الكتابة: تم الاعتماد جزء بسيط على برامج الذكاء الصناعي في انجاز البحث.

تضارب المصالح: يقر المؤلفون بعدم وجود تضارب مصالح يتعلق بالمضمون أو التأليف أو نشر هذا البحث.

نبذة قصيرة عن كل مؤلف

المؤلف الأول: الباحثة زهراء كاظم مجيد في مرحلة كتابة اطروحة الدكتوراه

المؤلف الثاني: الاستاذ المساعد الدكتور حيدر عباس عبد الله حاصل على شهادة الدكتوراه في مجال العلوم المالية والمصرفية ولديها أبحاث كثيرة في مجال الأسواق المالية

المؤلف الثالث: الاستاذ الدكتور امير علي خليل حاصل على شهادة الدكتوراه في مجال العلوم المالية والمصرفية ولديه ابحاث كثيرة في مجال المصارف.

المصادرReferences

1. روابية محمد. (2024). استخدام الشبكة الذاكرة طويلة قصيرة المدى للتنبؤ بأسعار عملة البيتكوين. مجلة المنهل الاقتصادي, 7, 113-122. <https://www.asjp.cerist.dz/en/PresentationRevue/479>

References

- Ahamad, S., Nair, M., & Varghese, B. (2013). A Survey on Crypto Currencies, In 4th International Conference on Advances in Computer Science , *AETACS*, 42–48.
- Alsalmi, N., Ullah, S., & Rafique, M. (2023). Accounting for digital currencies. *Research in International Business and Finance*, 64, 101897.
- Ammer, M. A., & Aldhyani, T. H. H. (2022). Deep Learning Algorithm to Predict Cryptocurrency Fluctuation Prices: Increasing Investment Awareness. *Electronics*, 11(15), 2349.
- Awoke, T., Rout, M., Mohanty, L., & Satapathy, S. C. (2021). *Bitcoin Price Prediction and Analysis Using Deep Learning Models* (pp. 631–640).
- Barrutia, I., Urquizo Maggia, J. A., & Acevedo, S. I. (2019). Criptomonedas y blockchain en el turismo como estrategia para reducir la pobreza. *Retos*, 9(18), 287–302.
- Bos, A. R. (2018). *ryptocurrencies and Regulation, a Master Thesis on the best practices for regulating cryptocurrencies within the EU*. University of Leiden.
- Chaum, D. (1983). Blind Signatures for Untraceable Payments. In *Advances in Cryptology* (pp. 199–203). Springer US.
- Chohan, U. (2017). Cryptocurrencies: A Brief Thematic Review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3024330>
- Faez Hasan, M. (2023). Beyond Bitcoin: A Review Study on the Diverse Future of Cryptocurrency. *IRE Journals*, 7(3), 64–69.
- Faria, D. L. (2020). *Revisiting the Impact of Cryptocurrency in Our Society, Master's thesis*. ISCTE-Instituto Universitario de Lisboa.
- Härdle, W. K., Harvey, C. R., & Reule, R. C. G. (2020). Understanding Cryptocurrencies*. *Journal of Financial Econometrics*, 18(2), 181–208.
- He, Y., Huang, P., Hong, W., Luo, Q., Li, L., & Tsui, K.-L. (2024). In-Depth Insights into the Application of Recurrent Neural Networks (RNNs) in Traffic Prediction: A Comprehensive Review. *Algorithms*, 17(9), 398.
- Hillman, H. D. (2020). *Money Laundering through Cryptocurrencies: Analysing the Responses of the United States and Australia and Providing Recommendations for the UK to Address the Money Laundering Risks Posed by Cryptocurrencies* ,. University of the West of England.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695.

16. Kingma, D. P. (2015). Adam: A method for stochastic optimization. *As a Conference Paper at ICLR International Conference on Learning Representations (ICLR)*. ArXiv Preprint ArXiv:1412.6980, 1412(6).
17. Leong, L. A. (2023). *Forecasting SOXX with Long Short-Term Memory (LSTM) Neural Networks Based on Varying Sampling Periods*. Dissertation, Selinus University.
18. Malladi, R. K. (2023). Pro forma modeling of cryptocurrency returns, volatilities, linkages and portfolio characteristics. *China Accounting and Finance Review*, 25(2), 145–183.
19. Mendes, J. F. B. (2019). *FORECASTING BITCOIN PRICES ARIMA vs LSTM* [Master's thesis]. ISCTE-Instituto Universitario de Lisboa.
20. Mijwil, M. M. , A. K. , S. S. , A.-M. A. H. , A. S. , G. M. , . . . & A. S. H. (2022). Has the Future Started? The Current Growth of Artificial Intelligence, Machine Learning, and Deep Learning. *Iraqi Journal for Computer Science and Mathematics*3(1), 13., 115–123.
21. Nosouhian, S., Nosouhian, F., & Kazemi Khoshouei, A. (2021). *A Review of Recurrent Neural Network Architecture for Sequence Learning: Comparison between LSTM and GRU*.
22. Peters, G. W., Panayi, E., & Chapelle, A. (2015). Trends in Crypto-Currencies and Blockchain Technologies: A Monetary Theory and Regulation Perspective. *SSRN Electronic Journal*, 3(3), 1–25.
23. Rahardja, U. (2023). The Economic Impact of Cryptocurrencies in Indonesia. *ADI Journal on Recent Innovation (AJRI)*, 4(2), 194–200.
24. Revuelta, V. (2018). *Design and implementation of a software system for the composition of a database and automated trading system on different cryptocurrency trading markets* [Master's thesis]. Universitat Politècnica de Catalunya.
25. Rice, M. (2019). *Cryptocurrency: History, advantages, disadvantages, and the future* [Master's Thesis]. Liberty University.
26. Sanz Bas, D. (2020). Hayek and the cryptocurrency revolution. *Iberian Journal of the History of Economic Thought*, 7(1), 15–28. <https://doi.org/10.5209/ijhe.69403>
27. Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160.
28. Shahinzadeh, H., Mahmoudi, A., Asilian, A., Sadrarhami, H., Hemmati, M., & Saberi, Y. (2024). Deep Learning: A Overview of Theory and Architectures. 2024 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP), 1–11.
29. Sharma, N., Sharma, R., & Jindal, N. (2021). Machine Learning and Deep Learning Applications-A Vision. *Global Transitions Proceedings*, 2(1), 24–28.
30. Tanwar, S., Patel, N. P., Patel, S. N., Patel, J. R., Sharma, G., & Davidson, I. E. (2021). Deep Learning-Based Cryptocurrency Price Prediction Scheme With Inter-Dependent Relations. *IEEE Access*, 9, 138633–138646.
31. Wang, P., Fan, E., & Wang, P. (2021). Comparative analysis of image classification algorithms based on traditional machine learning and deep learning. *Pattern Recognition Letters*, 141, 61–67.

32. Wolfson, S. N. (2015). Bitcoin: The Early Market. *Journal of Business & Economics Research (JBER)*, 13(4), 201.
33. Wu, J. Zhang, X. Huang, F. , Zhou, H. , & Chandra, R. (2024). *Review of deep learning models for crypto price prediction: implementation and evaluation*. 1–29.
34. Xiong, R. (2020). *Battery Management Algorithm for Electric Vehicles*. Springer Singapore.
35. Zhang, L., Wang, S., & Liu, B. (2018). Deep learning for sentiment analysis: A survey. *WIREs Data Mining and Knowledge Discovery*, 8(4).
36. Zou, W., Lo, D., Kochhar, P. S., Le, X.-B. D., Xia, X., Feng, Y., Chen, Z., & Xu, B. (2021). Smart Contract Development: Challenges and Opportunities. *IEEE Transactions on Software Engineering*, 47(10), 2084–2106.