

DỰ BÁO GIÁ BITCOIN BẰNG CÁC MÔ HÌNH HỌC MÁY

TS. Vũ Thị Huyền Trang* - Đặng Hải Yến* - Trần Thị Vân - Phạm Thị Hải Yến* - Nguyễn Kim Anh*

Trong kỷ nguyên Công nghiệp 4.0, Bitcoin đã vươn lên trở thành biểu tượng của công nghệ Blockchain, mở ra một thị trường tài chính đầy hứa hẹn nhưng cũng tiềm ẩn nhiều biến động. Việc dự báo giá Bitcoin đóng vai trò quan trọng trong chiến lược đầu tư kinh tế. Nghiên cứu này sử dụng dữ liệu giá đóng cửa của Bitcoin từ ngày 07/10/2021 đến 08/02/2025 và của các mô hình học máy tiên tiến (RNN, LSTM, GRU, LSTM-GRU, GRU-LSTM) để dự báo giá Bitcoin và so sánh, đánh giá hiệu suất của các mô hình sử dụng. Kết quả cho thấy, GRU là mô hình tối ưu nhất để dự báo giá Bitcoin.

• Từ khóa: giá Bitcoin, dự báo, học máy, LSTM, GRU, RNN.

In the era of Industry 4.0, Bitcoin has emerged as a symbol of Blockchain technology, opening up a promising but potentially volatile financial market. Bitcoin price forecasting plays an important role in economic investment strategies. This study uses Bitcoin closing price data from October 7, 2021 to February 8, 2025 and advanced machine learning models (RNN, LSTM, GRU, LSTM-GRU, GRU-LSTM) to forecast Bitcoin prices and compare and evaluate the performance of the models used. The results show that GRU is the most optimal model for forecasting Bitcoin prices.

• Key words: bitcoin price, forecasting, machine learning, LSTM, GRU, RNN.

Ngày gửi bài: 19/3/2025

Ngày gửi phản biện: 12/4/2025

Ngày nhận kết quả và sửa phản biện: 20/7/2025

Ngày chấp nhận đăng: 25/8/2025

DOI: <https://doi.org/10.71374/jfar.v25.i296.03>

1. Giới thiệu

Cuộc cách mạng công nghiệp 4.0 đã thúc đẩy sự phát triển của công nghệ số hóa, đặc biệt là Blockchain - nền tảng cốt lõi của Bitcoin. Trước bối cảnh thị trường giá Bitcoin biến động không ngừng, các mô hình dự báo đã trở thành công cụ đắc lực, không chỉ mang lại lợi ích kinh tế mà còn góp phần ổn định thị trường. Trong lĩnh vực nghiên cứu, dự đoán giá Bitcoin thông qua các thuật toán trí tuệ nhân tạo AI và sức mạnh tính toán vượt trội của máy tính đã trở thành một hướng đi nổi bật. Với sự phát triển vượt bậc của phần cứng trong thế kỷ 21, công nghệ học máy đã khẳng định vị thế là công cụ dự báo giá Bitcoin ưu việt, nhờ khả năng xử lý lượng dữ liệu khổng lồ, kết hợp linh hoạt nhiều phương pháp dự báo và thích ứng nhanh

chóng với biến động thị trường. Tuy nhiên, bên cạnh những ưu điểm vượt trội, các mô hình này cũng đối mặt với những thách thức như yêu cầu dữ liệu đầu vào chất lượng cao, nguy cơ overfitting và sự phụ thuộc vào các yếu tố thị trường khó lường.

Nghiên cứu này tập trung vào việc áp dụng và đánh giá hiệu suất của các mô hình học máy, bao gồm Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM) và các mô hình lai LSTM-GRU, GRU-LSTM trong dự báo giá Bitcoin. Kết quả không chỉ đóng góp cho lĩnh vực dự báo tài chính mà còn cung cấp những gợi ý quan trọng trong quản lý rủi ro và hoạch định chiến lược đầu tư, hỗ trợ nhà đầu tư và các bên liên quan đưa ra quyết định hiệu quả trên thị trường tiền mã hóa đầy biến động.

2. Cơ sở lý thuyết và tổng quan nghiên cứu

2.1. Cơ sở lý thuyết

Tiền mã hóa (cryptocurrency) là một loại tiền kỹ thuật số sử dụng cơ chế mã hóa để đảm bảo tính an toàn và xác thực cho các giao dịch. Không giống như tiền tệ truyền thống, tiền mã hóa không được phát hành bởi bất kỳ chính phủ nào mà được tạo ra và quản lý bởi hệ thống máy tính phi tập trung với các thuật toán tự động. Tiền mã hóa hoạt động trên nền tảng công nghệ chuỗi khối (blockchain), nơi tất cả các giao dịch được ghi lại công khai trong một sổ cái phân tán. Đồng tiền này ngoài tính năng thanh toán còn mang tính đầu tư và hiện nay không chịu sự kiểm soát của bất kỳ ngân hàng trung ương nào cũng như không có sự đảm bảo phát hành. Theo Nakamoto (2008), tiền mã hóa có rất nhiều ưu điểm vượt trội: tính an toàn, tính ẩn danh, tính tiết kiệm, tính nhanh chóng, tính năng chống lạm phát tự động. Một trong những loại hình tiền mã hóa thành công nhất

* Trường Đại học Thương mại; email: trang.vth@tmu.edu.vn

và được chấp nhận thanh toán nhiều nhất hiện nay là Bitcoin. Mặc dù còn tồn tại nhiều khuyết điểm khi triển khai trong thực tế nhưng Bitcoin đã gây ra cơn địa chấn toàn cầu và làm đẩy lên một cuộc cách mạng trong thị trường tiền tệ.

2.2. Tổng quan nghiên cứu

Có nhiều phương pháp đã được phát triển để dự báo giá Bitcoin, tuy nhiên bên cạnh những ưu điểm thì vẫn còn tồn tại nhiều hạn chế, không phải lúc nào cũng phù hợp với mọi loại dữ liệu và điều kiện thị trường. Các nghiên cứu dự báo giá Bitcoin hiện nay chủ yếu tập trung so sánh hiệu suất dự đoán giá Bitcoin giữa các mô hình; tỷ suất lợi nhuận và xu hướng giá của Bitcoin và phát triển một số mô hình học máy để dự đoán tỷ giá loại tiền mã hóa này.

Đầu tiên, nghiên cứu về RNN cho thấy mô hình này có khả năng học từ các mối quan hệ trong chuỗi dữ liệu, hữu ích trong dự báo chuỗi thời gian. Pant và cộng sự (2018) sử dụng phân tích cảm xúc từ 4254 tweet cùng dữ liệu giá trên CoinMarketCap để dự đoán giá Bitcoin. Kết quả cho thấy, mô hình RNN đạt độ chính xác 77,62% trong dự đoán giá Bitcoin và có mối tương quan 0,41 giữa số lượng ý kiến tiêu cực và giá Bitcoin.

So sánh giữa RNN và LSTM, Gunarto và cộng sự (2023) đã xây dựng và so sánh hiệu quả của hai mô hình học máy này trong việc dự báo giá Bitcoin và Ethereum, với dữ liệu từ năm 2015 đến năm 2021. Kết quả chỉ ra rằng mô hình LSTM vượt trội hơn so với mô hình RNN trong việc dự đoán giá Bitcoin và Ethereum, với giá trị RMSE thấp nhất là 0,061 và MAPE là 5,66% cho Bitcoin, cùng với RMSE là 0,036 và MAPE là 4,58% cho Ethereum. Trong khi đó, RNN có RMSE là 0,102 và MAPE là 8,82% cho Bitcoin, cũng như RMSE là 0,062 và MAPE là 6,51% cho Ethereum. Nghiên cứu cũng chỉ ra rằng các siêu tham số của mô hình có ảnh hưởng lớn đến kết quả dự đoán.

Chen (2023) so sánh hồi quy Random Forest (RF) với LSTM, sử dụng 47 biến giải thích thuộc 8 danh mục, từ giá Bitcoin, các chỉ số thị trường đến sự chú ý của công chúng. Kết quả nghiên cứu cho thấy hồi quy rừng ngẫu nhiên có độ chính xác dự đoán giá tốt hơn LSTM khi giá Bitcoin tương đối ổn định, nhưng không thể dự đoán các kết quả ngoài các mẫu đào tạo. Kết quả cũng cho thấy khi tăng số kỳ quá khứ của biến giải thích, độ chính xác của cả RF và LSTM đều giảm. Kết luận này gần với giả thuyết thị trường hiệu quả cổ điển.

Trong nghiên cứu của Shiri và cộng sự (2023) cho thấy GRU đạt độ chính xác cao trong các nhiệm vụ phân loại. Trên bộ dữ liệu IMDB, GRU đạt được độ chính xác 87,55% và trên bộ dữ liệu ARAS, nó đạt độ chính xác 93,65%. Đồng thời, GRU cũng yêu cầu ít thời gian huấn luyện hơn so với một số mô hình khác, điều này cho thấy rằng nó là một công cụ hữu ích trong việc xử lý dữ liệu chuỗi.

Bên cạnh đó, có rất nhiều nghiên cứu cho kết quả LSTM là tối ưu nhất. Trong nghiên cứu của Chen và cộng sự (2021), LSTM cũng cho thấy khả năng dự báo tốt hơn các mô hình ARIMA và SVR khi sử dụng dữ liệu kinh tế và công nghệ trong một mô hình hai giai đoạn. Tương tự, nghiên cứu của Phaladisailoed và Numnonda (2018) cũng cho thấy LSTM có độ chính xác cao nhất (52,78%) khi so sánh với hồi quy Theil-Sen, hồi quy Huber và GRU. Không chỉ vậy, LSTM còn được công nhận là một mô hình hiệu quả trong các bài toán dự báo mục tiêu nhiều lần (Shin và cộng sự, 2021; Jagannath và cộng sự, 2021; Rizwan và cộng sự, 2019), cho thấy tính linh hoạt của mô hình.

Tóm lại, LSTM thường được coi là một lựa chọn hàng đầu nhờ khả năng xử lý dữ liệu thời gian và độ chính xác cao trong các dự báo; cùng với đó, hồi quy RF, CNN, RNN hay GRU cũng cho thấy tiềm năng lớn trong việc dự báo giá Bitcoin. Tuy nhiên, hiệu suất của các mô hình cũng phụ thuộc vào các yếu tố như dữ liệu đầu vào, biến giải thích, và thiết lập tham số. Việc mở rộng nghiên cứu bao gồm các giai đoạn thị trường khác nhau có thể cung cấp cái nhìn sâu sắc hơn về khả năng dự đoán của các mô hình học máy.

3. Phương pháp nghiên cứu

3.1. Dữ liệu nghiên cứu

Nghiên cứu sử dụng dữ liệu giá đóng cửa hàng ngày của Bitcoin từ ngày 07 tháng 10 năm 2021 đến ngày 08 tháng 02 năm 2025, được thu thập từ yahoo finance.

3.2. Mô hình nghiên cứu

a. Mô hình Recurrent Neural Network - RNN

Mạng nơ-ron hồi quy (RNN) là một loại mạng nơ-ron nhân tạo chuyên xử lý dữ liệu tuần tự bằng cách duy trì trạng thái nội bộ qua các bước thời gian.


RNN gồm các lớp hồi quy, mỗi tế bào kết hợp đầu vào hiện tại với trạng thái trước để tạo đầu ra mới, giúp mạng học được các phụ thuộc theo thời

gian của dữ liệu. Ô nhớ lưu trữ thông tin các bước trước, hỗ trợ nhận diện xu hướng và mối quan hệ trong chuỗi dữ liệu (Zahid và cộng sự, 2022).

$$a(t) = \tanh(W_{ax}x(t) + W_{aa}a(t-1) + b_a)$$

$$\hat{y}(t) = \text{softmax}(W_{ya}a(t) + b_y)$$

Hình 1. Cấu trúc mạng RNN




Nguồn: Gholipour (2023)

Hạn chế của RNN là hiện tượng độ dốc biến mất khi lan truyền ngược, khiến mô hình khó học các mối quan hệ xa và ghi nhớ thông tin dài hạn, từ đó ảnh hưởng đến độ chính xác. Các biến thể như LSTM, GRU được phát triển để khắc phục hạn chế này, giúp nhằm cải thiện khả năng lưu trữ hiệu suất dự báo.

b. Mô hình Long Short-Term Memory - LSTM

LSTM được phát triển bởi Hochreiter và Schmidhuber (1997), là một biến thể mạnh mẽ của RNN nhằm khắc phục các vấn đề về độ dốc biến mất và độ dốc bùng nổ (Gholipour, 2023). Khác với RNN, LSTM chứa cấu trúc phức tạp hơn: ô nhớ (C_t), cổng quên (f_t), cổng đầu vào (i_t), cổng đầu ra (o_t); kết hợp với các sigmoid và tanh.

Hình 2. Cấu trúc của một đơn vị LSTM



Nguồn: Hu và cộng sự (2020)

Hoạt động của ô LSTM như sau:

+ Cổng quên: Loại bỏ thông tin không cần thiết:

$$f_t = \sigma(W_c[h_{t-1}, x_t] + b_c)$$

Trong đó:

W_c là ma trận trọng số của cổng quên;

b_c là độ lệch của cổng quên;

σ là hàm sigmoid, đảm bảo giá trị của f_t nằm trong khoảng (0,1), tức là chỉ giữ lại một phần thông tin từ trạng thái ô trước đó C_{t-1} .

+ Cổng đầu vào: Kiểm soát thông tin mới được thêm vào, đóng vai trò là đầu vào cho trạng thái hiện tại của mạng. Gồm hai bước như sau:

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

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

Sau đó, hai vector này được kết hợp để cập nhật ô nhớ:

$$C_t = (f_t * C_{t-1}) + (i_t * \tilde{C}_t)$$

+ Cổng đầu ra: Xác định trạng thái ẩn tiếp theo - đầu ra của ô LSTM:

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

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

Đầu ra có thể được coi là giá trị dự báo được mô hình tính toán cho trạng thái hiện tại (Zahid và cộng sự, 2022).

c. Mô hình Gated Recurrent Unit - GRU

GRU là một biến thể đơn giản hóa của RNN, giúp khắc phục vấn đề bộ nhớ ngắn hạn. GRU đơn giản hơn LSTM nhờ kết hợp cổng đầu vào và cổng quên thành cổng cập nhật duy nhất, không sử dụng trạng thái ô riêng biệt.

Một đơn vị GRU bao gồm ba thành phần chính. Cụ thể như sau:

+ Cổng cập nhật: Quyết định mức độ giữ lại thông tin quá khứ:

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z)$$

Trong đó:

W_z là ma trận trọng số;

b_z là vector độ lệch (bias);

σ là hàm sigmoid.

+ Cổng đặt lại: Quyết định lượng thông tin quá khứ cần được quên đi:

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r)$$

+ Nội dung bộ nhớ hiện tại: Đây là một trạng thái ẩn tạm thời:

$$\tilde{h}_t = \tanh(W_h[r_t h_{t-1}, x_t])$$


Cuối cùng, trạng thái bộ nhớ cuối cùng được xác định:

$$h_t = (1 - z_t)h_{t-1} + z_t\tilde{h}_t$$

$$o_t = \sigma(W_o[h_t] + b_o)$$

Trong đó ma trận trọng số lớp đầu ra là và vector lệch lớp đầu ra là.

Hình 3. Cấu trúc của một đơn vị GRU



Nguồn: Shiri và cộng sự (2023)

4. Kết quả nghiên cứu và thảo luận

4.1. Tiền xử lý dữ liệu

Để đảm bảo độ chính xác của mô hình dự đoán giá Bitcoin và tránh sai lệch, nhóm nghiên cứu đã tiến hành chuẩn hóa dữ liệu bằng phương pháp MinMax Scaling. Việc này giúp xử lý các biến có thang đo khác nhau một cách đồng đều.

Dữ liệu được chia thành hai phần: tập huấn luyện (80%) từ 07/10/2021 đến 13/05/2024 (950 quan sát) và tập kiểm tra (20%) từ 14/05/2024 đến 08/02/2025 (271 quan sát).

Để xây dựng và thực nghiệm được mô hình, nhóm các tác giả đã sử dụng Python 3.13.1 trên môi trường Google Colab và một số thư viện cốt lõi.

4.2. Xây dựng và huấn luyện mô hình

Sau khi hoàn thành xử lý dữ liệu, nhóm tác giả sẽ dùng các lớp Dense, Dropout, RNN, GRU, LSTM từ thư viện keras.layers và Sequential từ thư viện keras.layers để xây dựng và tinh chỉnh mô hình mạng nơ-ron. Chuỗi dữ liệu được xử lý chia làm đầu vào và dự báo xu hướng.

Với các mô hình đơn gồm RNN, GRU, LSTM có cấu trúc gồm 2 lớp tương ứng. Mỗi lớp có 50 neurons và nhận đầu vào là chuỗi thời gian với một đặc trưng. Lớp đầu tiên sử dụng `return_sequences=True` để trả về chuỗi trạng thái ẩn, giúp lớp tiếp theo tiếp tục học. Lớp thứ hai chỉ trả về giá trị cuối cùng. Lớp Dropout (0,5) được thêm vào để loại bỏ ngẫu nhiên 50% neurons, giảm overfitting và cải thiện khả năng tổng quát. Cuối cùng, lớp Dense với một neuron làm đầu ra, phù hợp cho bài toán hồi quy dự đoán một giá trị duy nhất.

Các mô hình lai bao gồm LSTM-GRU và GRU-LSTM được xây dựng với hai lớp LSTM (64 và 32 neurons) kết hợp hai lớp GRU (64 và 32 neurons), tạo nên mô hình dự báo phù hợp. Lớp Dropout (0,5) được thêm vào để giảm overfitting, giúp mô hình tổng quát hóa tốt hơn.

Trong quá trình biên dịch mô hình, thuật toán Adam được lựa chọn do khả năng tự động điều

chỉnh tỷ lệ học, giúp tăng tốc độ huấn luyện và giảm thiểu rủi ro rơi vào điểm tối ưu cục bộ. Hàm mất mát MAE được sử dụng để đo lường độ lệch giữa giá trị dự đoán và thực tế. Mô hình được lưu lại thông qua ModelCheckpoint khi có sự cải thiện về hiệu suất. Các mô hình đơn hội tụ sau 100 lần lặp, trong khi các mô hình phức hợp hội tụ nhanh hơn, sau 80 lần lặp, với kích thước lô `batch_size=32`. Kết quả hàm tổn thất giảm nhanh chóng sau tiền xử lý dữ liệu, chứng minh tính hợp lý của dữ liệu huấn luyện.

4.3. Kết quả dự báo

Bảng 1. Đo lường độ chính xác trên tập huấn luyện

Thông số	RNN	GRU	LSTM	LSTM-GRU	GRU-LSTM
score	0,99321	0,99221	0,99299	0,99015	0,99117
MSE	1276244,19	1464136,80	1319018,31	1852433,53	1660521,85
RMSE	1129,70978	1210,01521	1148,48522	1361,04134	1288,61238
MAE	721,32787	824,26917	773,89128	1049,75922	965,55714
MAPE	0,02093	0,02358	0,02297	0,03449	0,03062

Nguồn: Tính toán của các tác giả trên Google Colab

Kết quả đo lường ở Bảng 1 cho thấy các mô hình RNN, GRU, LSTM, LSTM-GRU và GRU-LSTM đều có độ phù hợp trên 99%, chứng tỏ mô hình hoạt động tốt. Trong số đó, RNN có hiệu suất tốt nhất với R^2 score cao nhất và các chỉ số sai số (MSE, RMSE, MAE, MAPE) thấp nhất. Ngược lại, LSTM-GRU có hiệu suất yếu nhất với các chỉ số sai số cao nhất. LSTM cũng cho kết quả tốt, đặc biệt trong việc giảm MAE và MAPE, nhưng vẫn kém hơn RNN. GRU có độ phù hợp cao nhưng chỉ số sai số chênh lệch so với LSTM và RNN. Các mô hình lai như LSTM-GRU và GRU-LSTM không mang lại cải thiện rõ rệt so với mô hình đơn.

Bảng 2. Đo lường độ chính xác trên tập giám sát

Thông số	RNN	GRU	LSTM	LSTM-GRU	GRU-LSTM
score	0,99321	0,99221	0,99299	0,99015	0,99117
MSE	1276244,2	1464136,80	1319018,31	1852433,53	1660521,85
RMSE	1129,7098	1210,01521	1148,48522	1361,04134	1288,61238
MAE	721,32787	824,26917	773,89128	1049,75922	965,55714
MAPE	0,02093	0,02358	0,02297	0,03449	0,03062


Nguồn: Tính toán của các tác giả trên Google Colab

Từ Bảng 2 cho thấy GRU có hiệu suất tốt nhất trên tập giám sát với R^2 score cao và sai số thấp nhất, tiếp theo là LSTM-GRU. Các mô hình khác lần lượt là RNN, GRU-LSTM và LSTM, trong đó LSTM có hiệu suất kém nhất. RNN và LSTM gặp hiện tượng overfitting, dẫn đến chênh lệch giữa kết quả huấn luyện và giám sát. LSTM-GRU dù không đạt hiệu suất cao nhất nhưng có độ ổn định tốt, cho thấy khả năng tổng quát hóa cao hơn so với các mô hình khác.

Kết quả dự báo trong Hình 4 bám sát xu hướng dữ liệu thực tế, cho thấy mô hình có khả năng tổng quát tốt. Khi so sánh dữ liệu huấn luyện và giám sát, có sự tương đồng rõ rệt giữa dự báo và thực tế, nhưng cũng xuất hiện hiện tượng overfitting ở RNN, LSTM, GRU-LSTM. Điều này thể hiện rõ khi mô hình cho kết quả tốt trên tập huấn luyện nhưng kém chính xác trên tập giám sát.

Như vậy, có thể thấy sự khác biệt đáng kể giữa hiệu suất của các mô hình trên tập huấn luyện và tập giám sát. Trong khi RNN cho kết quả tốt nhất trên tập huấn luyện, thì GRU lại thể hiện hiệu suất vượt trội trên tập giám sát với R^2 score cao nhất và các chỉ số sai số thấp nhất. Bên cạnh đó, các mô hình kết hợp như LSTM-GRU và GRU-LSTM chưa mang lại sự cải thiện rõ rệt. Sự chênh lệch giữa tập huấn luyện và tập giám sát phản ánh hiện tượng overfitting ở một số mô hình, đặc biệt là LSTM. Do đó, GRU được xác định là mô hình tối ưu nhất, đảm bảo tính tổng quát và hiệu quả khi áp dụng vào thực tiễn.

Hình 4. Đồ thị so sánh giữa giá Bitcoin dự báo và thực tế của các mô hình



Nguồn: Tính toán của các tác giả trên Google Colab

5. Kết luận và khuyến nghị

Nghiên cứu áp dụng các mô hình học máy RNN, GRU, LSTM và các mô hình kết hợp để dự báo giá Bitcoin, tuân theo quy trình khoa học từ thu thập dữ liệu, huấn luyện mô hình đến đánh giá hiệu suất. Kết quả trên tập huấn luyện cho thấy tất cả các mô hình đều đạt độ phù hợp cao, trong đó RNN có hiệu suất tốt nhất, còn LSTM-GRU có hiệu suất kém nhất. Tuy nhiên, hiện tượng quá khớp vẫn xuất hiện ở các mô hình RNN, LSTM, GRU-LSTM, khi mô hình hoạt động tốt trên tập huấn luyện nhưng không duy trì được độ chính

xác cao trên tập giám sát. Bên cạnh đó, GRU là mô hình có hiệu suất tốt nhất trên tập giám sát, với R^2 score cao nhất và sai số thấp nhất. Dữ liệu dự báo cũng thể hiện sự ổn định, không có biến động quá mức so với dữ liệu thực tế, cho thấy mô hình hoạt động hợp lý theo thời gian.

Để nâng cao hiệu quả dự báo giá Bitcoin, nghiên cứu đề xuất một số hướng phát triển quan trọng. Thứ nhất, cần tối ưu hóa tham số mô hình bằng các phương pháp để cải thiện độ chính xác và hạn chế overfitting. Thứ hai là mở rộng tập dữ liệu đầu vào để giúp mô hình phản ánh đầy đủ hơn các yếu tố ảnh hưởng đến giá Bitcoin, chẳng hạn như các yếu tố kinh tế vĩ mô (lãi suất, tỷ giá hối đoái, giá vàng), chỉ số thị trường (S&P 500, Nasdaq) và các biến liên quan đến công nghệ blockchain (độ khó khai thác, tỷ lệ băm), có thể nâng cao hiệu suất dự báo. Ngoài ra, cần tăng cường giám sát và kiểm soát rủi ro khi tiến hành dự báo. Thứ ba, mở rộng nghiên cứu bằng cải tiến, kết hợp các phương pháp để nâng cao độ chính xác và tính ứng dụng. Đặc biệt, cần tiếp tục thử nghiệm và đánh giá hiệu suất của các mô hình học máy tiên tiến như Transformer hoặc XGBoost để so sánh với các phương pháp hiện tại. Điều này giúp nâng cao khả năng dự báo, ứng dụng thực tiễn của các mô hình và cung cấp thêm thông tin hữu ích cho các nhà đầu tư.

Tài liệu tham khảo:

- Chen, J. (2023). Analysis of bitcoin price prediction using machine learning. *Journal of Risk and Financial Management*, 16(1), 51.
- Chen, W., Xu, H., Jia, L., & Gao, Y. (2021). Machine learning model for Bitcoin exchange rate prediction using economic and technology determinants. *International Journal of Forecasting*, 37(1), 28-43.
- Gholipour, M. (2023). Leveraging the Power of Hybrid Models: Combining ARIMA and LSTM for Accurate Bitcoin Price Forecasting.
- Gunarto, D. M., Sa'adah, S., & Utama, D. Q. (2023). Predicting cryptocurrency price using rnn and lstm method. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 12(1), 1-8.
- Hochreiter, S., & Schmidhuber, J. (1997). Flat minima. *Neural computation*, 9(1), 1-42.
- Hu, Y., Ni, J., & Wen, L. (2020). A hybrid deep learning approach by integrating LSTM-ANN networks with GARCH model for copper price volatility prediction. *Physica A: Statistical Mechanics and its Applications*, 557, 124907.
- Jagannath, N., Barbulescu, T., Sallam, K. M., Elgendi, I., Okon, A. A., McGrath, B., ... & Munasinghe, K. (2021). A self-adaptive deep learning-based algorithm for predictive analysis of bitcoin price. 9, 34054-34066.
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system, Satoshi Nakamoto.
- Pant, D. R., Neupane, P., Poudel, A., Pokhrel, A. K., & Lama, B. K. (2018, October). Recurrent neural network based bitcoin price prediction by twitter sentiment analysis. In 2018 IEEE 3rd international conference on computing, communication and security (ICCCS), 128-132, IEEE.
- Phaladisailoed, T., & Numnonda, T. (2018, July). Machine learning models comparison for bitcoin price prediction. In 2018 10th international conference on information technology and electrical engineering (ICITEE), 506-511, IEEE.
- Rizwan, M., Narejo, S., & Javed, M. (2019, December). Bitcoin price prediction using deep learning algorithm. In 2019 13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS), 1-7.
- Shin, M., Mohaisen, D., & Kim, J. (2021, January). Bitcoin price forecasting via ensemble-based LSTM deep learning networks. In 2021 International conference on information networking (ICOIN), 603-608, IEEE.
- Shiri, F. M., Perumal, T., Mustapha, N., & Mohamed, R. (2023). A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU.
- Zahid, M., Iqbal, F., & Koutmos, D. (2022). Forecasting Bitcoin volatility using hybrid GARCH models with machine learning. *Risks*, 10(12), 237.