

SO SÁNH HIỆU QUẢ MÔ HÌNH HỌC SÂU 1D-CNN, LSTM VÀ MÔ HÌNH LAI TRONG DỰ BÁO GIÁ ĐÓNG CỦA BITCOIN

Trần Thái Hòa^{1*}, Lê Mạnh Thanh², Nguyễn Đình Hoa Cương³

¹Khoa Hệ thống thông tin Kinh tế, Trường Đại học Kinh tế, Đại học Huế

²Khoa Công nghệ Thông tin, Trường Đại học Khoa học, Đại học Huế

³Khoa Công nghệ Kinh doanh, Trường Đại học Phú Xuân, Huế

*Email: tranthaihoa@hueuni.edu.vn

Ngày nhận bài: 02/12/2024; ngày hoàn thành phản biện: 16/12/2024; ngày duyệt đăng: 20/12/2024

TÓM TẮT

Nghiên cứu này so sánh hiệu quả của ba kiến trúc học sâu—mạng nơ-ron tích chập một chiều (1D-CNN), bộ nhớ dài-ngắn hạn (LSTM), và mô hình lai 1D-CNN-LSTM—trong dự báo giá đóng cửa của Bitcoin. Dữ liệu thu thập từ Yahoo Finance (17/09/2014 đến 01/10/2024) được xử lý bằng kỹ thuật cửa sổ trượt với ba cấu hình (10-3, 15-5, 21-7). Kết quả cho thấy LSTM vượt trội trong dự báo ngắn hạn, trong khi mô hình lai đạt hiệu năng tốt hơn ở các dự báo trung và dài hạn. Các chỉ số đánh giá như MSE, MAE, RMSE và R^2 đều xác nhận tính ưu việt của mô hình lai trong trường hợp chuỗi dự báo dài.

Từ khóa: Bitcoin, dự báo, LSTM, mô hình lai, 1D-CNN.

1. MỞ ĐẦU

Với mức độ biến động lớn và ảnh hưởng ngày càng sâu rộng, Bitcoin đang khẳng định vị thế quan trọng trong hệ thống tài chính toàn cầu. Do đó, việc dự báo chính xác giá đóng cửa của Bitcoin trở thành một yêu cầu thiết yếu trong các nghiên cứu và ứng dụng tài chính hiện đại. Các phương pháp thống kê truyền thống thường gặp khó khăn trong việc mô hình hóa các đặc trưng phi tuyến và động của chuỗi thời gian giá tiền điện tử [1]. Trước thách thức này, cộng đồng nghiên cứu đã chuyển hướng mạnh mẽ sang ứng dụng các mô hình học sâu nhằm nâng cao độ chính xác trong dự báo. Trong đó, mô hình lai giữa CNN và LSTM đang thu hút nhiều sự quan tâm nhờ khả năng đồng thời khai thác các đặc trưng không gian và thời gian. CNN có thế mạnh trong việc trích xuất các đặc trưng cục bộ, trong khi LSTM nổi bật với khả năng ghi nhớ và mô hình hóa sự phụ thuộc thời gian dài hạn [2]. Sự kết hợp giữa hai mô hình này tạo ra một kiến trúc linh hoạt và cải thiện độ chính xác trong nhiều tình huống dự báo khác nhau.

Mặc dù các mô hình CNN, LSTM và mô hình lai đã được áp dụng rộng rãi trong nhiều nghiên cứu trước đây, nhưng việc đánh giá định lượng về hiệu quả tương đối của chúng theo các khung thời gian dự báo khác nhau (ngắn hạn, trung hạn và dài hạn) vẫn chưa được nghiên cứu đầy đủ, đặc biệt trong bối cảnh thị trường Bitcoin có mức độ biến động cao. Trong nghiên cứu này, mô hình lai được xây dựng và so sánh hiệu năng với các mô hình cơ sở là CNN và LSTM để đánh giá về hiệu quả trong dự báo giá đóng cửa Bitcoin, đặc biệt trong khoảng thời gian trung và dài hạn.

Đóng góp của bài báo bao gồm:

- Thứ nhất, đề xuất một kiến trúc kết hợp mới giữa 1D-CNN và LSTM nhằm tận dụng tối ưu ưu điểm của từng mô hình.

- Thứ hai, tiến hành phân tích thực nghiệm dựa trên dữ liệu giao dịch thực tế với ba cấu hình cửa sổ thời gian khác nhau (10-3, 15-5, 21-7).

- Thứ ba, thực hiện so sánh hiệu quả mô hình đề xuất với hai mô hình cơ sở (1D-CNN và LSTM) qua các chỉ số đánh giá: MSE, MAE, RMSE, R^2 . Kết quả chỉ ra rằng mô hình lai cho hiệu năng vượt trội ở các giai đoạn dự báo trung và dài hạn, khẳng định tính hiệu quả và khả năng ứng dụng thực tiễn của kiến trúc lai trong dự báo biến động giá Bitcoin.

Nội dung tiếp theo của bài báo bao gồm 4 mục. Mục 2 giới thiệu các công trình liên quan về ứng dụng mô hình học sâu trong dự báo giá tiền điện tử. Mục 3 trình bày một số kiến trúc mô hình học sâu dùng trong dự báo chuỗi thời gian. Mục 4 Tiến hành thực nghiệm, mô tả kết quả và so sánh hiệu năng giữa các mô hình. Cuối cùng, Mục 5 tổng kết và đánh giá kết quả chính, đề xuất hướng nghiên cứu tiếp theo.

2. CÁC CÔNG TRÌNH NGHIÊN CỨU LIÊN QUAN

Thị trường tài chính, đặc biệt là tiền điện tử, với tính chất biến động mạnh và phi tuyến, đã thúc đẩy nhu cầu ứng dụng các kỹ thuật tính toán hiện đại để nâng cao độ chính xác trong dự báo giá. Các phương pháp truyền thống như ARIMA, hồi quy tuyến tính [1] dù từng phổ biến, nhưng dần bộc lộ hạn chế khi xử lý dữ liệu nhiễu và phi tuyến như giá Bitcoin. Trong bối cảnh đó, các mô hình học máy và học sâu như CNN, RNN, LSTM và các kiến trúc lai đã chứng minh hiệu quả vượt trội trong việc mô hình hóa các mối quan hệ phức tạp trong dữ liệu tài chính [3]. Tuy nhiên, đa số các nghiên cứu sử dụng phương pháp truyền thống hoặc học sâu riêng lẻ thường chưa đánh giá và so sánh hiệu năng dự báo theo từng khung thời gian cụ thể, dẫn đến khó khăn trong việc lựa chọn mô hình phù hợp với mục tiêu đầu tư ngắn, trung hay dài hạn.

Bài báo tập trung vào ba hướng tiếp cận chính trong dự báo giá tài chính và tiền điện tử: (1) CNN với khả năng trích xuất đặc trưng cục bộ trong chuỗi thời gian; (2)

LSTM với khả năng học các phụ thuộc dài hạn; và (3) mô hình lai CNN-LSTM tích hợp ưu điểm của cả hai kiến trúc. Các nghiên cứu sử dụng ba mô hình này đã cho thấy kết quả tích cực trong dự báo giá cổ phiếu, chỉ số tài chính và tiền điện tử như Bitcoin, Ethereum. Độc giả có thể tham khảo các tổng quan tại [4]-[5] để hiểu rõ hơn về ứng dụng học sâu trong lĩnh vực này.

Hasan và cộng sự [6] đề xuất mô hình CNN kết hợp dữ liệu lịch sử và phân tích cảm xúc từ Twitter để dự đoán giá bốn loại tiền điện tử, đạt độ chính xác 98.75%. Somayajulu và cộng sự [7] cho thấy CNN có MAPE 3.7%, vượt trội so với LSTM (6.5%) trong dự báo giá Bitcoin nhờ khả năng trích xuất đặc trưng ngắn hạn. Zhang và cộng sự [9] giới thiệu mô hình CNN tích hợp cơ chế chú ý và kênh bộ nhớ, giúp cải thiện hiệu năng trong dữ liệu phi tuyến. Tuy nhiên, do không lưu giữ thông tin theo thời gian, CNN đơn lẻ gặp hạn chế với các xu hướng dài hạn—từ đó thúc đẩy việc kết hợp CNN với LSTM để tận dụng ưu điểm của cả hai kiến trúc. Nhìn chung, các nghiên cứu này chủ yếu đánh giá hiệu quả CNN trong ngữ cảnh ngắn hạn mà chưa làm rõ tính ứng dụng khi kéo dài chuỗi dự báo.

Nasirtafreshi [8] sử dụng LSTM trong dự báo giá tiền điện tử và cho thấy mô hình này vượt trội hơn ANN, Simple RNN và ARIMA qua các chỉ số RMSE, MAE, MAPE và R^2 . Raj và Chattopadhyay [9] đề xuất LSTM Autoencoder tối ưu bằng thuật toán FNN và hàm mất mát MSE, giúp dự báo chính xác hướng biến động giá Bitcoin. Aditya Pai và cộng sự [10] phát triển mô hình LSTM dự báo giá mở cửa các loại tiền điện tử, có thể triển khai qua API và WebApp với sai số thấp. Reepu [11] tiếp tục khẳng định hiệu quả của LSTM trong dự báo giá Ethereum và mối liên hệ với Bitcoin. LSTM nổi bật nhờ khả năng ghi nhớ thông tin dài hạn thông qua các cổng nhớ, phù hợp với dữ liệu tài chính có ảnh hưởng kéo dài theo thời gian. Tuy nhiên, mô hình này đòi hỏi thời gian huấn luyện dài và dễ quá khớp nếu không tối ưu hóa siêu tham số phù hợp, nhất là khi xử lý dữ liệu nhiễu cao như trong thị trường tiền điện tử. Điểm hạn chế chung là phần lớn các nghiên cứu chỉ áp dụng LSTM độc lập mà không đặt trong bối cảnh so sánh trực tiếp với các kiến trúc khác để lựa chọn mô hình tối ưu theo từng khoảng thời gian dự báo.

Nhằm khắc phục hạn chế của từng mô hình đơn lẻ, các nghiên cứu gần đây đã đề xuất mô hình lai CNN-LSTM, kết hợp khả năng trích xuất đặc trưng cục bộ của CNN và ghi nhớ chuỗi dài hạn của LSTM. Trong khi Peng và cộng sự [12] tích hợp cơ chế attention vào mô hình CNN-LSTM để dự báo giá tiền điện tử với tần suất cao, đạt hiệu quả cao trên dữ liệu biến động, Khattak và cộng sự [13] kết hợp mô hình CNN-LSTM với chỉ báo Fibonacci và phân loại đa lớp nhằm tăng khả năng sinh lợi cho chiến lược đầu tư. Bên cạnh đó, Chen và cộng sự [14] phát triển mô hình có thể giải thích, đạt MAPE 2.39% và độ chính xác 89.54% trong dự báo giá Bitcoin, cho thấy vai trò của các biến như khối lượng và giá thị trường. Công trình nghiên cứu của Huang và cộng sự [15] cho thấy CNN-LSTM vượt trội hơn các mô hình kinh tế lượng như GARCH, HAR,

đặc biệt khi tích hợp Markov Transition Field, hiệu quả rõ rệt trong dự báo ngắn hạn (7 ngày), trong khi đó, He và cộng sự [16] đề xuất NRBO-CNN-BiLSTM-Attention, sử dụng các thuật toán tối ưu INFO và NRBO, giúp giảm MAPE trên 50% và duy trì độ ổn định qua kiểm định MCS. Tuy nhiên, đa phần các nghiên cứu trên vẫn chỉ triển khai một cấu hình thời gian cố định và chưa cung cấp cái nhìn định lượng rõ ràng về mối quan hệ giữa độ dài cửa sổ đầu vào, khoảng thời gian dự báo và hiệu suất của từng mô hình học sâu.

Nghiên cứu này không chỉ đề xuất mô hình lai CNN-LSTM hiệu quả đối với các mẫu phức tạp mà còn kiểm soát quá khớp tốt hơn, đặc biệt nghiên cứu còn so sánh hiệu năng của mô hình với các chuỗi dự báo ngắn, trung và dài hạn nhờ tính mở rộng và linh hoạt vượt trội của mô hình đề xuất.

3. MỘT SỐ PHƯƠNG PHÁP DỰ BÁO CHUỖI THỜI GIAN

3.1 Mô hình 1D-CNN

Mô hình 1D-CNN là một loại đặc biệt của mạng nơ-ron tích chập được thiết kế để xử lý dữ liệu theo các cấu trúc tuần tự như chuỗi thời gian hoặc ngôn ngữ tự nhiên. Một mạng 1D-CNN điển hình bao gồm một số lớp và thành phần quan trọng [17], [18]. Hàm kích hoạt (activation function) được các lớp sử dụng để nắm bắt các mẫu phức tạp. Các lớp gộp (pooling layers) được áp dụng để giảm chiều dữ liệu. Trong nghiên cứu này, 1D-CNN được kết nối với LSTM. Do đó, các lớp kết nối đầy đủ (fully connected layers) được chuyển đến cuối mô hình lai và sẽ được trình bày trong Mục 3.3.

Về mặt lý thuyết, một phép tích chập tại thời điểm t , sử dụng đầu vào x và kernel w có kích thước k , sẽ cho đầu ra y tại cùng thời điểm, như trong phương trình (1):

$$y(t) = (x * w)(t) = \sum_{i=0}^{k-1} x(t+i) \cdot w(i) \quad (1)$$

Trong đó:

- $*$ biểu thị phép tích chập (convolution),
- $x(t+i)$ là phần tử đầu vào tại vị trí $t+i$,
- $w(i)$ là phần tử thứ i của kernel.

Hàm kích hoạt được sử dụng trong mô hình lai này là hàm **ReLU** (Rectified Linear Unit). Với z là đầu vào của hàm kích hoạt. Hàm được định nghĩa trong phương trình (2):

$$ReLU(z) = \max(0, z) \quad (2)$$

Hàm **Max Pooling**, được áp dụng trong mô hình lai, được định nghĩa trong

Phương trình ((3):

$$y(t) = \max(x(t), x(t+1), \dots, x(t+p-1)) \quad (3)$$

Trong đó:

- $y(t)$: giá trị đầu ra tại thời điểm t
- $x(t+i)$: giá trị đầu vào tại các vị trí trong cửa sổ pooling, với $i \in [0, p-1]$
- p : kích thước cửa sổ pooling (pool size)

Trong giai đoạn huấn luyện, 1D-CNN sử dụng thuật toán lan truyền ngược để điều chỉnh các trọng số của bộ lọc dựa trên việc cập nhật liên tục sai số. Hàm mất mát (loss function) tính sai số dựa trên sự khác biệt giữa đầu ra thực tế và đầu ra dự đoán. Giá trị sai số này sau đó được lan truyền ngược qua mạng bằng gradient descent để cập nhật trọng số. Phương trình ((4)) định nghĩa gradient của phép tích chập:

$$\frac{\partial L}{\partial w(i)} = \sum_t \frac{\partial L}{\partial y(t)} \cdot x(t+i) \quad (4)$$

Trong đó:

- L : hàm mất mát (loss function)
- $y(t)$: đầu ra tại thời điểm t
- $w(i)$: trọng số tại vị trí i
- $x(t+i)$: đầu vào tại vị trí tương ứng
- $\frac{\partial L}{\partial w(i)}$: gradient của hàm mất mát theo trọng số $w(i)$

Mô hình 1D-CNN sử dụng các lớp tích chập một chiều và lớp gộp (max pooling) để trích xuất đặc trưng theo thời gian từ chuỗi dữ liệu.

3.2 Mô hình LSTM

Đây là mạng nơ-ron hồi tiếp có khả năng ghi nhớ dài hạn, đặc biệt phù hợp với dữ liệu tài chính có mối liên hệ kéo dài theo thời gian. Mô hình bao gồm một hoặc nhiều lớp LSTM xếp chồng (stacked), giúp mô hình học được mối quan hệ phức tạp giữa các bước thời gian trong chuỗi dữ liệu. Đầu ra của LSTM được kết nối đến lớp Dense để tạo ra giá trị dự báo cuối cùng [19].

LSTM sử dụng cơ chế cổng gồm: Forget Gate, Input Gate và Output Gate – cho phép chọn lọc lưu giữ hoặc loại bỏ thông tin theo thời gian, rất phù hợp để xử lý chuỗi tài chính có tính động phức tạp. Hoạt động nội tại của mỗi cell LSTM được tính toán theo các phương trình (12),

Cổng quên được tính toán theo phương trình (5):

$$F_t = \sigma (W_f X_t + U_f H_{t-1} + b_f) \quad (5)$$

Cổng vào và trạng thái các ứng viên được thực hiện theo phương trình (6):

$$\begin{aligned} I_t &= \sigma (W_i X_t + U_i H_{t-1} + b_i) \\ \tilde{C}_t &= \tanh (W_c X_t + U_c H_{t-1} + b_c) \end{aligned} \quad (6)$$

Cập nhật trạng thái ô nhớ theo phương trình (7):

$$C_t = F_t \odot C_{t-1} + I_t \odot \tilde{C}_t \quad (7)$$

Cổng ra và trạng thái ẩn được tính toán theo công thức (8):


$$\begin{aligned} O_t &= \sigma (W_o X_t + U_o H_{t-1} + b_o) \\ H_t &= O_t \odot \tanh (C_t) \end{aligned} \quad (8)$$

Trong đó:

- X_t : đầu vào tại thời điểm t
- H_{t-1} : trạng thái ẩn và trạng thái ô nhớ trước đó
- C_{t-1} : trạng thái ô nhớ từ thời điểm trước
- F_t, I_t, O_t : các giá trị kích hoạt của cổng quên, cổng vào và cổng ra
- $\tilde{C}_t$: trạng thái ô nhớ ứng viên
- W^*, U^*, b^* : các ma trận trọng số và độ lệch có thể huấn luyện được
- σ : hàm kích hoạt sigmoid
- $\tanh$: hàm kích hoạt hyperbolic tangent
- $\odot$: phép nhân từng phần tử (theo phần tử tương ứng)

Mạng LSTM nhờ vào cơ chế cổng linh hoạt có thể đồng thời học được cả biến động ngắn hạn và xu hướng dài hạn trong chuỗi giá tài chính, phù hợp với việc mô hình hóa các phụ thuộc theo chuỗi.

3.3 Mô hình lai 1D-CNN-LSTM



Hình 1. Kiến trúc mô hình lai 1D-CNN- LSTM

Kiến trúc của mô hình lai 1D-CNN-LSTM được nhóm tác giả nghiên cứu đề xuất trong bài báo này có cấu trúc như **Error! Reference source not found.** Mô hình gồm các lớp chính như sau: lớp đầu vào nhận chuỗi thời gian đã xử lý bằng phương pháp cửa sổ trượt; lớp 1D-CNN với các lớp tích chập một chiều giúp trích xuất đặc trưng cục bộ, làm nổi bật biến động giá ngắn hạn; lớp MaxPooling1D giảm số lượng tham số và chọn lọc đặc trưng quan trọng; lớp LSTM tiếp nhận đặc trưng từ CNN để ghi nhớ chuỗi thời gian dài và học quan hệ phụ thuộc theo thời gian; lớp Dense chuyển đổi đầu ra từ LSTM thành giá trị dự báo cụ thể; cuối cùng là lớp đầu ra cung cấp dãy giá dự báo tương ứng với forecast size của từng cấu hình.

Mô hình lai này được thiết kế nhằm tận dụng tối đa khả năng trích xuất đặc trưng mạnh mẽ của CNN và năng lực ghi nhớ chuỗi dài của LSTM. Nhờ đó, mô hình có thể thích nghi với cả xu hướng ngắn hạn và dài hạn trong dữ liệu tài chính, từ đó cải thiện đáng kể độ chính xác dự báo.

3.4 Chỉ số đánh giá mô hình

Để đánh giá và so sánh hiệu năng của các mô hình dự báo, nghiên cứu sử dụng bốn chỉ số phổ biến trong các bài toán hồi quy chuỗi thời gian: Sai số bình phương trung bình (MSE), Sai số tuyệt đối trung bình (MAE), Căn bậc hai của MSE (RMSE), Hệ số xác định (R^2).

Với:

- y_i : giá trị thực tế tại quan sát thứ i
- $\hat{y}_i$: giá trị dự báo tại quan sát thứ i
- $\bar{y}_i$: giá trị trung bình của tập dữ liệu thực tế
- n : số lượng quan sát

Các chỉ số đánh giá được xác định bởi công thức (9)(12):

$$MSE(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2 \quad (9)$$

$$MAE(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} |y_i - \hat{y}_i| \quad (10)$$

$$RMSE(y, \hat{y}) = \sqrt{MSE(y, \hat{y})} \quad (11)$$

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{N-1} (y_i - \bar{y}_i)^2} \quad (12)$$

Bốn chỉ số này được tính toán trên cả tập kiểm định và tập kiểm tra, nhằm đánh giá tính tổng quát hóa (generalization) của từng mô hình trong từng cấu hình trượt khác nhau.

4. THỰC NGHIỆM VÀ THẢO LUẬN KẾT QUẢ

4.1 Dữ liệu giá Bitcoin:

Dữ liệu sử dụng trong nghiên cứu là chuỗi thời gian giá Bitcoin thu thập từ nguồn Yahoo Finance¹ từ ngày 17/09/2014 đến ngày 01/10/2024. Tập dữ liệu bao gồm các thuộc tính: giá mở cửa (Open), giá cao nhất (High), giá thấp nhất (Low), giá đóng cửa (Close) và khối lượng giao dịch (Volume). Biến mục tiêu được lựa chọn trong nghiên cứu là giá đóng cửa, có ý nghĩa quan trọng trong dự báo.

4.2 Tiền xử lý dữ liệu:

Trước khi huấn luyện mô hình, dữ liệu được xử lý bằng cách loại bỏ các giá trị thiếu và chuẩn hóa toàn bộ tập dữ liệu về khoảng $[0, 1]$ bằng phương pháp Min-Max scaling, nhằm đảm bảo độ ổn định và tăng tốc quá trình huấn luyện. Phương trình cho phạm vi tỉ lệ $[0, 1]$ được cho bởi công thức (13):

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (13)$$

Trong đó, x_i là giá trị thực tế, $x_{\min}$ là giá trị nhỏ nhất, $x_{\max}$ là giá trị lớn nhất trong tập dữ liệu; x'_i là giá trị chuẩn hoá.

4.3 Phương pháp cửa sổ trượt (Sliding window) và cấu hình dự báo:

Trong nghiên cứu này, kỹ thuật cửa sổ trượt (sliding window) được áp dụng để chuyển đổi chuỗi thời gian ban đầu thành dạng dữ liệu có cấu trúc, phù hợp cho việc huấn luyện các mô hình học sâu. Giá sử tập dữ liệu gốc là một chuỗi thời gian đa biến, được biểu diễn theo Phương trình (14):

$$S = \{s_1, s_2, \dots, s_T\}, \quad s_t \in \mathbb{R}^D \quad (14)$$

Trong đó, s_t là dữ liệu cổ phiếu tại thời điểm t , và D là số lượng đặc trưng (chẳng hạn như giá mở cửa, giá cao nhất, giá thấp nhất, khối lượng giao dịch). Toàn bộ tập dữ liệu tạo thành một ma trận $S \in \mathbb{R}^{T \times D}$, đảm bảo tính tuần tự theo thời gian.

Kỹ thuật cửa sổ trượt được xác định bởi các tham số:

- *Kích thước cửa sổ W* : số bước thời gian trong quá khứ được sử dụng làm đầu vào cho mô hình.
- *Khoảng thời gian dự báo F* : số bước thời gian trong tương lai cần dự đoán.

Với mỗi chỉ số $t \in \{W+F, \dots, T\}$, các chuỗi đầu vào và đầu ra tương ứng được định nghĩa theo Phương trình (15) và (16) như sau:

¹ <https://finance.yahoo.com/>

$$X_t = [s_{t-W-F+1}, \dots, s_{t-F}] \in \mathbb{R}^{W \times D} \quad (15)$$

$$y_t = [y_{t-F+1}, \dots, y_t] \in \mathbb{R}^{F \times 1} \quad (16)$$

Trong đó, y_t thường là giá đóng cửa tại thời điểm t , được trích xuất từ vector s_t .


Quá trình biến đổi này cho kết quả:

- Tensor đầu vào: $X \in \mathbb{R}^{N \times W \times D}$
- Tensor đầu ra: $y \in \mathbb{R}^{N \times F \times 1}$

Với $N = T - W - F + 1$, là tổng số mẫu dữ liệu huấn luyện thu được.

Cụ thể, mỗi chuỗi liên tiếp gồm n ngày dữ liệu đầu vào sẽ được sử dụng để dự báo m ngày giá đóng cửa tiếp theo, giúp mô hình học được các quy luật từ quá khứ để dự đoán xu hướng tương lai. Nhằm kiểm tra hiệu quả dự báo ở các khoảng thời gian khác nhau, nhóm tác giả triển khai ba cấu hình thí nghiệm: cửa sổ 10 ngày – dự báo 3 ngày (10–3), cửa sổ 15 ngày – dự báo 5 ngày (15–5), và cửa sổ 21 ngày – dự báo 7 ngày (21–7). Dữ liệu trong mỗi cấu hình được chia thành 70% cho huấn luyện, 15% cho kiểm định và 15% cho kiểm tra, đảm bảo đánh giá khách quan hiệu năng của các mô hình trong các bối cảnh dự báo ngắn, trung và dài hạn.

4.4 Kiến trúc mô hình học sâu để xuất dự báo giá Bitcoin



Hình 2. Quy trình so sánh hiệu quả dự báo của các mô hình 1D-CNN, LSTM và mô hình lai 1D-CNN-LSTM

Trong nghiên cứu này, quy trình đánh giá và so sánh hiệu quả dự báo giá đóng cửa của Bitcoin giữa ba mô hình — 1D-CNN, LSTM và mô hình lai 1D-CNN-LSTM — được minh họa trong **Error! Reference source not found..** Quy trình dự báo giá Bitcoin bao gồm ba giai đoạn chính: thu thập dữ liệu, tiền xử lý, và huấn luyện mô hình. Đầu tiên, dữ liệu lịch sử tiền điện tử được thu thập và chuẩn hóa. Sau đó, kỹ thuật cửa sổ trượt (sliding window) được áp dụng để tạo ra các chuỗi con có cấu trúc đầu vào – đầu ra. Dữ liệu tiếp tục được chia thành ba tập: huấn luyện, kiểm định và kiểm tra.


Ba mô hình học sâu được sử dụng để huấn luyện gồm: 1D-CNN, LSTM, và mô hình lai 1D-CNN-LSTM. Sau khi huấn luyện, các mô hình được đánh giá bằng các chỉ số như MSE, MAE, RMSE và R^2 để lựa chọn mô hình tối ưu cho dự báo giá đóng cửa của Bitcoin.

4.5 Phân tích và thảo luận kết quả thực nghiệm:

Kết quả thực nghiệm cho thấy hiệu quả dự báo của các mô hình học sâu thay đổi đáng kể theo từng cấu hình cửa sổ trượt. Trong phần này, các biểu đồ đường cong mất mát (loss) và đồ thị so sánh giữa giá thực tế và giá dự báo được sử dụng để phân tích hiệu năng của từng mô hình trong ba cấu hình cụ thể: 10-3, 15-5 và 21-7.

Cấu hình 1: Dự báo 3 ngày với cửa sổ 10 ngày (10-3)


Trong cấu hình này, mô hình LSTM thể hiện ưu thế vượt trội với sai số dự báo thấp nhất và độ khớp cao nhất giữa giá thực và giá dự báo. Đường cong mất mát trong **Error! Reference source not found.** cho thấy mô hình LSTM hội tụ tốt với sai số huấn luyện và kiểm định đều giảm ổn định theo số epoch. Mô hình lai và 1D-CNN mặc dù có độ chính xác tương đối cao nhưng vẫn kém hơn LSTM trong bối cảnh ngắn hạn.



Hình 1. Đường cong mất mát của 3 mô hình dự báo với cấu hình 1(10-3)

Cấu hình 2: Dự báo 5 ngày với cửa sổ 15 ngày (15-5)


Ở cấu hình trung hạn, mô hình lai 1D-CNN + LSTM cho kết quả tốt nhất. Biểu đồ giá trong **Hình 5** cho thấy đường dự báo của mô hình lai bám sát giá trị thực qua toàn bộ chuỗi thời gian. Đồng thời, đường cong mất mát của mô hình lai trong **Error! Reference source not found.** cũng có xu hướng giảm đều, cho thấy khả năng học ổn định và khả năng khái quát tốt hơn hai mô hình đơn lẻ.



Hình 2. Đường cong mất mát của 3 mô hình dự báo với cấu hình 2 (15-5)

Cấu hình 3: Dự báo 7 ngày với cửa sổ 21 ngày (21-7)

Với cấu hình dự báo dài hạn, sự khác biệt giữa các mô hình càng trở nên rõ rệt. Mô hình lai tiếp tục thể hiện độ chính xác vượt trội so với LSTM và 1D-CNN, cả về độ trùng khớp với giá thực tế như trong **Hình 6** lẫn độ hội tụ của hàm mất mát như trong **Error! Reference source not found.** LSTM bắt đầu suy giảm hiệu quả khi dự báo xa hơn, trong khi 1D-CNN thường dao động nhiều và thiếu tính ổn định.



Hình 3. Đường cong mất mát của 3 mô hình dự báo với cấu hình 3 (21-7)




Bảng 1. Đánh giá hiệu năng các mô hình 1D-CNN, LSTM và mô hình lai 1D-CNN-LSTM

Window_size - Forecast_size	Model	MSE	MAE	RMSE	R2
Cấu hình 1 window_size = 10 forecast_size = 3	Hybrid	0.002039	0.031284	0.045151	0.978926
	1D-CNN	0.001491	0.027356	0.038613	0.984589
	LSTM	0.001077	0.022712	0.032822	0.988865
Cấu hình 2 window_size = 15 forecast_size = 5	Hybrid	0.00218	0.033846	0.046694	0.977376
	1D-CNN	0.003347	0.041884	0.057857	0.965256
	LSTM	0.006341	0.060353	0.079629	0.934174
Cấu hình 3 window_size = 21 forecast_size = 7	Hybrid	0.002758	0.037433	0.052513	0.97126
	1D-CNN	0.006978	0.063264	0.083537	0.927235
	LSTM	0.007942	0.062959	0.089119	0.917197

Kết quả dự đoán của các mô hình trên ba cấu hình cửa sổ trượt được trình bày trong **Hình 4**, **Hình 5**, và **Hình 6** kèm theo các chỉ số đánh giá hiệu năng được tổng hợp trong Bảng 1. Kết quả chứng minh rằng mô hình lai 1D-CNN-LSTM luôn vượt trội hơn các mô hình độc lập trong các cấu hình có kích thước cửa sổ lớn hơn (Cấu hình 2 và 3),

đặc biệt là đối với các dự đoán dài hạn. Mặc dù sai số giữa các mô hình có chênh lệch rõ, nghiên cứu chưa áp dụng kiểm định thống kê (như ANOVA, Wilcoxon test) để xác định mức độ ý nghĩa thống kê giữa các kết quả.

Tổng quan kết quả cho thấy mỗi mô hình phát huy ưu thế ở các khoảng thời gian dự báo khác nhau. Mô hình LSTM hoạt động hiệu quả trong dự báo ngắn hạn (3 ngày), trong khi mô hình lai CNN-LSTM tỏ ra vượt trội ở các khung thời gian trung và dài hạn (5–7 ngày). Mô hình 1D-CNN tuy có kết quả khả quan ban đầu nhưng giảm ổn định khi độ dài chuỗi dự báo tăng.



5. KẾT LUẬN

Nghiên cứu này đã tiến hành đánh giá và so sánh hiệu quả của ba kiến trúc học sâu—1D-CNN, LSTM và mô hình lai 1D-CNN-LSTM—trong dự báo giá đóng cửa của Bitcoin, dựa trên ba cấu hình của sổ trượt đại diện cho các khung thời gian ngắn hạn (10–3), trung hạn (15–5) và dài hạn (21–7). Kết quả thực nghiệm cho thấy LSTM có hiệu năng vượt trội trong dự báo ngắn hạn nhờ khả năng học phụ thuộc theo chuỗi, trong khi mô hình lai CNN-LSTM cho kết quả tốt hơn ở các dự báo trung và dài hạn nhờ khả năng kết hợp đặc trưng cục bộ và dài hạn.

Từ đó, nghiên cứu đề xuất hướng tiếp cận linh hoạt trong lựa chọn mô hình theo mục tiêu dự báo: LSTM phù hợp với các ứng dụng yêu cầu phản ứng nhanh trong ngắn hạn, trong khi mô hình lai CNN-LSTM thích hợp cho các chiến lược đầu tư và dự báo dài hạn với yêu cầu ổn định và độ chính xác cao.

Tuy nhiên, nghiên cứu vẫn tồn tại một số hạn chế. Thứ nhất, chỉ tập trung vào dữ liệu giá đóng cửa mà chưa tích hợp thêm các yếu tố bên ngoài như dữ liệu cảm xúc, tin tức hoặc biến động vĩ mô. Thứ hai, nghiên cứu mới chỉ đánh giá trên dữ liệu của một loại tiền điện tử (Bitcoin), do đó khả năng tổng quát hóa sang các tài sản số khác chưa được kiểm chứng. Ngoài ra, việc tối ưu siêu tham số cho từng mô hình còn thực hiện thủ công, chưa áp dụng các thuật toán tự động hóa như Grid Search hoặc Bayesian Optimization.

Hướng nghiên cứu tiếp theo sẽ tập trung vào việc mở rộng mô hình với dữ liệu đa nguồn (đa biến), tích hợp cơ chế attention để tăng khả năng diễn giải, đồng thời so sánh với các kiến trúc tiên tiến hơn như Transformer hoặc Temporal Fusion Transformer. Ngoài ra, việc đánh giá hiệu quả mô hình trong điều kiện thị trường thực tế và ứng dụng trong chiến lược đầu tư tự động cũng là một hướng triển vọng.

TÀI LIỆU THAM KHẢO

- [1] A. M. Khedr, I. Arif, P. R. P V, M. El-Bannany, S. M. Alhashmi, and M. Sreedharan, "Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey," *Intell. Syst. Account. Finance Manag.*, vol. 28, no. 1, pp. 3–34, Jan. 2021, doi: 10.1002/isaf.1488.
- [2] H. Widiputra, A. Mailangkay, and E. Gautama, "Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction," *Complexity*, vol. 2021, no. 1, p. 9903518, 2021, doi: 10.1155/2021/9903518.
- [3] J. Shah, D. Vaidya, and M. Shah, "A comprehensive review on multiple hybrid deep learning approaches for stock prediction," *Intell. Syst. Appl.*, vol. 16, p. 200111, Nov. 2022, doi: 10.1016/j.iswa.2022.200111.
- [4] O. Omole and D. Enke, "Deep learning for Bitcoin price direction prediction: models and trading strategies empirically compared," *Financ. Innov.*, vol. 10, no. 1, p. 117, Aug. 2024, doi: 10.1186/s40854-024-00643-1.
- [5] J. Zhang, K. Cai, and J. Wen, "A survey of deep learning applications in cryptocurrency," *iScience*, vol. 27, no. 1, p. 108509, Jan. 2024, doi: 10.1016/j.isci.2023.108509.
- [6] S. Hasan, S. Hasan, M. Ahmed, and S. Hasan, "A Novel Cryptocurrency Prediction Method Using Optimum CNN," *Comput. Mater. Contin.*, vol. 71, no. 1, pp. 1051–1063, 2021, doi: 10.32604/cmc.2022.020823.
- [7] M. V. N. S. S. R. K. S. Somayajulu, D. M. Ahmed, and B. Kotaiah, "Bitcoin Price Prediction Using LSTM and CNN," Mar. 24, 2025, Social Science Research Network, Rochester, NY: 5190840. doi: 10.2139/ssrn.5190840.

- [8] I. Nasirtafreshi, "Forecasting cryptocurrency prices using Recurrent Neural Network and Long Short-term Memory," *Data Knowl. Eng.*, vol. 139, p. 102009, May 2022, doi: 10.1016/j.datak.2022.102009.
- [9] C. Raj and M. Chattopadhyay, "Bitcoin price prediction using LSTM autoencoder regularized by false nearest neighbor loss," *Soft Comput.*, vol. 28, no. 21, pp. 12827–12834, Nov. 2024, doi: 10.1007/s00500-024-10301-4.
- [10] B. Aditya Pai, L. Devareddy, S. Hegde, and B. S. Ramya, "A Time Series Cryptocurrency Price Prediction Using LSTM," in *Emerging Research in Computing, Information, Communication and Applications*, N. R. Shetty, L. M. Patnaik, H. C. Nagaraj, P. N. Hamsavath, and N. Nalini, Eds., Singapore: Springer, 2022, pp. 653–662. doi: 10.1007/978-981-16-1342-5_50.
- [11] Reepu, "A Price Prediction Using LSTM of Various Blockchain Platforms vs BITCOIN," in *Innovations and Advances in Cognitive Systems*, S. D. P. Ragavendiran, V. D. Pavaloaia, M. S. Mekala, and A. S. Cabezuelo, Eds., Cham: Springer Nature Switzerland, 2024, pp. 464–472. doi: 10.1007/978-3-031-69201-7_34.
- [12] P. Peng, Y. Chen, W. Lin, and J. Z. Wang, "Attention-based CNN–LSTM for high-frequency multiple cryptocurrency trend prediction," *Expert Syst. Appl.*, vol. 237, p. 121520, Mar. 2024, doi: 10.1016/j.eswa.2023.121520.
- [13] B. H. A. Khattak, I. Shafi, C. H. Rashid, M. Safran, S. Alfarhood, and I. Ashraf, "Profitability trend prediction in crypto financial markets using Fibonacci technical indicator and hybrid CNN model," *J. Big Data*, vol. 11, no. 1, p. 58, Apr. 2024, doi: 10.1186/s40537-024-00908-7.
- [14] S. Chen, Z. Liao, and J. Zhang, "Forecasting the Price of Bitcoin Using an Explainable CNN-LSTM Model," in *Intelligent Computers, Algorithms, and Applications*, C. Cruz, Y. Zhang, and W. Gao, Eds., Singapore: Springer Nature, 2024, pp. 93–101. doi: 10.1007/978-981-97-0065-3_7.
- [15] Z.-C. Huang, I. Sangiorgi, and A. Urquhart, "Forecasting Bitcoin volatility using machine learning techniques," *J. Int. Financ. Mark. Inst. Money*, vol. 97, p. 102064, Dec. 2024, doi: 10.1016/j.intfin.2024.102064.
- [16] X. He, Y. Li, and H. Li, "Revolutionizing Bitcoin price forecasts: A comparative study of advanced hybrid deep learning architectures," *Finance Res. Lett.*, vol. 69, p. 106136, Nov. 2024, doi: 10.1016/j.frl.2024.106136.
- [17] O. Russakovsky et al., "ImageNet Large Scale Visual Recognition Challenge," *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, Dec. 2015, doi: 10.1007/s11263-015-0816-y.
- [18] W. Chen, M. Jiang, W.-G. Zhang, and Z. Chen, "A novel graph convolutional feature based convolutional neural network for stock trend prediction," *Inf. Sci.*, vol. 556, pp. 67–94, 2021.
- [19] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," Dec. 11, 2014, arXiv: arXiv:1412.3555. doi: 10.48550/arXiv.1412.3555.

A COMPARATIVE STUDY OF 1D-CNN, LSTM, AND HYBRID DEEP LEARNING MODELS IN FORECASTING BITCOIN CLOSING PRICES

Hoa Tran Thai^{1*}, Le Manh Thanh², Cuong H.Nguyen-Dinh³

¹ Faculty of Economic Information Systems, University of Economics, Hue University

² Faculty of Information Technology, University of Sciences, Hue University

³ Faculty of Technology and Business, Phu Xuan University

*Email: tranthaihoa@hueuni.edu.vn

ABSTRACT

This study compares the performance of three deep learning architectures—1D Convolutional Neural Network (1D-CNN), Long Short-Term Memory (LSTM), and a hybrid 1D-CNN-LSTM model—for forecasting Bitcoin closing prices. Historical data from Yahoo Finance (September 17, 2014 to October 1, 2024) were processed using a sliding window technique with three configurations: 10–3, 15–5, and 21–7 (input–forecast). Results show that the LSTM model performs best in short-term forecasting, while the hybrid model achieves superior accuracy in medium- and long-term horizons. Performance metrics including MSE, MAE, RMSE, and R^2 confirm the hybrid model's advantages, especially in longer prediction intervals.

Keywords: Bitcoin, forecasting, deep learning, hybrid model, LSTM, 1D-CNN



Trần Thái Hòa sinh năm 1983 tại Huế. Ông tốt nghiệp Cử nhân ngành Công nghệ thông tin năm 2005 tại Trường Đại học Khoa học, Đại học Huế và Thạc sĩ ngành Quản lý và Phân tích thông tin Kinh tế năm 2010 tại Trường Đại học Kinh tế Quốc dân, Hà Nội. Ông hiện đang là giảng viên Khoa Hệ thống thông tin kinh tế, Trường Đại học Kinh tế, Đại học Huế.

Lĩnh vực nghiên cứu: Học máy và trí tuệ nhân tạo, Hệ thống thông tin quản lý, Phát triển Hệ thống thông tin, Khai phá dữ liệu



Lê Mạnh Thanh sinh năm 1953 tại Quảng Trị. Ông nhận học vị Tiến sĩ ngành khoa học máy tính tại Đại học Budapest (ELTE), Hungary vào năm 1994 và trở thành Phó giáo sư tại trường Đại học Khoa học, Đại học Huế vào năm 2004. Ông hiện đang là giảng viên Khoa Công nghệ thông tin, Trường Đại học Khoa học, Đại học Huế.

Lĩnh vực nghiên cứu: cơ sở dữ liệu, cơ sở tri thức và lập trình logic.



Nguyễn Đình Hoa Cương đã nhận bằng Thạc sĩ Khoa học và Tiến sĩ chuyên ngành Khoa học Máy tính tại Trường Đại học Khoa học, Đại học Huế, Việt Nam và tại Đại học Khon Kaen, Thái Lan lần lượt vào các năm 2005 và 2016. Hiện nay, ông là giảng viên tại Trường Đại học Phú Xuân, Huế.

Lĩnh vực nghiên cứu: khai phá dữ liệu, khai phá văn bản, quản lý tri thức và hệ thống hỗ trợ ra quyết định