

PHÂN TÍCH THỰC NGHIỆM MÔ HÌNH N-BEATS CHO BÀI TOÁN DỰ BÁO GIÁ BITCOIN THEO NHIỀU KHUNG THỜI GIAN

Trần Thái Hòa^{1,2*}, Dương Đức Hưng^{2,3}, Nguyễn Thanh Nam², Hoàng Bảo Khánh²

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

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

³ Ban Khoa học Công nghệ và Quan hệ Quốc tế, Đại học Huế

*Email: tranthaihoa@hueuni.edu.vn

Ngày nhận bài: 25/02/2026; ngày hoàn thành phản biện: 01/3/2026; ngày duyệt đăng: 16/3/2026

TÓM TẮT

Dự báo giá tiền mã hóa là một bài toán quan trọng trong phân tích tài chính do đặc tính biến động mạnh và phi tuyến của thị trường. Bitcoin, với vai trò là đồng tiền mã hóa có vốn hóa lớn nhất, đặt ra thách thức đáng kể đối với các mô hình dự báo truyền thống. Nghiên cứu này đánh giá hiệu năng của mô hình học sâu N-BEATS – với điểm mới là tận dụng kiến trúc xếp chồng khối dư (residual stacking) độc lập để tự động phân rã chuỗi thời gian – trong dự báo giá Bitcoin theo nhiều khung thời gian và so sánh với các mô hình cơ sở như CNN, LSTM, GRU, Bi-LSTM và mô hình lai. Dữ liệu được thu thập từ Yahoo Finance và xử lý bằng kỹ thuật cửa sổ trượt 30 ngày, với các khoảng thời gian dự báo 1, 3, 5 và 7 ngày. Hiệu năng được đánh giá thông qua các chỉ số MSE, RMSE, MAE và R^2 . Kết quả thực nghiệm định lượng cho thấy, tại khung 1 ngày, CNN cạnh tranh tốt với MAE đạt 1957.65 (so với 1981.51 của N-BEATS). Tuy nhiên, khi mở rộng khung thời gian, N-BEATS thể hiện sự vượt trội toàn diện và độ bền vững cao. Cụ thể, tại khung dự báo dài nhất (7 ngày), N-BEATS đạt sai số thấp nhất (RMSE = 7815.738, MAE = 6184.976) và độ phù hợp cao nhất ($R^2 = 0.919365$). Điều này cho thấy N-BEATS đạt độ chính xác cao hơn ở phần lớn các khung thời gian và duy trì mức suy giảm sai số thấp hơn khi mở rộng khoảng dự báo.

Từ khóa: Bitcoin, dự báo chuỗi thời gian, N-BEATS, học sâu.

1. MỞ ĐẦU

Trong những năm gần đây, thị trường tiền mã hóa đã phát triển nhanh chóng và trở thành một bộ phận quan trọng của hệ thống tài chính toàn cầu. Trong đó, Bitcoin là

tài sản có giá trị vốn hóa lớn nhất và mức độ giao dịch cao nhất. Tuy nhiên, giá Bitcoin có đặc tính biến động mạnh, phi tuyến và chịu ảnh hưởng của nhiều yếu tố kinh tế – xã hội, khiến bài toán dự báo trở nên phức tạp. Việc xây dựng các mô hình dự báo chính xác có ý nghĩa quan trọng đối với quản trị rủi ro, phân bổ danh mục và hỗ trợ ra quyết định đầu tư.

Các phương pháp thống kê truyền thống như ARIMA hoặc GARCH thường dựa trên giả định tuyến tính và tính dừng của chuỗi thời gian. Trong bối cảnh dữ liệu tài chính có tính phi tuyến và phụ thuộc dài hạn, các mô hình này gặp hạn chế về khả năng tổng quát hóa [1]. Sự phát triển của học sâu đã mở ra hướng tiếp cận mới cho bài toán dự báo chuỗi thời gian. Các kiến trúc như CNN, LSTM, GRU và Bi-LSTM có khả năng khai thác quan hệ phi tuyến và phụ thuộc dài hạn trong dữ liệu. Tuy nhiên, hiệu năng của các mô hình này có thể suy giảm khi mở rộng khung thời gian dự báo [2].

Gần đây, mô hình N-BEATS được đề xuất như một kiến trúc chuyên biệt cho dự báo chuỗi thời gian với cấu trúc khối dư (residual blocks) và cơ chế phân rã thành phần xu hướng và chu kỳ [3]. Kiến trúc này cho phép mô hình hóa trực tiếp quan hệ giữa đầu vào và đầu ra đa bước mà không phụ thuộc vào cấu trúc hồi tiếp truyền thống. Do đó, việc đánh giá hiệu năng của N-BEATS trong bài toán dự báo giá Bitcoin đa bước là cần thiết để xác định khả năng ứng dụng thực tiễn.

Nghiên cứu này thực hiện phân tích so sánh thực nghiệm mô hình N-BEATS với các mô hình học sâu cơ sở gồm CNN, LSTM, GRU, Bi-LSTM và mô hình lai trong bài toán dự báo giá Bitcoin đa bước thời gian. Dữ liệu được thu thập từ Yahoo Finance và được xử lý bằng kỹ thuật cửa sổ trượt 30 ngày. Bài toán được thiết lập với các khung thời gian dự báo 1 ngày, 3 ngày, 5 ngày và 7 ngày. Các mô hình được đánh giá dựa trên các chỉ số MSE, RMSE, MAE, MAPE và R^2 nhằm đảm bảo tính khách quan và định lượng.

Nghiên cứu này có bốn đóng góp chính. Thứ nhất, nghiên cứu xây dựng một khung đánh giá toàn diện cho bài toán dự báo giá Bitcoin theo nhiều khung thời gian dựa trên chiến lược cửa sổ trượt cố định, bảo đảm tính nhất quán trong thiết kế thực nghiệm. Thứ hai, nghiên cứu thực hiện so sánh định lượng giữa mô hình N-BEATS và năm mô hình học sâu cơ sở trên cùng một tập dữ liệu, qua đó đảm bảo tính công bằng và khách quan trong đánh giá hiệu năng. Thứ ba, nghiên cứu phân tích xu hướng biến động của sai số dự báo khi gia tăng độ dài khoảng thời gian dự báo, giúp làm rõ mức độ ổn định và khả năng thích ứng của các mô hình trong các khung thời gian khác nhau. Cuối cùng, nghiên cứu cung cấp bằng chứng thực nghiệm có giá trị nhằm hỗ trợ việc lựa chọn mô hình dự báo phù hợp trong thị trường tiền mã hóa.

Phần còn lại của bài báo được tổ chức như sau: Phần 2 trình bày các công trình liên quan. Phần 3 mô tả phương pháp và kiến trúc mô hình. Phần 4 trình bày thiết lập thực nghiệm và phân tích kết quả. Phần 5 đưa ra kết luận và hướng nghiên cứu tiếp theo.

2. CÁC CÔNG TRÌNH NGHIÊN CỨU LIÊN QUAN

Dự báo giá Bitcoin và các tài sản tiền mã hóa đã thu hút sự quan tâm mạnh mẽ trong những năm gần đây do đặc tính biến động cao, phi tuyến và chịu ảnh hưởng bởi nhiều yếu tố kinh tế – tâm lý [4]. Những năm gần đây, xu hướng nghiên cứu chuyển dịch rõ rệt từ các mô hình kinh tế lượng truyền thống sang các kiến trúc học sâu nhằm cải thiện khả năng mô hình hóa quan hệ phi tuyến và phụ thuộc dài hạn [5].

Trong nhóm các mô hình hồi tiếp, LSTM và GRU vẫn là những kiến trúc được sử dụng phổ biến trong dự báo tài chính. Tripathi và Sharma [6] kết hợp Bayesian optimization với mạng nơ-ron sâu để dự báo giá Bitcoin và ghi nhận cải thiện đáng kể so với các mô hình tuyến tính. El Abaji và A. Haraty [7] cho thấy việc tích hợp đặc trưng kỹ thuật và phân tích cảm xúc giúp tăng độ chính xác dự báo Bitcoin. Gülmez [8] đề xuất tối ưu cấu trúc LSTM bằng thuật toán metaheuristic và đạt cải thiện RMSE so với cấu trúc mặc định. Li và cộng sự [9] phát triển mô hình lai CEEMDAN–Informer–LSTM để xử lý chuỗi phi tuyến và không dừng, cho thấy ưu thế so với các kiến trúc đơn lẻ. Mohsin và Jamaani [10] cũng chứng minh hiệu quả của học sâu trong dự báo biến động dầu mỏ, củng cố tính phù hợp của các kiến trúc này cho dữ liệu tài chính có nhiễu cao.

Tuy nhiên, nhiều nghiên cứu chỉ ra rằng các mô hình hồi tiếp thường gặp hiện tượng tích lũy sai số khi mở rộng khung thời gian dự báo. Trong bối cảnh đó, các kiến trúc feedforward chuyên biệt cho dự báo chuỗi thời gian như N-BEATS được quan tâm đáng kể. Oreshkin và cộng sự [11] giới thiệu N-BEATS với cơ chế residual stacking và backcast–forecast, cho thấy hiệu năng vượt trội trong các bộ dữ liệu chuẩn. Sau đó, các ứng dụng thực tế trong dự báo phụ tải điện trung hạn [12] và dự báo nhu cầu điện [3] xác nhận tính ổn định và khả năng tổng quát hóa của mô hình.

Olivares và cộng sự [13] mở rộng kiến trúc N-BEATS thành NBEATSx nhằm tích hợp biến ngoại sinh trong dự báo giá điện, cho thấy cải thiện rõ rệt so với các kiến trúc hồi tiếp. Trong lĩnh vực thị trường chứng khoán, Pramanick và cộng sự [14] kết hợp wavelet decomposition với N-BEATS để xử lý tính không dừng của chuỗi và đạt mức giảm MAPE đáng kể. Sbrana và Lima de Castro [15] đề xuất N-BEATS Perceiver cho dự báo danh mục tiền mã hóa và cho thấy hiệu năng cạnh tranh với các kiến trúc RNN truyền thống.

Song song đó, hướng tối ưu hóa siêu tham số và cấu trúc N-BEATS được phát triển nhằm cải thiện độ chính xác dự báo. Lin và Wang [16] đề xuất DIGWO-N-BEATS, tích hợp thuật toán tối ưu bầy sói cải tiến để lựa chọn cấu hình tối ưu và đạt cải thiện sai số đáng kể. Các nghiên cứu khác cũng cho thấy việc điều chỉnh số block và kích thước tầng ẩn ảnh hưởng trực tiếp đến hiệu năng dự báo [3], [16].

Ngoài lĩnh vực tài chính, nhiều nghiên cứu về dự báo theo nhiều khung thời gian trong năng lượng và tài nguyên tái tạo cung cấp cơ sở phương pháp luận quan trọng.

Putz và cộng sự [17] phát triển mô hình dự báo điện gió với nhiều khung thời gian bằng mạng học sâu và chỉ ra xu hướng sai số tăng theo độ dài khung dự báo, tương tự đặc điểm trong dự báo tài sản tài chính. Wang và cộng sự [18] đánh giá các phương pháp học máy trong dự báo biến động tiền mã hóa và cho thấy mô hình học sâu có ưu thế so với các phương pháp truyền thống trong môi trường biến động cao. Alessandretti và cộng sự [19] chứng minh rằng cấu trúc mạng phi tuyến có thể khai thác hiệu quả đặc trưng động học thị trường tiền mã hóa.

Tổng hợp các nghiên cứu trước đây cho thấy: (i) mô hình học sâu thường vượt trội hơn các mô hình truyền thống về độ chính xác dự báo; (ii) các kiến trúc hồi tiếp còn hạn chế trong dự báo nhiều bước do tích lũy sai số; (iii) N-BEATS thể hiện tiềm năng mạnh mẽ trong mô hình hóa chuỗi phi tuyến; và (iv) vẫn tồn tại khoảng trống nghiên cứu trong việc đánh giá hiệu năng theo nhiều khoảng thời gian dự báo đối với Bitcoin. Đây cũng là mục tiêu trọng tâm của nghiên cứu này.

3. MỘT SỐ PHƯƠNG PHÁP DỰ BÁO CHUỖI THỜI GIAN

3.1 Tiền xử lý dữ liệu

Chuỗi dữ liệu đầu vào của nghiên cứu là giá đóng cửa Bitcoin theo ngày, được ký hiệu $\{y_1, y_2, \dots, y_T\}$, trong đó $y_t \in \mathbb{R}$ biểu diễn giá tại thời điểm t . Để chuyển đổi chuỗi thời gian này thành dạng dữ liệu phù hợp cho các mô hình học sâu, nghiên cứu áp dụng kỹ thuật cửa sổ trượt, cho phép biến bài toán dự báo chuỗi thời gian thành bài toán hồi quy có giám sát.

Với độ dài cửa sổ cố định $L = 30$, tại mỗi thời điểm $t \geq L$, vector đầu vào được xây dựng dưới biểu thức (1):

$$X_t = [y_{t-L+1}, y_{t-L+2}, \dots, y_t] \in \mathbb{R}^{30} \quad (1)$$

Lựa chọn này được căn cứ dựa trên chu kỳ giao dịch hàng tháng trọn vẹn của thị trường tiền mã hóa (hoạt động 24/7), mức thời gian này đã được chứng minh trong các nghiên cứu tiền nhiệm (Hasriadi et al. [20]; Simtharakao [21]) là đủ dài để trích xuất xu hướng, động lượng ngắn hạn, đồng thời tối ưu hóa chi phí tính toán và tránh đưa vào độ nhiễu từ các dữ liệu quá khứ xa.

Đối với bài toán dự báo đa bước với khung thời gian $h \in \{1, 3, 5, 7\}$, vector đầu ra tương ứng được xác định bằng biểu thức (2):

$$Y_t^{(h)} = [y_{t+1}, y_{t+2}, \dots, y_{t+h}] \in \mathbb{R}^h \quad (2)$$

Như vậy, mô hình học ánh xạ $f_\theta = \mathbb{R}^{30} \rightarrow \mathbb{R}^h$, trong đó θ là tập tham số cần tối ưu. Sau mỗi bước thời gian, cửa sổ dịch sang phải một đơn vị để tạo mẫu mới dưới công thức (3):

$$X_{t+1} = [y_{t-L+2}, \dots, y_{t+1}] \quad (3)$$

Cơ chế dịch chuyển tuần tự này cho phép khai thác tối đa thông tin lịch sử và gia tăng số lượng mẫu huấn luyện mà vẫn đảm bảo toàn cấu trúc thời gian của dữ liệu.

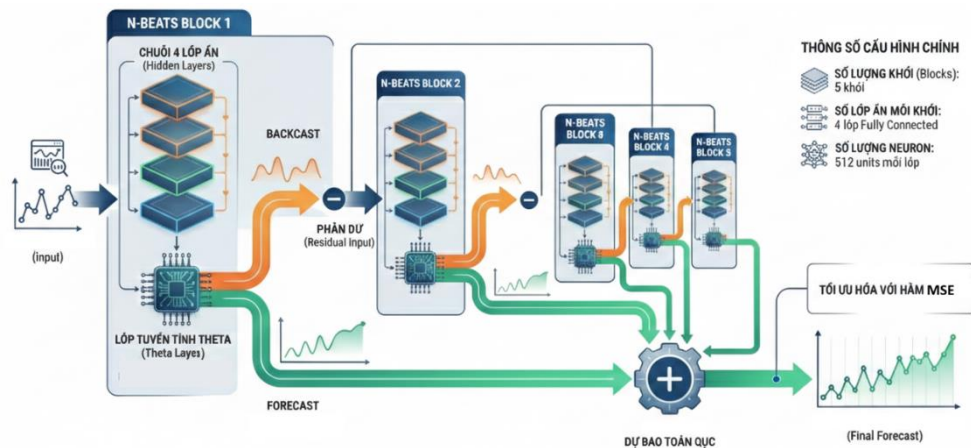
Trước khi tạo cửa sổ trượt, dữ liệu được chuẩn hóa bằng phương pháp Min–Max Scaling, giúp đưa dữ liệu về cùng thang đo $[0, 1]$, như công thức ((4):

$$x'_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (4)$$

Trong đó, x_i là giá trị thực tế, các giá trị x_{min} và x_{max} chỉ được tính toán duy nhất trên tập dữ liệu huấn luyện (Training set). Sau đó, hai tham số này mới được sử dụng để chuẩn hóa tập kiểm tra (Test set), nhằm đảm bảo tuyệt đối không xảy ra hiện tượng rò rỉ thông tin tương lai (data leakage) làm sai lệch kết quả đánh giá mô hình. Dữ liệu được chia theo tỷ lệ 80%–20% theo thứ tự thời gian nhằm đảm bảo không rò rỉ thông tin tương lai.

3.2 Kiến trúc N-BEATS

N-BEATS (Neural Basis Expansion Analysis for Time Series Forecasting) là một kiến trúc mạng thần kinh feedforward được thiết kế chuyên biệt cho dự báo chuỗi thời gian [11]. Khác với các mô hình hồi tiếp như LSTM hoặc GRU, N-BEATS không sử dụng trạng thái ẩn tuần tự mà học trực tiếp ánh xạ toàn cục giữa vector đầu vào và vector dự báo đầu ra. Kiến trúc này đặc biệt phù hợp cho dự báo đa bước trực tiếp, trong đó toàn bộ khung thời gian dự báo được tối ưu đồng thời. Kiến trúc mô hình N-BEATS trong nghiên cứu được đề xuất như **Hình 1**.



Hình 1. Kiến trúc N-BEATS đề xuất dự báo giá Bitcoin với nhiều khung dự báo

Giả sử đầu vào của mô hình là vector $X_t \in R^{30}$ được xây dựng từ cửa sổ trượt 30 ngày gần nhất. Mục tiêu là ước lượng vector dự báo $Y_t^{(h)} \in R^h$, với $h \in \{1,3,5,7\}$. N-BEATS

thực hiện ánh xạ: $f_\theta = \mathbb{R}^{30} \rightarrow \mathbb{R}^h$, trong đó θ là tập tham số của toàn bộ mạng.

Kiến trúc N-BEATS được xây dựng theo cơ chế xếp chồng các khối (stack of blocks). Mỗi block là một mạng fully connected sâu, bao gồm nhiều lớp tuyến tính liên tiếp với hàm kích hoạt ReLU. Tại block thứ k , phần dư đầu vào được ký hiệu là R_{k-1} . Block thực hiện ánh xạ như công thức (5):

$$\theta_k = f_k(R_{k-1}) \quad (5)$$

trong đó f_k là mạng fully connected của block thứ k , và θ_k là vector tham số trung gian. Từ θ_k , hai nhánh đầu ra được xây dựng: backcast và forecast. Thành phần backcast được định nghĩa như công thức (6):

$$\hat{X}_k = B_k(\theta_k) \in \mathbb{R}^{30} \quad (6)$$

Thành phần forecast được định nghĩa theo công thức (7):

$$\hat{Y}_k = F_k(\theta_k) \in \mathbb{R}^h \quad (7)$$

Phần dư được cập nhật theo cơ chế residual như công thức (8):

$$R_k = R_{k-1} - \hat{X}_k \quad (8)$$

Dự báo cuối cùng của mô hình được tính bằng tổng các forecast từ tất cả các block như công thức (9):

$$\hat{Y} = \sum_{k=1}^K \hat{Y}_k \quad (9)$$

Cơ chế residual stacking này giúp mô hình phân rã dần tín hiệu đầu vào thành các thành phần tiềm ẩn, cho phép mỗi block học các cấu trúc khác nhau của chuỗi thời gian. Điều này đặc biệt quan trọng đối với dữ liệu tài chính có tính phi tuyến và biến động mạnh như Bitcoin.

Trong thực nghiệm này, kiến trúc N-BEATS được cấu hình: gồm $K = 5$ khối xếp chồng; mỗi block chứa 4 lớp fully connected; mỗi lớp gồm 512 neuron; hàm kích hoạt sử dụng ReLU; kích thước backcast cố định bằng 30; kích thước forecast tương ứng với từng khung thời gian dự báo h . Thuật toán tối ưu sử dụng Adam với tốc độ học 0,001; batch size 64; số epoch tối đa 50; áp dụng cơ chế early stopping dựa trên validation loss nhằm tránh quá khớp.

Hàm mất mát được sử dụng trong huấn luyện là MSE theo công thức (10):

$$\mathcal{L}(\theta) = \frac{1}{n} \sum_{i=1}^n \|Y_i - \hat{Y}_i\|^2 \quad (10)$$

Việc tối ưu trực tiếp vector dự báo đa bước thay vì dự báo tuần tự từng bước giúp N-BEATS hạn chế hiện tượng tích lũy sai số, vốn thường xảy ra trong các kiến trúc hồi tiếp truyền thống. Ngoài ra, do sử dụng mạng fully connected thay vì cấu trúc tuần

tự, mô hình có thể khai thác toàn bộ thông tin trong cửa sổ đầu vào một cách đồng thời, từ đó tăng khả năng học các quan hệ phi tuyến phức tạp trong chuỗi giá Bitcoin.

3.3 Các mô hình cơ sở

Để đánh giá khách quan hiệu năng của N-BEATS trong bài toán dự báo giá Bitcoin đa bước, nghiên cứu triển khai một tập các mô hình học sâu phổ biến làm đối chứng (baseline). Các mô hình này đại diện cho các kiến trúc được sử dụng rộng rãi trong dự báo chuỗi thời gian tài chính, bao gồm mô hình tích chập, mô hình hồi tiếp và mô hình lai. Tất cả các mô hình được huấn luyện trên cùng tập dữ liệu, cùng kỹ thuật cửa sổ trượt và cùng cấu hình chia tập nhằm đảm bảo tính công bằng trong so sánh.

Mô hình 1D-CNN được sử dụng để khai thác đặc trưng cục bộ trong chuỗi thời gian thông qua các bộ lọc tích chập trượt trên trục thời gian [22]. Kiến trúc 1D-CNN bao gồm một lớp tích chập một chiều (Conv1D) sử dụng 64 bộ lọc (filters) kết hợp hàm kích hoạt ReLU, theo sau là một lớp kết nối đầy đủ (FC) với 50 đơn vị ẩn. Cấu trúc này cho phép mô hình nhận diện các mẫu (patterns) cơ bản trong chuỗi dữ liệu ở lớp đầu tiên, trước khi truyền qua lớp FC để tổng hợp thông tin và đưa ra dự đoán cuối cùng. CNN có ưu điểm về khả năng song song hóa và chi phí tính toán thấp, tuy nhiên hạn chế trong việc mô hình hóa phụ thuộc dài hạn.

Mô hình LSTM được triển khai nhằm khai thác phụ thuộc thời gian dài thông qua cơ chế cổng gồm input gate, forget gate và output gate. Với đầu vào dạng chuỗi 30 bước thời gian, LSTM duy trì trạng thái ẩn h_t và trạng thái bộ nhớ c_t để cập nhật thông tin tuần tự. Trong nghiên cứu này, kiến trúc LSTM được xây dựng chuyên biệt để xử lý dữ liệu chuỗi có tính phụ thuộc dài hạn thông qua cấu trúc xếp chồng gồm 2 tầng ẩn liên tiếp. Mỗi tầng ẩn chứa 50 khối LSTM và sử dụng hàm kích hoạt Tanh mặc định của cấu trúc cổng chuẩn, cho phép mô hình điều chỉnh hiệu quả luồng thông tin đi qua các trạng thái tế bào (cell states) để ghi nhớ các đặc điểm quan trọng theo thời gian.

Mô hình GRU được sử dụng như một biến thể đơn giản hơn của LSTM. GRU kết hợp reset gate và update gate để kiểm soát luồng thông tin mà không cần tách riêng trạng thái bộ nhớ. Nhờ số lượng tham số ít hơn, GRU có tốc độ huấn luyện nhanh hơn LSTM trong khi vẫn duy trì khả năng học phụ thuộc thời gian. Trong thực nghiệm, GRU cũng được thiết kế với 2 tầng ẩn xếp chồng lên nhau. Mỗi tầng của mô hình bao gồm 50 đơn vị GRU, áp dụng hàm kích hoạt Tanh mặc định để kiểm soát luồng thông tin, giúp mô hình xử lý chuỗi dữ liệu thời gian một cách hiệu quả trong khi tối ưu hóa được khối lượng tính toán nội bộ.

Mô hình Bi-LSTM được thiết kế nhằm khai thác thông tin theo cả hai chiều thời gian trong phạm vi cửa sổ 30 ngày. Là phiên bản nâng cấp của mạng LSTM truyền thống, mô hình Bi-LSTM cho phép học thông tin ngữ cảnh từ cả hai chiều của chuỗi dữ liệu (từ quá khứ đến tương lai và ngược lại) thông qua 2 tầng ẩn. Tính hai chiều này được thể

hiện bằng việc cung cấp 50 đơn vị ẩn cho mỗi chiều quét trong từng tầng, kết hợp cùng hàm kích hoạt Tanh mặc định ở các cổng tính toán để nắm bắt toàn diện xu hướng của chuỗi thời gian.

Mô hình lai CNN-LSTM được xây dựng nhằm kết hợp ưu điểm của hai kiến trúc. Kiến trúc mô hình bắt đầu bằng lớp Conv1D (gồm 64 bộ lọc và hàm kích hoạt ReLU) đóng vai trò trích xuất đặc trưng để làm nổi bật tín hiệu quan trọng và giảm nhiễu từ chuỗi dữ liệu thô. Ngay sau đó, chuỗi đặc trưng đã được tinh lọc sẽ được đưa vào một lớp LSTM chứa 50 đơn vị ẩn sử dụng hàm kích hoạt Tanh, giúp mô hình học các phụ thuộc về mặt thời gian trên nền dữ liệu chất lượng cao trước khi đưa ra kết quả.

Tất cả các mô hình cơ sở được huấn luyện độc lập cho từng khung thời gian dự báo $h \in \{1,3,5,7\}$. Hàm mất mát sử dụng là Mean Squared Error và thuật toán tối ưu là Adam với tốc độ học cố định. Việc huấn luyện riêng cho từng horizon đảm bảo mỗi mô hình tối ưu trực tiếp ánh xạ từ \mathbb{R}^{30} sang \mathbb{R}^h , thay vì dự báo tuần tự từng bước. Cách tiếp cận này giúp đảm bảo tính công bằng trong so sánh với kiến trúc N-BEATS.

Việc lựa chọn các mô hình cơ sở nêu trên phản ánh ba nhóm kiến trúc chính trong dự báo chuỗi thời gian: mạng tích chập, mạng hồi tiếp và mô hình lai. Điều này cho phép đánh giá toàn diện ưu thế của N-BEATS so với các phương pháp học sâu phổ biến trong bối cảnh dữ liệu tiền mã hóa có tính phi tuyến và biến động cao.

3.4 Chỉ số đánh giá mô hình

Để đánh giá toàn diện hiệu năng của các mô hình dự báo giá Bitcoin đa bước, nghiên cứu sử dụng đồng thời bốn chỉ số phổ biến trong bài toán hồi quy chuỗi thời gian gồm MSE, RMSE, MAE và hệ số xác định R^2 . Các chỉ số đánh giá được xác định bởi công thức (11) (14):

$$MSE(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (11)$$

$$MAE(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (12)$$

$$RMSE(y, \hat{y}) = \sqrt{MSE(y, \hat{y})} \quad (13)$$

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (14)$$

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

4. THỰC NGHIỆM VÀ THẢO LUẬN KẾT QUẢ

Dữ liệu giá Bitcoin được thu thập từ Yahoo Finance bao gồm 3850 mẫu quan sát (từ ngày 17/09/2014 đến ngày 01/04/2025). Tập dữ liệu sau đó được chia theo tỷ lệ 80% cho huấn luyện và 20% cho kiểm tra (trùng ứng với 770 ngày cuối cùng). Trước khi tiến hành chuẩn hóa bằng phương pháp Min-Max Scaler, chuỗi dữ liệu gốc đã được rà soát để xử lý các giá trị khuyết thiếu (missing values) thông qua phương pháp nội suy tuyến tính, đồng thời kiểm tra và xử lý các giá trị ngoại lai (outliers) nhằm loại bỏ nhiễu. Các mẫu dữ liệu được xây dựng bằng kỹ thuật cửa sổ trượt 30 ngày. Bài toán được thiết lập với bốn khung thời gian dự báo gồm 1 ngày, 3 ngày, 5 ngày và 7 ngày. Mỗi mô hình được huấn luyện độc lập cho từng khung thời gian nhằm đảm bảo tối ưu hóa trực tiếp mục tiêu dự báo đa bước. Hiệu năng của các mô hình được đánh giá trên tập kiểm tra thông qua các chỉ số MSE, RMSE, MAE, MAPE và hệ số xác định R2. Kết quả định lượng chi tiết của các mô hình được trình bày trong *Bảng 1*.


Bảng 1. Kết quả so sánh hiệu năng dự báo của các mô hình với thời gian 1, 3, 5 và 7 ngày

Cấu hình dự báo	Mô hình	MAE	MSE	RMSE	R2
<i>1 ngày</i>	Bi-LSTM	3599.601	21839110	4673.233	0.971612
	CNN	1957.651	7406299	2721.452	0.990373
	GRU	2014.681	7495670	2737.822	0.990257
	Hybrid	3828.093	27084580	5204.285	0.964794
	LSTM	1987.804	7367247	2714.267	0.990424
	N-BEATS	1981.51	6790470	2605.853	0.991173
<i>3 ngày</i>	Bi-LSTM	6207.927	66554910	8158.119	0.913044
	CNN	4907.846	39766480	6306.067	0.948044
	GRU	4695.167	35908890	5992.403	0.953084
	Hybrid	7360.829	91133710	9546.398	0.880931
	LSTM	5624.316	52110250	7218.743	0.931916
	N-BEATS	2469.875	11218300	3349.372	0.985343
<i>5 ngày</i>	Bi-LSTM	7271.569	90957880	9537.184	0.880537
	CNN	4860.473	41159030	6415.531	0.945942
	GRU	5367.159	48124070	6937.152	0.936794
	Hybrid	7754.322	1.06E+08	10276.73	0.861292
	LSTM	5911.544	58483350	7647.44	0.923189

	N-BEATS	3166.902	18043510	4247.765	0.976302
7 ngày	Bi-LSTM	13064.36	2.84E+08	16866.89	0.624462
	CNN	8718.732	1.19E+08	10908.04	0.842936
	GRU	6105.781	62820650	7925.948	0.917075
	Hybrid	11539.53	2.2E+08	14831.76	0.709618
	LSTM	7382.363	91993540	9591.326	0.878566
	N-BEATS	6184.976	61085750	7815.738	0.919365

Từ **Bảng 1** có thể quan sát thấy sai số dự báo tăng dần khi mở rộng khung thời gian dự báo. Đây là xu hướng phổ biến trong các bài toán dự báo chuỗi thời gian do mức độ bất định tăng theo thời gian. Tuy nhiên, mức gia tăng sai số giữa các mô hình là khác nhau.

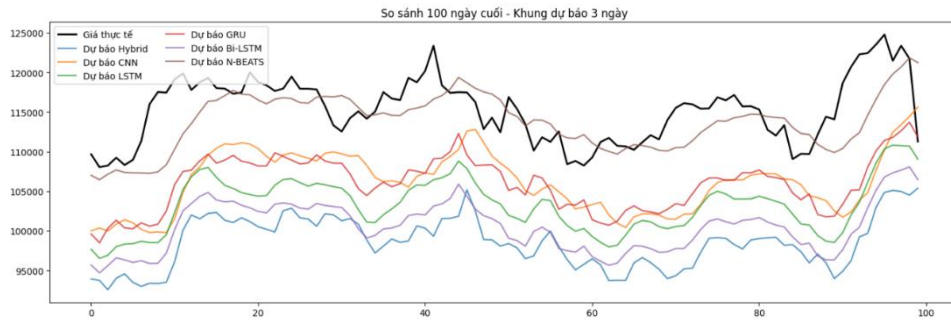
Trong khung thời gian dự báo 1 ngày, các mô hình đều cho thấy khả năng bám sát biến động giá khá tốt. Đáng chú ý, mô hình CNN thể hiện sự cạnh tranh rất tốt khi đạt chỉ số MAE thấp nhất (1957.651), nhỉnh hơn đôi chút so với N-BEATS (1981.51). Điều này cho thấy kiến trúc mạng tích chập có ưu thế trong việc trích xuất các đặc trưng biến động cục bộ ngắn hạn. Tuy nhiên, khi xét trên tổng thể các chỉ số chịu ảnh hưởng nhiều bởi các sai số lớn (MSE, RMSE) và độ phù hợp (R^2), N-BEATS vẫn cho thấy sự ổn định. Đặc biệt, sự vượt trội của N-BEATS chỉ thực sự trở nên rõ rệt và toàn diện khi khung thời gian dự báo được mở rộng ra 3, 5 và 7 ngày.



Hình 2. So sánh giá trị dự báo và giá trị thực tế tại khung thời gian 1 ngày

Từ **Hình 2**, có thể thấy đường dự báo của N-BEATS bám sát diễn biến thực tế hơn trong các giai đoạn biến động mạnh, trong khi một số mô hình hồi tiếp xuất hiện độ trễ pha.


Khi tăng thời gian dự báo lên 3 ngày, sai số của tất cả các mô hình đều tăng. Tuy nhiên, theo **Bảng 1**, mức tăng RMSE và MAE của N-BEATS thấp hơn so với CNN, LSTM và GRU. Điều này cho thấy kiến trúc residual stacking giúp hạn chế tích lũy sai số khi dự báo đa bước.



Hình 3. So sánh giá trị dự báo và giá trị thực tế tại khung thời gian 3 ngày

Quan sát **Hình 3** cho thấy các mô hình hồi tiếp có xu hướng làm mượt tín hiệu, dẫn đến sai lệch trong các giai đoạn biến động mạnh. Trong khi đó, N-BEATS duy trì độ bám sát xu hướng tốt hơn.

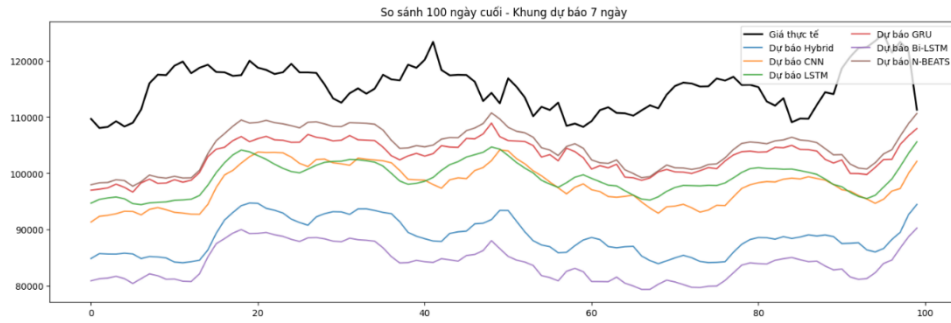
Với khung dự báo 5 ngày, sự khác biệt giữa các mô hình trở nên rõ rệt hơn. Sai số MAE của các mô hình cơ sở tăng đáng kể. N-BEATS tiếp tục đạt RMSE thấp nhất và hệ số R^2 cao hơn so với phần lớn các mô hình so sánh. Điều này cho thấy khả năng học trực tiếp quan hệ đầu vào – đầu ra đa bước giúp mô hình giảm hiện tượng lan truyền sai số.



Hình 4. So sánh giá trị dự báo và giá trị thực tế tại khung thời gian 5 ngày

Hình 4 cho thấy các mô hình hồi tiếp có xu hướng lệch khỏi xu hướng thực tế trong các giai đoạn đảo chiều mạnh, trong khi N-BEATS thể hiện độ ổn định cao hơn.

Ở khung dự báo 7 ngày, sai số tiếp tục tăng ở tất cả các mô hình do mức độ bất định cao của thị trường tiền mã hóa. Tuy nhiên, theo **Bảng 1**, N-BEATS vẫn duy trì giá trị RMSE và MAE thấp nhất trong nhóm mô hình được so sánh. Mặc dù hệ số R^2 giảm so với các khoảng thời gian dự báo ngắn hơn, mức suy giảm của N-BEATS thấp hơn so với các mô hình hồi tiếp truyền thống.



Hình 5. So sánh giá trị dự báo và giá trị thực tế tại khung thời gian 7 ngày

Từ *Hình 5* có thể nhận thấy sai lệch dự báo của các mô hình cơ sở tăng rõ rệt khi xuất hiện biến động đột ngột, trong khi N-BEATS vẫn giữ được xu hướng tổng thể tốt hơn.

Tổng hợp các kết quả thực nghiệm cho thấy: (i) sai số tăng theo độ dài khoảng thời gian dự báo; (ii) N-BEATS đạt giá trị MSE, RMSE và MAE thấp nhất ở phần lớn các khoảng thời gian dự báo; (iii) hệ số R^2 của N-BEATS cao hơn so với các mô hình cơ sở; và (iv) mức suy giảm hiệu năng của N-BEATS khi tăng thời gian dự báo thấp hơn so với các kiến trúc hồi tiếp.

Nguyên nhân N-BEATS duy trì được độ ổn định khi mở rộng khung thời gian là nhờ kiến trúc gồm nhiều khối dư xếp chồng lên nhau. Khác với LSTM hay GRU dễ bị triệt tiêu gradient khi dự báo dài hạn, cơ chế backcast và forecast của N-BEATS cho phép mô hình liên tục tách bóc và học các thành phần xu hướng (trend) và tính chu kỳ (seasonality) độc lập, từ đó bám sát tốt hơn các nhịp đảo chiều của thị trường.

Những kết quả này cho thấy mô hình N-BEATS là lựa chọn phù hợp cho bài toán dự báo giá Bitcoin đa bước ngắn hạn trong bối cảnh dữ liệu chuỗi thời gian có tính biến động cao.

5. KẾT LUẬN

Nghiên cứu đã xây dựng và đánh giá mô hình N-BEATS cho bài toán dự báo giá Bitcoin theo nhiều khung thời gian (1, 3, 5 và 7 ngày) dựa trên dữ liệu từ Yahoo Finance và kỹ thuật cửa sổ trượt 30 ngày. Kết quả thực nghiệm cho thấy N-BEATS đạt hiệu năng tốt hơn so với các mô hình học sâu cơ sở như CNN, LSTM, GRU, Bi-LSTM và hybrid trên phần lớn các khoảng thời gian dự báo, thể hiện qua các chỉ số MSE, RMSE, MAE, MAPE và R^2 . Mặc dù sai số tăng khi mở rộng khoảng dự báo, mức suy giảm của N-BEATS thấp hơn so với các kiến trúc mô hình cơ sở khác. Tuy nhiên, nghiên cứu còn một số hạn chế: chỉ sử dụng dữ liệu đơn biến (giá đóng cửa), chưa tích hợp biến ngoại sinh; quá trình lựa chọn siêu tham số chưa tối ưu hóa tự động ở quy mô lớn; và phạm vi đánh giá giới hạn trên một tài sản và một giai đoạn dữ liệu. Thêm vào đó, nghiên cứu

này mới chỉ sử dụng các độ đo sai số trung bình (MAE, RMSE, MSE) mà chưa thực hiện các kiểm định thống kê chuyên sâu (ví dụ: kiểm định Diebold-Mariano) để đánh giá mức độ ý nghĩa thống kê về sự khác biệt hiệu năng giữa N-BEATS và các mô hình đối chứng. Trong tương lai, việc mở rộng sang mô hình đa biến, tối ưu siêu tham số bằng thuật toán metaheuristic và kiểm chứng trên nhiều tài sản có thể giúp nâng cao khả năng tổng quát hóa của mô hình.

LỜI CẢM ƠN

Nghiên cứu được tài trợ bởi Trường Đại học Khoa học, Đại học Huế trong khuôn khổ đề tài mã số **ĐHKH2026D-002** dành cho nghiên cứu sinh.

TÀI LIỆU THAM KHẢO

- [1] M. T. Gholami and A. Shahabi, "Comparison of deep learning methods with traditional financial time series models for forecasting the TEPIX index in the Tehran Stock Exchange," *Syst. Soft Comput.*, vol. 7, p. 200395, Dec. 2025, doi: 10.1016/j.sasc.2025.200395.
- [2] A. Yunita *et al.*, "Performance analysis of neural network architectures for time series forecasting: A comparative study of RNN, LSTM, GRU, and hybrid models," *MethodsX*, vol. 15, p. 103462, Jul. 2025, doi: 10.1016/j.mex.2025.103462.
- [3] M. Kasprzyk, P. Pełka, B. N. Oreshkin, and G. Dudek, "Enhanced N-BEATS for mid-term electricity demand forecasting," *Appl. Soft Comput.*, vol. 182, p. 113575, Oct. 2025, doi: 10.1016/j.asoc.2025.113575.
- [4] M. Lin, Y. Liu, and V. N. K. Sheng, "Analysis of the impact of macroeconomic factors on cryptocurrency returns - Based on quantile regression study," *Int. Rev. Econ. Finance*, vol. 97, p. 103757, Jan. 2025, doi: 10.1016/j.iref.2024.103757.
- [5] J. Kim, H. Kim, H. Kim, D. Lee, and S. Yoon, "A comprehensive survey of deep learning for time series forecasting: architectural diversity and open challenges," *Artif. Intell. Rev.*, vol. 58, no. 7, p. 216, Apr. 2025, doi: 10.1007/s10462-025-11223-9.
- [6] B. Tripathi and R. K. Sharma, "Modeling Bitcoin Prices using Signal Processing Methods, Bayesian Optimization, and Deep Neural Networks," *Comput. Econ.*, pp. 1–27, Oct. 2022, doi: 10.1007/s10614-022-10325-8.
- [7] M. El Abaji and R. A. Haraty, "Enhancing Bitcoin Forecast Accuracy by Integrating AI, Sentiment Analysis, and Financial Models," *Int. J. Comput. Digit. Syst.*, vol. 17, no. 1, pp. 1–15, Jan. 2025, doi: 10.12785/ijcds/1571026011.
- [8] B. Gülmez, "Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm," *Expert Syst. Appl.*, vol. 227, p. 120346, Oct. 2023, doi: 10.1016/j.eswa.2023.120346.
- [9] J.-C. Li, L.-P. Sun, X. Wu, and C. Tao, "Enhancing financial time series forecasting with hybrid Deep Learning: CEEMDAN-Informer-LSTM model," *Appl. Soft Comput.*, vol. 177, p. 113241, Jun. 2025, doi: 10.1016/j.asoc.2025.113241.

- [10] M. Mohsin and F. Jamaani, "A novel deep-learning technique for forecasting oil price volatility using historical prices of five precious metals in context of green financing – A comparison of deep learning, machine learning, and statistical models," *Resour. Policy*, vol. 86, p. 104216, Oct. 2023, doi: 10.1016/j.resourpol.2023.104216.
- [11] B. N. Oreshkin, D. Carпов, N. Chapados, and Y. Bengio, "N-BEATS: Neural basis expansion analysis for interpretable time series forecasting," Feb. 20, 2020, *arXiv*: arXiv:1905.10437. doi: 10.48550/arXiv.1905.10437.
- [12] B. N. Oreshkin, G. Dudek, P. Pełka, and E. Turkina, "N-BEATS neural network for mid-term electricity load forecasting," *Appl. Energy*, vol. 293, p. 116918, Jul. 2021, doi: 10.1016/j.apenergy.2021.116918.
- [13] K. G. Olivares, C. Challu, G. Marcjasz, R. Weron, and A. Dubrawski, "Neural basis expansion analysis with exogenous variables: Forecasting electricity prices with NBEATSx," *Int. J. Forecast.*, vol. 39, no. 2, pp. 884–900, Apr. 2023, doi: 10.1016/j.ijforecast.2022.03.001.
- [14] N. Pramanick, V. Singhal, Neeraj, J. Mathew, and M. Agarwal, "Fusion of Wavelet Decomposition and N-BEATS for Improved Stock Market Forecasting," *SN Comput. Sci.*, vol. 5, no. 7, p. 869, Sep. 2024, doi: 10.1007/s42979-024-03222-4.
- [15] A. Sbrana and P. A. Lima de Castro, "N-BEATS Perceiver: A Novel Approach for Robust Cryptocurrency Portfolio Forecasting," *Comput. Econ.*, vol. 64, no. 2, pp. 1047–1081, Aug. 2024, doi: 10.1007/s10614-023-10470-8.
- [16] H. Lin and C. Wang, "DIGWO-N-BEATS: An evolutionary time series prediction method for situation prediction," *Inf. Sci.*, vol. 664, p. 120316, Apr. 2024, doi: 10.1016/j.ins.2024.120316.
- [17] D. Putz, M. Gumhalter, and H. Auer, "A novel approach to multi-horizon wind power forecasting based on deep neural architecture," *Renew. Energy*, vol. 178, pp. 494–505, Nov. 2021, doi: 10.1016/j.renene.2021.06.099.
- [18] Y. Wang, G. Andreeva, and B. Martin-Barragan, "Machine learning approaches to forecasting cryptocurrency volatility: Considering internal and external determinants," *Int. Rev. Financ. Anal.*, vol. 90, p. 102914, Nov. 2023, doi: 10.1016/j.irfa.2023.102914.
- [19] L. Alessandretti, A. ElBahrawy, L. M. Aiello, and A. Baronchelli, "Anticipating Cryptocurrency Prices Using Machine Learning," *Complexity*, vol. 2018, no. 1, p. 8983590, 2018, doi: 10.1155/2018/8983590.
- [20] H. Hasriadi, M. Razak, and A. Jalil, "Analysis of Cryptocurrency Candlestick Patterns using Gramian Angular Field and Hybrid Deep Learning," *Sist. J. Sist. Inf.*, vol. 15, no. 2, pp. 546–557, Feb. 2026, doi: 10.32520/stmsi.v15i2.5883.
- [21] S. Simtharakao, "Bitcoin candlestick price prediction with recurrent neural network," Bangkok, Thailand, 2022. doi: 10.58837/CHULA.THE.2022.196.
- [22] "A Novel Compact 1D-CNN Architecture for Short-Term Stock Price Prediction: A Case Study on Apple Stock Prices," 2025, *ICIC International 学会*: 5. doi: 10.24507/ijicic.21.05.1401.

EXPERIMENTAL ANALYSIS OF THE N-BEATS MODEL FOR MULTI-HORIZON BITCOIN PRICE FORECASTING

Tran Thai Hoa^{1,2*}, Duong Duc Hung^{2,3}, Nguyen Thanh Nam², Hoang Bao Khanh²

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

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

³ Department of Science Technology and International Cooperation, Hue University

*Email: tranthaihoa@hueuni.edu.vn

ABSTRACT

Cryptocurrency price forecasting is a critical task in financial analysis due to the highly volatile and non-linear nature of the market. Bitcoin, as the cryptocurrency with the largest market capitalization, poses a significant challenge to traditional forecasting models. This study evaluates the performance of the N-BEATS deep learning model, highlighting its novelty in leveraging an independent residual stacking architecture to automatically decompose time series for forecasting Bitcoin prices across multiple time horizons, and compares it with baseline models including CNN, LSTM, GRU, Bi-LSTM, and a hybrid model. Data was collected from Yahoo Finance and processed using a 30-day sliding window technique for forecasting horizons of 1, 3, 5, and 7 days. Model performance was evaluated using MSE, RMSE, MAE, and R^2 metrics. Quantitative empirical results indicate that at the 1-day horizon, CNN is highly competitive, achieving an MAE of 1957.65 (compared to 1981.51 for N-BEATS). However, as the time horizon increases, N-BEATS demonstrates superior performance and robustness. Specifically, at the longest forecasting horizon (7 days), N-BEATS achieves the lowest error rates (RMSE = 7815.738, MAE = 6184.976) and the highest goodness-of-fit ($R^2 = 0.919365$). This demonstrates that N-BEATS achieves higher accuracy across most time horizons and exhibits lower error degradation as the forecasting window is extended.

Keywords: Bitcoin, time series forecasting, N-BEATS, deep learning.