

USING LSTM DEEP LEARNING MODEL IN STOCK PRICE PREDICTION**Tran Quang Quy^{1*}, Nguyen Vu Hai¹, Ha Van Ninh¹, Nguyen Thi Thuy²**¹TNU - University of Information and Communication Technology²Department of Education and Training of Thai Nguyen City

ARTICLE INFO		ABSTRACT
Received:	14/11/2024	In recent times, the stock market has attracted a diverse range of participants, from organizations to financial experts, each employing different investment strategies. The common objective of investors is to maximize returns through investment. While various prediction methods have been proposed to mitigate risks, the application of artificial intelligence in stock price prediction continues to garner attention and research interest. Particularly, predicting time series data with irregular, non-seasonal characteristics, such as stock price data, remains a challenging task. This paper presents a method utilizing the Long Short-Term Memory deep learning model for stock price prediction and provides a comprehensive review of this model. The results indicate that the proposed method can predict stock price trends of adjusted closing prices with a root mean square error of 0.1387 and mean absolute error of 0.1007. Although the Long Short-Term Memory method may not achieve highly accurate predictions, it can offer a reasonably close approximation to real-world data trends.
Revised:	18/12/2024	
Published:	18/12/2024	
KEYWORDS		
Deep learning		
Time series data		
Long Short-Term Memory		
Stock price prediction		
Recurrent Neural Network		

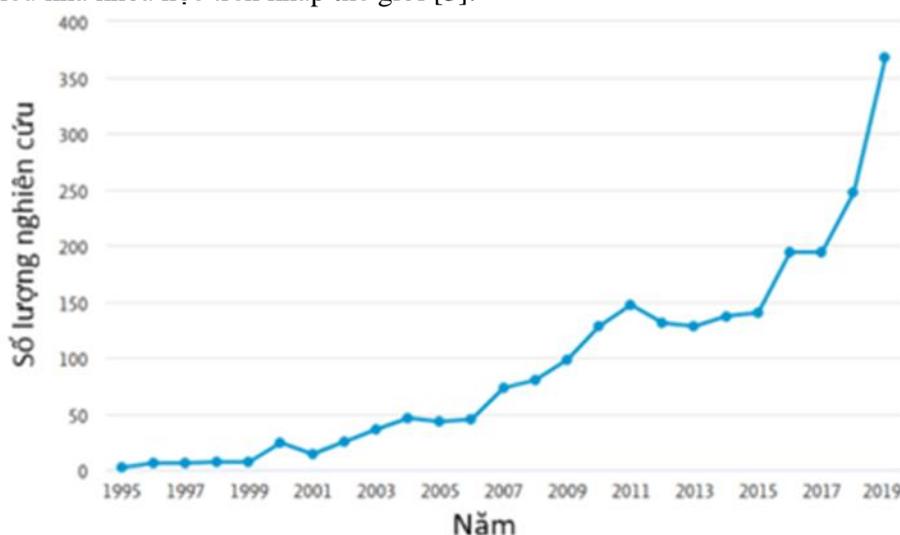
SỬ DỤNG MÔ HÌNH HỌC SÂU LSTM TRONG DỰ ĐOÁN GIÁ TRỊ CỔ PHIẾU**Trần Quang Quý^{1*}, Nguyễn Vũ Hải¹, Hà Văn Ninh¹, Nguyễn Thị Thúy²**¹Trường Đại học Công nghệ thông tin và Truyền thông - ĐH Thái Nguyên²Phòng Giáo dục và Đào tạo thành phố Thái Nguyên

THÔNG TIN BÀI BÁO	TÓM TẮT
Ngày nhận bài: 14/11/2024	Trong thời gian gần đây, thị trường chứng khoán đã thu hút nhiều đối tượng khác nhau, từ những tổ chức và các chuyên gia tài chính với các cách thức đầu tư khác nhau. Mục tiêu chung của nhà đầu tư là gia tăng lợi nhuận nhờ việc đầu tư. Nhiều cách thức về dự đoán đảm bảo rủi ro đã được đề xuất, tuy nhiên sử dụng trí tuệ nhân tạo trong dự đoán giá trị cổ phiếu vẫn được quan tâm và nghiên cứu. Đặc biệt, việc dự đoán dữ liệu chuỗi thời gian trở nên thách thức khi dữ liệu mang tính bất thường, không tuân theo quy luật cố định, điển hình là dữ liệu giá trị cổ phiếu, với các biến động khó lường và không theo mô hình định trước. Bài báo đưa ra phương pháp sử dụng mô hình học sâu Long Short-Term Memory trong dự đoán giá trị cổ phiếu và nghiên cứu tổng quan về mô hình này. Kết quả bài báo có thể dự đoán được xu hướng giá trị cổ phiếu của giá đóng điều chỉnh với sai số độ lệch bình phương trung bình gốc, sai số tuyệt đối trung bình lần lượt là 0,1387 và 0,1007. Tuy phương pháp Long Short-Term Memory không thể dự đoán giá trị cổ phiếu ở mức độ chính xác cao nhưng có thể cung cấp một kết quả theo xu hướng gần đúng so với dữ liệu thực tế.
Ngày hoàn thiện: 18/12/2024	
Ngày đăng: 18/12/2024	
TỪ KHÓA	
Học sâu	
Dữ liệu chuỗi thời gian	
Long Short-Term Memory	
Dự đoán giá trị cổ phiếu	
Mạng nơ ron hồi quy	

DOI: <https://doi.org/10.34238/tnu-jst.11554>* Corresponding author. Email: tqquy@ictu.edu.vn

1. Giới thiệu

Dự đoán dữ liệu chuỗi thời gian nói chung và dự đoán giá trị cổ phiếu nói riêng luôn gặp phải các thách thức lớn khi dự đoán xu hướng, các bất thường đặc trưng của cổ phiếu [1]. Dự báo lợi nhuận cổ phiếu, đặc biệt là tỷ suất sinh lời [2], có tác động đáng kể đến quyết định kinh doanh của các nhà đầu tư, góp phần định hướng chiến lược và tối ưu hóa hiệu quả đầu tư. Từ đó, việc dự đoán giá trị cổ phiếu vẫn là một trong những công việc cấp thiết bằng nhiều phương pháp và hình thức khác nhau. Trong mọi lĩnh vực của đời sống hiện nay, trí tuệ nhân tạo đã được ứng dụng như một phương pháp mang lại hiệu quả vượt trội. Hình 1 cho thấy từ năm 1995 đến 2019, việc áp dụng trí tuệ nhân tạo trong cổ phiếu luôn là vấn đề nhận được sự quan tâm từ nhiều nhà khoa học trên khắp thế giới [3].



Hình 1. Các xu hướng nghiên cứu về sử dụng trí tuệ nhân tạo dành cho dữ liệu cổ phiếu từ năm 1995 đến 2019 trong tài liệu số [3]

Trong thời gian qua, nhiều nhà nghiên cứu trong và ngoài nước đã đề xuất các phương pháp khác nhau nhằm nâng cao khả năng dự đoán xu hướng thị trường chứng khoán.

Nhóm tác giả Trần Trung Kiên [4] đã đưa ra phương pháp kết hợp GA-SVR (Genetic Algorithm - Support Vector Regression) trong dự đoán và đạt được kết quả sai số phần trăm tuyệt đối trung bình (MAPE - Mean Absolute Percentage Error) là 1,308. Mô hình mờ TSK (TSK fuzzy model) đã được đề xuất để dự đoán giá trị cổ phiếu Việt Nam bởi Nguyễn Đức Hiền và Lê Mạnh Thạch [5]. Mô hình đạt được các kết quả có độ sai số trung bình tuyệt đối (MAE - Mean Absolute Error) từ 0,01-0,02. Vũ Thị Loan cùng các tác giả [6] đề xuất phương pháp dự báo biến động tiếp theo của giá cổ phiếu trước các thông tin tài chính và phi tài chính bằng phương pháp nghiên cứu sự kiện (event study) và thuật toán học máy Random Forest, đưa ra các kết quả dự đoán biến động chính xác gần 90%. Với các nghiên cứu quốc tế, Wenjie Lu và cộng sự [7] đề xuất phương pháp phối hợp sử dụng các mạng nơ-ron tích chập CNN-BiLSTM-AM trong các công đoạn dự đoán giá trị cổ phiếu, kết quả cho ra với sai số MAE và căn bậc hai của trung bình bình phương sai số (RMSE - Root Mean Squared Error) lần lượt là 21,952 và 31,694. Phương pháp dự đoán sử dụng mạng nơ-ron nhân tạo (ANN) được Mehar Vijh và nhóm tác giả [8] chứng minh là tốt hơn so với phương pháp sử dụng thuật toán Random Forest, trong bài toán dự đoán giá đóng (closing) trong cổ phiếu.

Qua các nghiên cứu, mạng hồi quy Long Short-Term Memory (LSTM) [9] được chứng minh là một phương pháp hiệu quả hơn đối với dữ liệu chuỗi thời gian về lĩnh vực cổ phiếu [10], song việc dự đoán giá trị cổ phiếu vẫn là một bài toán đầy thách thức. Vậy trong nghiên cứu này,

chúng tôi sẽ làm rõ phương pháp sử dụng mạng hồi quy LSTM trong dự đoán giá trị cổ phiếu, và đưa ra các kết quả bổ sung cho các nghiên cứu liên quan tới lĩnh vực dự đoán giá cổ phiếu.

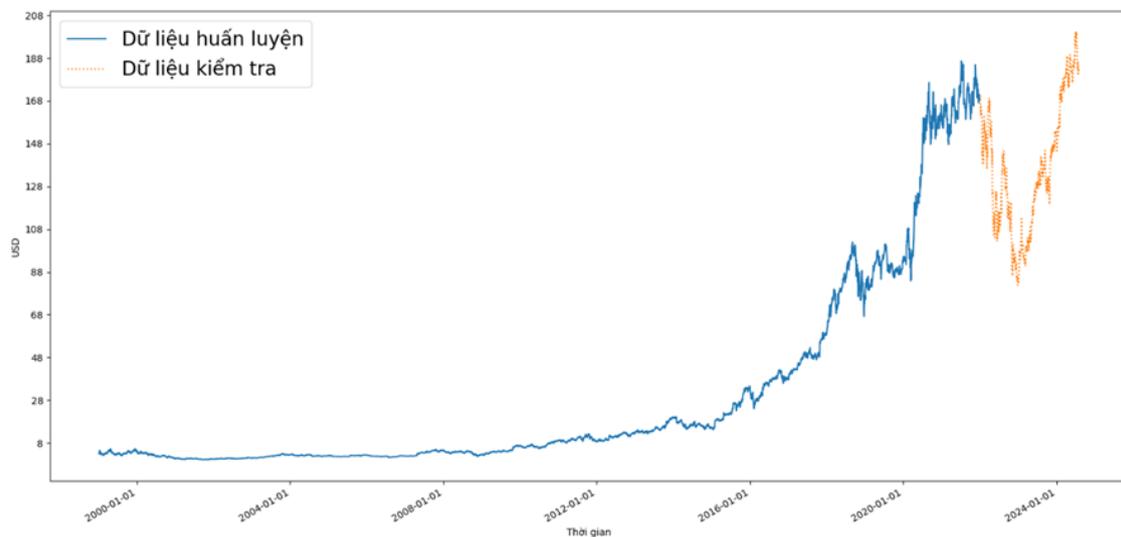
2. Phương pháp nghiên cứu

2.1. Mô tả dữ liệu và bài toán nghiên cứu

Dữ liệu nghiên cứu trong bài báo là giá cổ phiếu của Amazon với mã thị trường là AMZN [11], dữ liệu cổ phiếu gồm 25 năm dữ liệu. Thông tin dữ liệu bao gồm giá cổ phiếu cao nhất của ngày, thấp nhất của ngày, giá mở cửa, giá đóng cửa, giá đóng cửa điều chỉnh và khối lượng giao dịch. Bảng 1 thống kê dữ liệu được sử dụng cho huấn luyện và kiểm tra mô hình LSTM:

Bảng 1. Dữ liệu thống kê (Dữ liệu định dạng từ ngày 02/01/1999 - 31/07/2024)

	Dữ liệu	Dữ liệu huấn luyện	Dữ liệu kiểm tra
Thời gian	02/01/1999 – 31/07/2024	02/01/1999 – 31/12/2021	02/01/2022 – 31/07/2024



Hình 2. Trực quan bộ dữ liệu sử dụng

Chỉ dữ liệu giá đóng cửa điều chỉnh được sử dụng trong quá trình dự đoán. Hình 2 trực quan giá trị cổ phiếu giá đóng cửa điều chỉnh trên toàn bộ tập dữ liệu gồm dữ liệu sử dụng cho việc huấn luyện và kiểm tra mô hình LSTM đề xuất. Mục tiêu của nghiên này là đánh giá khả năng của LSTM trong việc học từ dữ liệu chuỗi thời gian đơn giản, do đó, chúng tôi chỉ sử dụng giá đóng cửa điều chỉnh để lựa chọn cho việc huấn luyện mô hình, có thể lý giải kỹ hơn lý do này qua các tiêu chí sau:

- Giá đóng cửa điều chỉnh thường được coi là đại diện tốt nhất cho giá trị của một cổ phiếu trong một ngày giao dịch. Nó phản ánh tất cả các thông tin và hoạt động giao dịch diễn ra trong ngày, được "tổng hợp" vào một điểm dữ liệu duy nhất. Điều này làm cho việc phân tích và dự đoán trở nên đơn giản hơn.

- Dữ liệu giá đóng cửa điều chỉnh (đã tính toán cả chia tách cổ phiếu, cổ tức v.v.) có sẵn rộng rãi và dễ dàng thu thập từ nhiều nguồn khác nhau.

- Việc sử dụng quá nhiều yếu tố đầu vào có thể dẫn đến hiện tượng "nhiều", làm cho mô hình khó học được các mẫu quan trọng từ dữ liệu. Chỉ sử dụng giá đóng cửa điều chỉnh giúp giảm thiểu nhiễu và tập trung vào xu hướng giá chính.

- Việc bỏ qua các yếu tố khác như tin tức thị trường, báo cáo tài chính, khối lượng giao dịch,... có thể làm mất đi thông tin quan trọng ảnh hưởng đến giá cổ phiếu. Tuy nhiên, trong một số trường hợp, tác động của những yếu tố này đã được phản ánh một phần vào giá đóng cửa điều chỉnh.

Để giải quyết vấn đề dự đoán giá cổ phiếu của Amazon (AMZN), mô hình mạng nơ-ron LSTM sẽ được áp dụng nhằm dự đoán giá trị cổ phiếu cho ngày tiếp theo. Giá đóng cửa cổ phiếu là mỗi chuỗi giá trị biến đổi theo thời gian ký hiệu là N . Trong đó, P đại diện cho giá đóng cửa vào ngày thứ i với điều kiện $0 < i < N$.

Một cửa sổ trượt sẽ được thiết lập trên trục thời gian, với kích thước w được giữ cố định và bước di chuyển cũng bằng kích thước này, nhằm đảm bảo không có sự chồng chéo dữ liệu. Mục tiêu là sử dụng dữ liệu trong cửa sổ $w(t)$ để dự đoán giá cho $w(t + 1)$.

2.2. Kiến trúc mô hình hồi quy Long Short-term Memory (LSTM)

2.2.1. Mạng nơ-ron hồi quy (RNN - Recurrent Neural Network)

Mạng hồi quy LSTM là một dạng của mạng nơ-ron hồi quy RNN. RNN được gọi là mạng nơ-ron hồi quy vì nó áp dụng cùng một phép biến đổi cho mỗi phần tử của một chuỗi theo cách mà đầu ra của RNN phụ thuộc vào kết quả của các lần lặp trước đó. Do đó, RNN duy trì một trạng thái nội bộ để nắm bắt thông tin về các phần tử trước đó trong chuỗi, giống như bộ nhớ. Một đơn vị ẩn RNN sẽ được học dựa vào công thức (1), đầu ra của RNN: y_t , là một phép biến đổi phi tuyến của tổng hai phép nhân ma trận, sử dụng ví dụ như các hàm kích hoạt tanh hoặc ReLU:

$$y_t = g(W_{hh}h_{t-1} + W_{hx}x_t) \quad (1)$$

Trong đó:

- W : ma trận dữ liệu cần tính toán
- W_{hh} : áp dụng cho trạng thái ở trạng thái ẩn trước h_{t-1}
- W_{hx} : áp dụng cho trạng thái ở trạng thái đầu vào hiện tại x_t

2.2.2. Mạng hồi quy Long Short-term Memory (LSTM)

Tuy nhiên, mạng RNN gặp phải một số hạn chế đáng chú ý, bao gồm hiện tượng bùng nổ gradient (gradient explosion) và suy biến gradient (vanishing gradient) [12]. Việc nhân liên tiếp ma trận $W_{(k)}$ không ổn định dẫn đến việc gradient biến mất trong quá trình triển khai thuật toán lan truyền ngược, hoặc bùng nổ gradient dẫn đến các giá trị lớn một cách không ổn định. Mạng hồi quy LSTM sử dụng bốn biến trung gian \bar{i} , \bar{f} , \bar{o} và \bar{c} có kích thước p chiều. Ma trận cập nhật được ký hiệu là $W_{(k)}$ và được sử dụng để nhân trước với vector cột $[\bar{h}_t^{(k-1)}, \bar{h}_{t-1}^{(k)}]^T$. Cập nhật ma trận sẽ được biểu diễn bằng công thức (2):

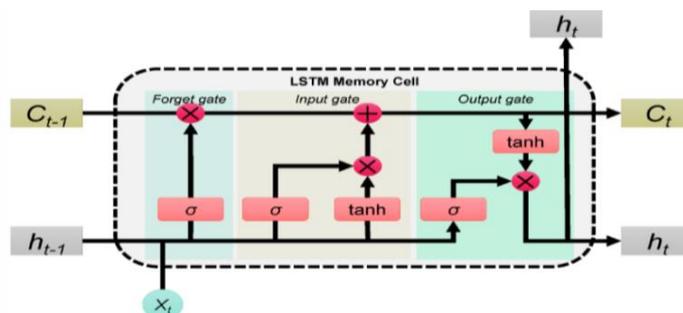
$$\begin{array}{l} \text{Cổng đầu vào} \\ \text{Cổng quên} \\ \text{Cổng đầu ra} \\ \text{Trạng thái c mới} \end{array} \begin{bmatrix} \bar{i} \\ \bar{f} \\ \bar{o} \\ \bar{c} \end{bmatrix} = \begin{pmatrix} \text{sigm} \\ \text{sigm} \\ \text{sigm} \\ \text{tanh} \end{pmatrix} W^k \begin{bmatrix} \bar{h}_t^{(k-1)} \\ \bar{h}_{t-1}^{(k)} \end{bmatrix} \quad [\text{thiết lập tham số}] \quad (2)$$

Sự xác định vector trạng thái ẩn $\bar{h}_t^{(k)}$ và vector trạng thái ô $\bar{c}_t^{(k)}$ sử dụng một quá trình nhiều bước, bắt đầu bằng việc tính toán các biến trung gian tại lần lượt (3) và (4).

$$\bar{c}_t^{(k)} = \bar{f} \odot \bar{c}_{t-1}^{(k)} + \bar{i} \odot \bar{c} \quad [\text{Chọn lọc quên và thêm vào bộ nhớ dài hạn}] \quad (3)$$

$$\bar{h}_t^{(k)} = \bar{o} \odot \text{tanh}(\bar{c}_t^{(k)}) \quad [\text{Chọn lọc rò rỉ bộ nhớ dài hạn vào trạng thái ẩn}] \quad (4)$$

Tại đây, phép nhân từng phần của các vector được ký hiệu bằng “ \odot ,” và ký hiệu “sigm” chỉ hàm sigmoid. Tại lớp thứ nhất ($k=1$), $\bar{h}_t^{(k)}$ trong phương trình trên nên được thay thế bằng \bar{x}_t và ma trận $W^{(1)}$ có kích thước $p \times (p + d)$. Trong các triển khai thực tế, các hệ số điều chỉnh (bias) cũng được sử dụng trong các cập nhật ở trên. Kiến trúc mô hình LSTM sẽ được minh họa tại Hình 3.



Hình 3. Kiến trúc mô hình LSTM trong quá trình cập nhật ma trận [13]

2.3. Thiết lập mô hình LSTM và điều chỉnh siêu tham số mô hình

Mô hình LSTM được sử dụng trong bài báo có kiến trúc bao gồm một lớp LSTM 200 đơn vị với tỷ lệ 0,2 trên lớp dropout, điều này được lặp lại 4 lần. Tham số 200 đơn vị là kích thước của nơ-ron cho lớp LSTM, do đó trong trường hợp này, lớp LSTM có 200 đơn vị ẩn hoặc ô ẩn. Lớp dropout được thực hiện để ngăn ngừa các vấn đề quá khớp (overfitting), vấn đề này có thể gặp phải trong quá trình huấn luyện mô hình. Trong giai đoạn huấn luyện, các nút và kết nối được xóa ngẫu nhiên khỏi mạng. Trong trường hợp phương pháp được đề xuất, xác suất loại bỏ là 20%. Sau lớp dropout cuối cùng, một lớp dense với 1 đơn vị được sử dụng. Thông tin chi tiết về mô hình được đề cập ở Hình 4.

Layer (type)	Output Shape	Param #
lstm_22 (LSTM)	(None, 20, 200)	161600
dropout_22 (Dropout)	(None, 20, 200)	0
lstm_23 (LSTM)	(None, 20, 200)	320800
dropout_23 (Dropout)	(None, 20, 200)	0
lstm_24 (LSTM)	(None, 20, 200)	320800
dropout_24 (Dropout)	(None, 20, 200)	0
lstm_25 (LSTM)	(None, 200)	320800
dropout_25 (Dropout)	(None, 200)	0
dense_5 (Dense)	(None, 1)	201

Total params: 1,124,201
Trainable params: 1,124,201
Non-trainable params: 0

Hình 4. Mô hình LSTM được đề xuất

Mô hình học sâu sử dụng thuật toán tối ưu bằng các vòng lặp, các tham số mô hình sẽ được cải thiện dựa vào thuật toán tối ưu mất mát mini-batch gradient descent [14]. Việc huấn luyện dữ liệu nhiều hơn một lần để tối ưu tham số, điều này sẽ phải dùng đến siêu tham số epoch, đây cũng biểu diễn số lần thuật toán sẽ chạy lại thuật toán lan truyền ngược và xuôi để cập nhật tham số mô hình. Việc chia dữ liệu trong bài toán chuỗi thời gian cần tuân thủ nguyên tắc duy trì tính liên tục thời gian để tránh rò rỉ dữ liệu. Trong nghiên cứu này, tập dữ liệu được chia thành ba phần: tập huấn luyện, tập kiểm thử (validation), và tập kiểm tra (test). Tập huấn luyện được sử dụng để mô hình học từ các mẫu quá khứ, trong khi tập kiểm thử (25% từ cuối tập huấn luyện) giúp đánh giá hiệu suất trong quá trình tối ưu mà không ảnh hưởng đến tập kiểm tra. Tập kiểm tra, bao gồm

dữ liệu chưa từng xuất hiện trong huấn luyện hoặc kiểm thử, được sử dụng để đánh giá mô hình trên dữ liệu mới. Quy trình này đảm bảo mô hình không tiếp cận thông tin từ tương lai, giữ vững tính khách quan và khoa học trong đánh giá hiệu quả dự đoán của mô hình.

Dữ liệu sẽ được bóc tách ra từng phần qua mỗi lần lặp trong 1 epoch, điều này giúp mô hình có thể huấn luyện mà tối ưu toàn cục dữ liệu, được gọi là batch size (số lượng mẫu dữ liệu). Số lượng mẫu dữ liệu được tính theo công thức (5), trong đó N là tổng số mẫu của dữ liệu, M là số mẫu dữ liệu qua một vòng lặp, từ đó chúng ta suy ra được:

$$M = \frac{N}{\text{Batch size}} \quad (5)$$

Từ đó, chúng ta cũng suy ra được tổng số lần lặp của 1 epoch sẽ là N/M .

Các siêu tham số được điều chỉnh để sử dụng cho mô hình LSTM được định nghĩa như sau:

- Batch size: 128
- Epoch: 50
- Dữ liệu kiểm thử (validation): 25% tập huấn luyện
- Patience: 15 (sẽ dừng huấn luyện sau 15 lần nếu mô hình không đạt hiệu quả tốt hơn)
- Mode: RMSE (Hiệu quả mô hình được đo bằng chỉ số RMSE, sẽ được đề cập tới ở phần kết quả và bàn luận)
- Min_delta: 0.000001 (khi hiệu quả mô hình tại từng epoch tốt hơn số sau, sẽ không kích hoạt patience)

Cấu hình mạng LSTM được đề xuất sử dụng các siêu tham số được lựa chọn dựa trên các thực tiễn phổ biến trong huấn luyện mạng nơ-ron. Batch size 128 cho phép xử lý song song hiệu quả, cân bằng giữa tốc độ huấn luyện và mức tiêu thụ bộ nhớ. Việc huấn luyện trong 50 epoch cung cấp đủ số lần lặp cần thiết để mô hình có thể hội tụ, trong khi cơ chế dừng sớm với patience 15 và min_delta 0,000001 giúp giảm thiểu nguy cơ quá khớp bằng cách dừng huấn luyện khi không còn cải thiện đáng kể trên tập kiểm thử (validation).

RMSE được sử dụng làm hàm mất mát (loss function) và chỉ số đánh giá, phù hợp cho các bài toán hồi quy và cung cấp thước đo trực quan về độ lệch giữa giá trị dự đoán và giá trị thực tế. Mặc dù cấu hình này không phải là tối ưu tuyệt đối và hiệu suất cuối cùng phụ thuộc mạnh mẽ vào đặc điểm của tập dữ liệu và bài toán cụ thể, các siêu tham số được thiết lập nhằm tối ưu hóa quá trình huấn luyện và đạt được hiệu suất tổng quát hóa cao. Việc tinh chỉnh các siêu tham số này có thể được thực hiện thông qua các kỹ thuật như tìm kiếm trên lưới hoặc tìm kiếm ngẫu nhiên để đạt được hiệu suất tốt nhất cho từng trường hợp cụ thể.

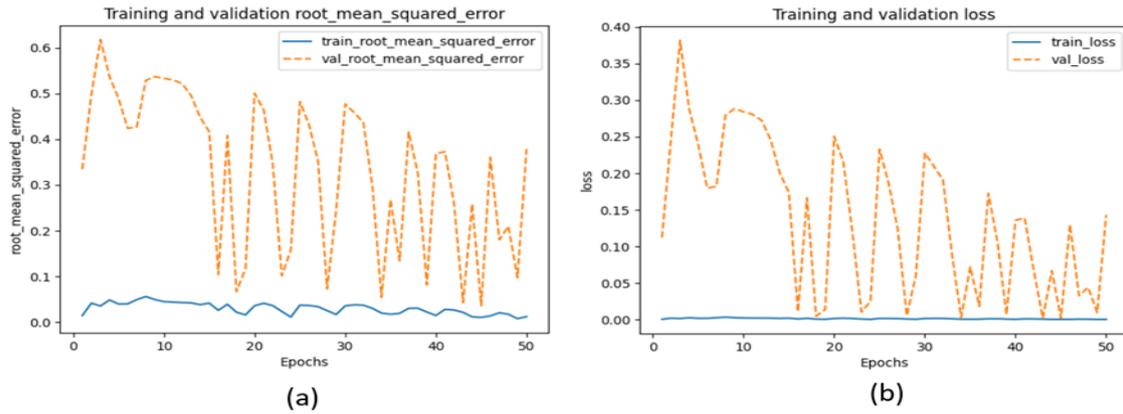
3. Kết quả và bàn luận

Để đánh giá tính hiệu quả mô hình hồi quy LSTM được đề xuất, chúng tôi đưa ra các độ đo RMSE (Căn bậc hai độ lệch bình phương trung bình) và MAE (Sai số tuyệt đối trung bình) [15]. Đây là hai độ đo phổ biến để xét các giá trị dự đoán có khác biệt như thế nào đối với giá trị gốc. RMSE sẽ được lý giải trong công thức (6):

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (6)$$

Trong đó, \hat{y}_i là giá trị cổ phiếu thực tế và y_i là giá trị cổ phiếu mà mô hình LSTM dự đoán, trong đó, n là tổng số mẫu quan sát. Tương tự, MAE được lý giải trong công thức (7):

$$MAE = \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{n} \quad (7)$$



Hình 5. Kết quả huấn luyện của tập huấn luyện và kiểm thử: (a) RMSE (b) Độ mất mát (Loss)

Quá trình huấn luyện gồm 50 epochs được minh họa tại Hình 5. Trong Hình 5a, độ đo RMSE được đo đối với dữ liệu huấn luyện và kiểm thử, Hình 5b mô tả giá trị của hàm mất mát đối với dữ liệu huấn luyện và kiểm thử. Chúng ta có thể thấy rằng kết quả cho ra là khả quan để mô hình dự đoán gần đúng các xu hướng cổ phiếu trong thực tế.

Ta thu được chi tiết số liệu tại Bảng 2, gồm các độ đo về mất mát, RMSE và MAE đối với tập huấn luyện, kiểm thử và kiểm tra.

Bảng 2. Kết quả sau huấn luyện mô hình LSTM

	Độ mất mát (Loss)	RMSE	MAE
Tập huấn luyện	0,00008	0,0091	0,0069
Tập kiểm thử	0,0241	0,1553	0,1074
Tập kiểm tra	0,0192	0,1387	0,1007

Hình 6 minh họa mô hình LSTM dự đoán đối với tập dữ liệu kiểm tra từ ngày 02/01/2022 – 31/07/2024.



Hình 6. Trực quan dự đoán của mô hình LSTM so với giá trị thực tế

Như vậy, các kết quả thu được từ phương pháp đề xuất đối với bài toán dự đoán giá trị cổ phiếu bằng mô hình LSTM là khả quan. Kết quả có thể bị ảnh hưởng khi điều chỉnh lại các siêu tham số của mô hình LSTM, lượng dữ liệu huấn luyện, trên hết đó chính là tính chất và đặc điểm của giá trị cổ phiếu. Tính chất của dữ liệu cổ phiếu tăng giảm không theo một chu kỳ bền vững và luôn dao động bất thường phụ thuộc vào yếu tố như xã hội, chính trị và tình hình thế giới. Đây là một trong những dữ liệu mang tới nhiều thách thức khi dự đoán và nắm bắt.

Qua Hình 6, chúng ta có thể khẳng định rằng mô hình LSTM có thể dự đoán tốt xu hướng của giá trị cổ phiếu thực tế nói chung và Amazon nói riêng. Tuy nhiên, có một số khoảng thời gian mà mô hình dự đoán giá tăng giảm không chính xác, điều này sẽ ảnh hưởng trực tiếp đến quyết định của nhà đầu tư. Trên cơ sở đó, các nhà đầu tư có thể xem đây là một nguồn tham khảo và gợi ý nếu nhìn trên một chu kỳ cổ phiếu dài hạn, ví dụ như từ nửa năm đến lớn hơn một năm.

4. Kết luận

Bài báo mô tả việc áp dụng mô hình học sâu LSTM cho dự đoán giá trị cổ phiếu của giá đóng điều chỉnh của tập dữ liệu cổ phiếu AMAZON. Nghiên cứu đem tới một nguồn tài liệu tham khảo cho lĩnh vực liên quan về mô hình LSTM trong dự đoán dữ liệu chuỗi thời gian.

Kết quả thử nghiệm lý giải cho việc sử dụng LSTM dự đoán giá trị cổ phiếu như là một công cụ gợi ý và hỗ trợ quyết định cho các nhà đầu tư hoặc người nắm giữ cổ phiếu và chứng khoán. Mặc dù vẫn còn sai số nhất định so với dữ liệu thực tế, tuy nhiên kết quả cho ra được nhận định là khả quan đối với bài toán dự đoán xu hướng thị trường tài chính, giúp nhà đầu tư đưa ra quyết định mua/bán cổ phiếu hiệu quả hơn, tối ưu hóa lợi nhuận hoặc dự báo biến động giá cả bằng LSTM hỗ trợ nhà đầu tư quản lý rủi ro danh mục đầu tư, giảm thiểu thua lỗ tiềm ẩn.

Việc điều chỉnh tham số của mô hình LSTM và thử nghiệm huấn luyện mô hình trên các tập dữ liệu khác sẽ được tiếp tục nghiên cứu và thực hiện nhằm đưa ra được một mô hình chính xác hơn và có tính ổn định hơn.

TÀI LIỆU THAM KHẢO/ REFERENCES

- [1] J. H. Stock and M. W. Watson, "Variable Trends in Economic Time Series," *Journal of Economic Perspectives*, vol. 2, no. 3, pp. 147-174, Sep. 1988, doi: 10.1257/jep.2.3.147.
- [2] T. H. H. Nguyen, "The Impact of Profit Forecasts on Stock Returns in Listed Companies in Vietnam," *Economy and Forecast Review*, 2022. [Online]. Available: <https://lib.hutech.edu.vn/chitiet?id=413220>. [Accessed Oct. 13, 2024].
- [3] F. G. D. C. Ferreira, A. H. Gandomi, and R. T. N. Cardoso, "Artificial Intelligence Applied to Stock Market Trading: A Review," *IEEE Access*, vol. 9, pp. 30898-30917, 2021, doi: 10.1109/ACCESS.2021.3058133.
- [4] T. K. Tran, T. T. Banh, and H. T. A. Nguyen, "A Hybrid GA-SVR Approach for Vietnam Stock Price Prediction," *Journal on Information Technologies & Communications*, vol. V-1, no. 7 (27), pp. 12-22, 2012, doi: 10.32913/mic-ict-research-vn.v1.n27.101.
- [5] D. H. Nguyen and M. T. Le, "The TSK fuzzy model extracted from Support-vector-machine-for-regression for stock price forecasting," *CTU Journal of Science*, special issue on Information Technology, pp. 144-151, 2015.
- [6] T. L. Vu, T. A. T. Nguyen, T. H. L. Nong, and M. L. Vu, "Forecasting Stock Price Using Financial and Non-financial Information: Application of Event Study and Random Forest Analysis," *VNU Journal of Economics and Business*, vol. 3, no. 3, 2023, doi: 10.57110/jebvn.v3i3.178.
- [7] W. Lu, J. Li, J. Wang, and L. Qin, "A CNN-BiLSTM-AM method for stock price prediction," *Neural Comput & Applic*, vol. 33, no. 10, pp. 4741-4753, May 2021, doi: 10.1007/s00521-020-05532-z.
- [8] M. Vijh, D. Chandola, V. A. Tikkiwal, and A. Kumar, "Stock Closing Price Prediction using Machine Learning Techniques," *Procedia Computer Science*, vol. 167, pp. 599-606, Jan. 2020, doi: 10.1016/j.procs.2020.03.326.
- [9] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.

-
- [10] K. Chen, Y. Zhou, and F. Dai, "A LSTM-based method for stock returns prediction: A case study of China stock market," in *2015 IEEE International Conference on Big Data (Big Data)*, Oct. 2015, pp. 2823-2824, doi: 10.1109/BigData.2015.7364089.
- [11] Amazon.com Inc., "Amazon.com Inc (AMZN) Stock Price & News," Google Finance, 2024. [Online]. Available: <https://www.google.com/finance/quote/AMZN:NASDAQ>. [Accessed Oct. 16, 2024].
- [12] S. Jansen, *Machine learning for algorithmic trading: predictive models to extract signals from market and alternative data for systematic trading strategies with Python*, 2nd edition. Birmingham Mumbai: Packt, 2020.
- [13] N. Yehia, "Understanding Long Short-Term Memory (LSTM) Networks," 2024. [Online]. Available: <https://mlarchive.com/deep-learning/understanding-long-short-term-memory-networks/>. [Accessed Oct. 17, 2024].
- [14] S. Khirirat, H. R. Feyzmahdavian, and M. Johansson, "Mini-batch gradient descent: Faster convergence under data sparsity," in *2017 IEEE 56th Annual Conference on Decision and Control (CDC)*, Dec. 2017, pp. 2880-2887, doi: 10.1109/CDC.2017.8264077.
- [15] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," *Geoscientific Model Development*, vol. 15, no. 14, pp. 5481-5487, Jul. 2022, doi: 10.5194/gmd-15-5481-2022.