



# DỰ BÁO GIÁ CỔ PHIẾU BẰNG CÁC MÔ HÌNH HỌC SÂU ĐƯỢC TỐI ƯU BẰNG PSO: XÉT TRƯỜNG HỢP MÃ CỔ PHIẾU VCB

Trần Thái Hòa, Lê Ngọc Lưu Quang, Lê Thị Quỳnh Liên\*

Trường Đại học Kinh tế, Đại học Huế, 99 Hồ Đắc Di, Thành phố Huế, Việt Nam

\* Tác giả liên hệ: Lê Thị Quỳnh Liên < lethiquynhlien@hueuni.edu.vn >

(Ngày nhận bài: 26-10-2025; Ngày chấp nhận đăng: 16-03-2026)

**Tóm tắt.** Dự báo chính xác giá cổ phiếu là nhiệm vụ quan trọng trong phân tích đầu tư và quản trị rủi ro trên thị trường tài chính. Nghiên cứu này nhằm nâng cao độ chính xác dự báo giá đóng cửa hằng ngày của cổ phiếu VCB niêm yết trên HOSE bằng các mô hình học sâu. Ba kiến trúc mạng nơ-ron hồi quy gồm LSTM, GRU và BiLSTM được xây dựng và so sánh trong cùng một khuôn khổ thực nghiệm. Bài toán được thiết lập dưới dạng dự báo chuỗi thời gian đơn biến, chỉ sử dụng chuỗi giá đóng cửa, với kỹ thuật cửa sổ trượt 10–1, tức dùng dữ liệu của 10 phiên trước để dự đoán giá của phiên kế tiếp. Để giảm sự phụ thuộc vào quá trình thử-sai thủ công, nghiên cứu áp dụng giải thuật tối ưu bầy đàn hạt (PSO) nhằm tối ưu các siêu tham số quan trọng, gồm số nút ẩn, tỷ lệ dropout, tốc độ học và kích thước batch. Kết quả thực nghiệm cho thấy PSO cải thiện đáng kể hiệu năng dự báo của cả ba mô hình, trong đó GRU sau tối ưu đạt kết quả tốt nhất trên tập kiểm tra với  $RMSE = 0,6851$  và  $R^2 = 0,9693$ . Nghiên cứu góp phần khẳng định hiệu quả của việc kết hợp học sâu và tối ưu siêu tham số trong dự báo giá cổ phiếu tại Việt Nam.

**Keywords:** dự báo giá cổ phiếu, LSTM, GRU, Bi-LSTM, PSO, tối ưu hoá siêu tham số

## PSO-OPTIMIZED DEEP LEARNING MODELS FOR STOCK PRICE FORECASTING: EVIDENCE FROM VCB STOCK

Tran Thai Hoa, Le Ngoc Luu Quang, Le Thi Quynh Lien\*

University of Economics, Hue University, 99 Ho Duc Di St., Hue City, Vietnam

\* Correspondence to Le Thi Quynh Lien < lethiquynhlien@hueuni.edu.vn >

(Submitted: October 26, 2025; Accepted: March 16, 2026)

**Abstract.** Accurate stock price forecasting plays a crucial role in investment analysis and financial risk management. This study aims to improve the forecasting accuracy of the daily closing price of VCB stock listed on the Ho Chi Minh City Stock Exchange (HOSE) using deep learning models. Three architectures, namely LSTM, GRU, and BiLSTM, were developed and compared within a unified experimental framework. The forecasting task was formulated as a univariate time-series problem using only the closing price series, with a 10-to-1 sliding window approach in which the prices of the previous 10 trading

sessions were used to predict the closing price of the following session. To reduce reliance on manual trial-and-error procedures, Particle Swarm Optimization (PSO) was employed to optimize key hyperparameters, including the number of hidden units, dropout rate, learning rate, and batch size. Experimental results show that PSO significantly improved the forecasting performance of all three models, with the optimized GRU achieving the best results on the test set, with an RMSE of 0.6851 and an  $R^2$  of 0.9693. These findings provide empirical evidence for the effectiveness of integrating deep learning with hyperparameter optimization in stock price forecasting for the Vietnamese stock market.

**Keywords:** stock price forecasting, Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Bidirectional LSTM (Bi-LSTM), Particle Swarm Optimization (PSO), hyperparameter optimization

## 1. Giới thiệu

Dự báo chuỗi thời gian tài chính từ lâu đã là một nhiệm vụ quan trọng nhưng đầy thách thức trong nghiên cứu và thực tiễn. Tính ngẫu nhiên, phi tuyến và biến động mạnh của thị trường chứng khoán khiến cho việc dự báo trở nên khó khăn, đặc biệt là tại các nền kinh tế mới nổi, nơi thông tin thị trường còn thiếu minh bạch và tính ổn định chưa cao [1]. Trong quản trị tài chính hiện đại, dự báo chính xác giá cổ phiếu là đầu vào quan trọng cho việc hoạch định chiến lược đầu tư, phân bổ tài sản và kiểm soát rủi ro danh mục. Các dự báo ngắn hạn giúp nhà đầu tư xác định điểm mua – bán tối ưu, đánh giá mức độ rủi ro, đồng thời cải thiện hiệu quả sử dụng vốn. Đối với nhà quản lý quỹ và tổ chức tài chính, khả năng dự báo tin cậy giúp tăng hiệu quả tái cân bằng danh mục, giảm thiểu tổn thất trong giai đoạn biến động. Ở tầm vĩ mô, các mô hình dự báo chính xác còn góp phần nâng cao tính minh bạch và ổn định của thị trường tài chính, hỗ trợ cơ quan quản lý trong việc giám sát và cảnh báo rủi ro hệ thống.

Mặc dù các mô hình thống kê truyền thống như ARIMA và GARCH có nền tảng toán học vững chắc và khả năng diễn giải cao, chúng thường chưa đủ khả năng nắm bắt đầy đủ các mối quan hệ phụ thuộc phức tạp theo thời gian cũng như những biến động đột ngột của dữ liệu tài chính. Những hạn chế này càng bộc lộ rõ khi mô hình cần nắm bắt các quan hệ dài hạn, phát hiện sự thay đổi đột ngột trong xu hướng hay những biến đổi quan trọng về cấu trúc thị trường [2]. Bên cạnh đó, tính phi dừng của chuỗi thời gian khiến việc mô hình hóa và dự báo càng trở nên phức tạp hơn [3].

Trong thập kỷ gần đây, sự phát triển của học máy (machine learning) và học sâu (deep learning) mang đến những giải pháp mạnh mẽ nhằm khắc phục các hạn chế nói trên. Các mô hình Recurrent Neural Networks - RNN và biến thể tiên tiến như LSTM, GRU hay các kiến trúc lai kết hợp mạng nơ-ron với kỹ thuật thống kê truyền thống đã cho thấy khả năng vượt trội trong việc khai thác các quan hệ phi tuyến và phụ thuộc dài hạn [4], [5]. Những mô hình này đã chứng minh được hiệu quả trong việc mô tả tính phi tuyến của biến động giá, nhận diện các

mối tương quan theo thời gian mà các phương pháp truyền thống thường bỏ sót. Trong nghiên cứu này, bài toán dự báo được thiết lập dưới dạng dự báo chuỗi thời gian đơn biến, trong đó chỉ sử dụng chuỗi giá đóng cửa của cổ phiếu VCB. Dữ liệu đầu vào được xây dựng bằng kỹ thuật cửa sổ trượt với cấu hình  $10 \rightarrow 1$ , tức là sử dụng mười quan sát liên tiếp để dự báo giá đóng cửa của ngày kế tiếp. Cách tiếp cận này cho phép mô hình khai thác hiệu quả thông tin ngắn hạn trong chuỗi thời gian, đồng thời phù hợp với đặc điểm dữ liệu giá cổ phiếu hàng ngày tại thị trường Việt Nam.

Tuy nhiên, hiệu năng của các mô hình học sâu phụ thuộc rất lớn vào lựa chọn siêu tham số, bao gồm số lượng nút ẩn, tốc độ học, tỷ lệ dropout và kích thước batch [6]. Việc điều chỉnh thủ công các siêu tham số này thường tốn nhiều thời gian, đòi hỏi chuyên môn và dễ dẫn đến cấu hình chưa tối ưu. Để khắc phục vấn đề này, các thuật toán tối ưu metaheuristic đã được ứng dụng rộng rãi nhằm tự động hóa quá trình tìm kiếm siêu tham số [7]. Trong số đó, giải thuật tối ưu bầy đàn hạt PSO được đánh giá cao nhờ tính đơn giản, hiệu quả tính toán và khả năng tìm lời giải tối ưu trong không gian tìm kiếm có nhiều chiều [8].

Mặc dù lĩnh vực này đã có nhiều bước tiến đáng kể, một số khía cạnh vẫn chưa được khám phá đầy đủ. Cụ thể, các nghiên cứu thực hiện so sánh hệ thống giữa nhiều kiến trúc RNN trước và sau khi tối ưu bằng PSO trong bối cảnh các thị trường mới nổi như Việt Nam vẫn còn thưa thớt. Hơn nữa, các bằng chứng định lượng về mức độ cải thiện độ chính xác dự báo nhờ PSO trên dữ liệu tài chính thực tế vẫn chưa được trình bày một cách toàn diện. Trong phạm vi nghiên cứu này, giải thuật PSO được sử dụng nhằm tối ưu các siêu tham số của mô hình học sâu trên các kiến trúc mạng cố định, không nhằm tìm kiếm hay tối ưu cấu trúc mạng nơ-ron.

Dựa trên những vấn đề chưa được khai thác đầy đủ, bài báo đóng góp ba phương diện chính. Thứ nhất, nhóm tác giả đề xuất một khuôn khổ tối ưu hóa siêu tham số cho các mô hình RNN dựa trên PSO, giúp giảm thiểu quá trình thử-sai thủ công và nâng cao tính tái lập. Thứ hai, nghiên cứu đã tiến hành phân tích, so sánh LSTM, GRU và Bi-LSTM trước và sau khi tối ưu, cung cấp những hiểu biết sâu sắc về ưu và nhược điểm của từng mô hình trong dự báo chuỗi thời gian tài chính. Cuối cùng, thực nghiệm được kiểm định trên dữ liệu cổ phiếu VCB (Ngân hàng Thương mại cổ phần Ngoại thương Việt Nam) niêm yết tại HOSE, chứng minh rằng PSO cải thiện đáng kể độ chính xác dự báo, với GRU đạt kết quả tốt nhất ( $RMSE = 0,6851$ ,  $R^2 = 0,9693$ ). Trên cơ sở đó, nghiên cứu này không chỉ đánh giá hiệu quả kỹ thuật của mô hình mà còn làm rõ giá trị ứng dụng trong quản trị đầu tư và chính sách tài chính tại Việt Nam – một thị trường mới nổi đang chuyển mình mạnh mẽ theo hướng số hóa và dữ liệu hóa. Bên cạnh các đóng góp về mặt phương pháp, nghiên cứu còn nhấn mạnh ý nghĩa kinh tế – quản trị của việc nâng cao độ chính xác dự báo, qua đó cung cấp bằng chứng thực nghiệm giúp nhà đầu tư,

doanh nghiệp và nhà quản lý sử dụng mô hình AI trong phân tích thị trường và hoạch định chiến lược tài chính.

Phần còn lại của bài báo được cấu trúc như sau: mục 2 trình bày tổng quan các công trình nghiên cứu liên quan đến dự báo giá cổ phiếu dựa trên mô hình mạng nơ-ron hồi quy (RNN) và các phương pháp tối ưu hóa siêu tham số. Mục 3 mô tả phương pháp nghiên cứu, bao gồm quy trình xử lý dữ liệu, cấu trúc các mô hình RNN (LSTM, GRU, BiLSTM) và cơ chế tối ưu siêu tham số bằng PSO. Tiếp đó, mục 4 trình bày thiết lập thí nghiệm, kết quả thực nghiệm và thảo luận, qua đó phân tích hiệu quả của từng mô hình trước và sau khi tối ưu. Mục 5 khai thác các hàm ý quản trị và chính sách, nhấn mạnh giá trị ứng dụng của kết quả nghiên cứu trong thực tiễn quản lý đầu tư và thị trường tài chính. Cuối cùng, Mục 6 đưa ra kết luận chung và định hướng nghiên cứu tiếp theo, nhằm mở rộng khung dự báo cho các ứng dụng tài chính khác trong tương lai.

## 2. Tổng quan nghiên cứu

Dự báo giá cổ phiếu từ lâu là một chủ đề trọng tâm trong lĩnh vực tài chính và khoa học dữ liệu, thu hút sự quan tâm của cả giới nghiên cứu và đầu tư. Trải qua nhiều giai đoạn phát triển, các phương pháp dự báo đã tiến hóa từ mô hình thống kê cổ điển đến các kiến trúc học sâu hiện đại, và gần đây là sự xuất hiện của các kỹ thuật tối ưu hóa siêu tham số tiên tiến. Việc tổng quan những cách tiếp cận này giúp làm rõ điểm mạnh, hạn chế của từng nhóm phương pháp, đồng thời xác định khoảng trống nghiên cứu mà bài báo này hướng tới.

Các nghiên cứu ban đầu chủ yếu sử dụng các mô hình tuyến tính ngẫu nhiên như AR, MA và ARIMA, thường được mở rộng bằng các họ mô hình ARCH/ GARCH để mô tả biến động thay đổi theo thời gian [9]. Ưu điểm của các mô hình này nằm ở khả năng diễn giải cao và cơ sở thống kê chặt chẽ, đặc biệt hiệu quả khi chuỗi thời gian gần tuyến tính và được xử lý loại bỏ yếu tố mùa vụ. Tuy nhiên, khả năng biểu diễn của chúng bị hạn chế trước các quan hệ phi tuyến, sự chuyển chế và phụ thuộc dài hạn vốn xuất hiện phổ biến trên thị trường chứng khoán, nhất là trong các giai đoạn biến động mạnh hoặc có cú sốc kinh tế [10], [11].

Sự phát triển của học sâu đã khiến trọng tâm nghiên cứu dịch chuyển sang các kiến trúc mạng nơ-ron, vốn có khả năng học và biểu diễn các đặc trưng phức tạp của dữ liệu. Mạng nơ-ron hồi quy (RNN), đặc biệt là LSTM và GRU, giải quyết trực tiếp vấn đề mất dần đạo hàm (vanishing gradient) và tỏ ra phù hợp để nắm bắt phụ thuộc dài hạn [12], [13]. BiLSTM còn tăng cường khả năng biểu diễn bằng cách xử lý chuỗi dữ liệu theo cả hai chiều, tận dụng thông tin quá khứ và tương lai gần [14]. Các bằng chứng thực nghiệm cho thấy LSTM và GRU thường vượt trội hơn các mô hình truyền thống trong dự báo lợi suất, dự báo đa bước và mô hình hóa biến động, đặc biệt trong điều kiện thị trường phi tuyến và nhiễu. Các kiến trúc của

Transformer dựa trên cơ chế chú ý cũng chứng minh được tiềm năng nhờ khả năng nắm bắt cả đặc trưng cục bộ và phụ thuộc dài hạn, nhưng đòi hỏi lượng dữ liệu lớn và kỹ thuật điều chuẩn cẩn thận – điều này đôi khi khó đáp ứng tại các thị trường mới nổi [15].

Một thách thức chung của các mô hình học sâu là độ nhạy với siêu tham số thiết kế như: chiều dài chuỗi đầu vào, số lớp, số nút ẩn, tốc độ học, dropout hay kích thước batch. Việc chọn siêu tham số không phù hợp dễ dẫn đến hiện tượng học chưa đủ (underfitting) hoặc học quá mức (overfitting), làm suy giảm khả năng khái quát hóa mô hình [16]. Ngoài ra, do dữ liệu tài chính thường phi dừng và có thể thay đổi cấu trúc theo thời gian, các mô hình sử dụng cấu trúc cố định sẽ dần giảm hiệu quả. Điều này cho thấy cần có các quy trình tối ưu hóa siêu tham số mang tính thích ứng, đáng tin cậy để duy trì và cải thiện hiệu suất dự báo.

Các phương pháp tìm kiếm truyền thống như grid search và random search tuy đơn giản nhưng kém hiệu quả trong không gian siêu tham số nhiều chiều, đồng thời tốn kém tính toán. Các kỹ thuật tối ưu Bayesian (Bayesian Optimization – BO) cải thiện hiệu quả lấy mẫu nhờ mô hình hóa bề mặt phản hồi nhưng có thể suy giảm hiệu năng khi gặp hàm mục tiêu nhiễu và phi dừng như trong dữ liệu tài chính [6]. Do đó, các thuật toán metaheuristic đã được ứng dụng ngày càng nhiều, bao gồm PSO, giải thuật di truyền (GA) và tiến hóa vi phân (DE), với ưu điểm là chiến lược tìm kiếm quần thể, ít giả định về tính trơn của bài toán và khả năng hội tụ tới nghiệm tốt trong không gian phi lồi [17], [7]. Trong đó, PSO được ưa chuộng nhờ tính đơn giản, hiệu quả tính toán cao và hiệu năng tốt khi tối ưu các mô hình dự báo chuỗi thời gian. Nhiều nghiên cứu trước đã áp dụng PSO để tinh chỉnh kiến trúc mạng nơ-ron, bao gồm RNN và CNN, và báo cáo kết quả cải thiện rõ rệt về độ chính xác và tốc độ hội tụ so với điều chỉnh thủ công hoặc grid search [18], [19].

Các công trình kết hợp PSO với LSTM hoặc GRU trong dự báo giá cổ phiếu, chỉ số và tỷ giá ngoại hối thường tối ưu số lượng nút ẩn, tỷ lệ dropout, tốc độ học và batch size, và hầu hết đều ghi nhận sự cải thiện đáng kể về RMSE, MAE và độ ổn định dự báo [6]. Tuy nhiên, vẫn tồn tại một số khoảng trống nghiên cứu. Thứ nhất, nhiều nghiên cứu chỉ đánh giá một kiến trúc (ví dụ LSTM) mà chưa so sánh với GRU hoặc BiLSTM trong cùng một điều kiện thực nghiệm. Thứ hai, phần lớn các nghiên cứu tập trung vào các thị trường phát triển, trong khi bằng chứng thực nghiệm từ các thị trường mới nổi như Việt Nam vẫn còn hạn chế. Thứ ba, các kết quả so sánh đôi khi chưa được báo cáo theo giao thức chuẩn hóa (cùng tập dữ liệu, thước đo và trực quan hóa), gây khó khăn trong việc tổng hợp và so sánh.

Nghiên cứu này nhằm giải quyết các khoảng trống nói trên. Trước hết, chúng tôi thực hiện so sánh thống nhất giữa LSTM, GRU và BiLSTM trong cùng một quy trình thực nghiệm, đồng thời báo cáo kết quả trước và sau khi tối ưu bằng PSO thông qua các chỉ số chuẩn như MSE, RMSE, MAE và  $R^2$ , kèm theo trực quan hóa kết quả. Tiếp theo, PSO được sử dụng để tối

ưu đồng thời các siêu tham số quan trọng, thay thế quá trình thử-sai thủ công bằng một quy trình tìm kiếm có thể tái lập. Cuối cùng, kết quả thực nghiệm trên dữ liệu cổ phiếu VCB niêm yết tại HOSE chứng minh rằng việc tối ưu bằng PSO cải thiện đáng kể hiệu năng dự báo và cho thấy GRU là mô hình đạt hiệu suất vượt trội.

Tóm lại, dự báo tài chính cần cả sức mạnh biểu diễn và tối ưu siêu tham số hiệu quả. Nghiên cứu này kết hợp các mô hình RNN phổ biến: LSTM, GRU và Bi-LSTM với PSO để tự động tìm siêu tham số tốt nhất, giảm thử-sai thủ công và cải thiện khả năng khái quát. Kết quả trên dữ liệu thị trường Việt Nam chứng minh tính ưu việt của cách tiếp cận, đồng thời cung cấp một khung tối ưu có thể áp dụng cho nhiều thị trường khác.

### 3. Quy trình dự báo giá cổ phiếu VCB bằng các mô hình RNN (LSTM, GRU, BiLSTM) kết hợp tối ưu siêu tham số bằng PSO

Nghiên cứu đề xuất quy trình dự báo giá cổ phiếu bằng các mô hình mạng nơ-ron hồi quy kết hợp tối ưu siêu tham số bằng giải thuật tối ưu bầy đàn hạt (PSO) được mô tả khái quát trong Hình 1. Toàn bộ quy trình này sẽ bao gồm các giai đoạn chính như sau:

**Bước 1 - Tiền xử lý dữ liệu:** Dữ liệu giá cổ phiếu VCB được thu thập và sắp xếp theo trình tự thời gian, sau đó được chia thành ba tập: huấn luyện (training), kiểm định (validation) và kiểm tra (test). Quá trình chuẩn hóa dữ liệu được thực hiện để đảm bảo tính ổn định và hội tụ của mô hình trong quá trình huấn luyện.

**Bước 2 - Xác định không gian tìm kiếm siêu tham số:** Các siêu tham số ảnh hưởng mạnh đến hiệu năng mô hình như số nút ẩn (hidden units), tỷ lệ dropout, tốc độ học (learning rate) và kích thước batch được giới hạn trong một khoảng tìm kiếm hợp lý nhằm giảm chi phí tính toán và tránh hiện tượng quá khớp.

**Bước 3 - Khởi tạo quần thể hạt:** Một quần thể các hạt được khởi tạo ngẫu nhiên, trong đó mỗi hạt đại diện cho một cấu hình siêu tham số tiềm năng của mô hình RNN.

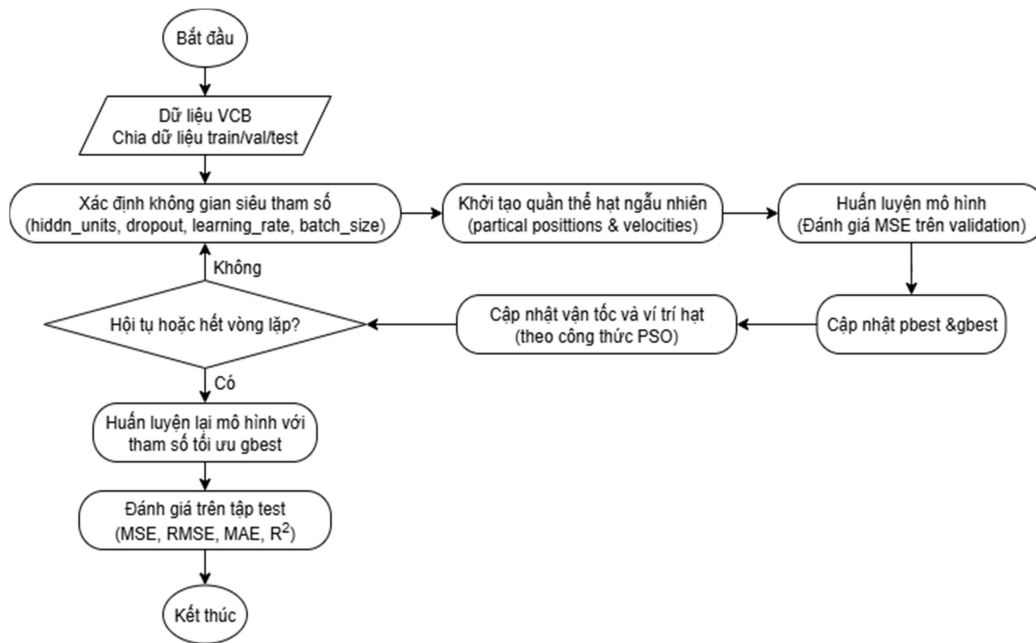
**Bước 4 - Đánh giá giá trị thích nghi:** Với mỗi hạt, mô hình được huấn luyện trên tập dữ liệu huấn luyện và sai số dự báo (MSE) được tính toán trên tập kiểm định. Giá trị MSE này được sử dụng làm hàm mục tiêu để đánh giá mức độ thích nghi của từng hạt trong không gian tìm kiếm.

**Bước 5 - Cập nhật nghiệm tối ưu:** Ở mỗi vòng lặp, các hạt được cập nhật theo hai thành phần: nghiệm tốt nhất cá nhân (pbest) và nghiệm tốt nhất toàn cục (gbest). Vận tốc và vị trí của các hạt được điều chỉnh dựa trên công thức cập nhật của PSO, giúp quần thể dần tiến tới vùng nghiệm tối ưu.

**Bước 6 - Tiêu chuẩn dừng:** Điều chỉnh vận tốc và vị trí hạt theo công thức PSO để khám phá các nghiệm tiềm năng mới. Quá trình tối ưu được lặp lại cho đến khi đạt số vòng lặp tối đa hoặc khi sai số hội tụ về một ngưỡng xác định trước.

**Bước 7 - Huấn luyện và đánh giá cuối cùng:** Sau khi xác định được bộ siêu tham số tối ưu (gbest), mô hình RNN được huấn luyện lại trên toàn bộ tập dữ liệu (train + validation) và kiểm tra trên tập test độc lập. Hiệu năng dự báo được đánh giá bằng các chỉ số MSE, RMSE, MAE và  $R^2$ , nhằm đảm bảo kết quả có độ tin cậy và khả năng khái quát cao.

Quy trình này cho phép tự động hóa việc lựa chọn siêu tham số thay vì điều chỉnh thủ công, giúp tăng tốc quá trình huấn luyện, cải thiện độ chính xác dự báo và đảm bảo khả năng tái lập thực nghiệm của mô hình.



**Hình 1.** Quy trình dự báo giá cổ phiếu VCB bằng các mô hình RNNs (LSTM, GRU, Bi-LSTM) kết hợp tối ưu siêu tham số bằng PSO

### 3.1. Giới thiệu bộ dữ liệu và tiền xử lý dữ liệu

Dữ liệu nghiên cứu gồm giá giao dịch hàng ngày của cổ phiếu VCB (Ngân hàng Thương mại cổ phần Ngoại thương Việt Nam – HOSE: VCB), được thu thập bằng thư viện vnstock trong Python. Tập dữ liệu bao gồm 2.500 phiên giao dịch liên tục từ 05/01/2015 đến 02/01/2025, đại diện cho một thập kỷ biến động của thị trường. Mỗi bản ghi chứa đầy đủ các trường chuẩn

OHLCV: giá mở cửa (open), giá cao (high), giá thấp (low), giá đóng cửa (close) và khối lượng giao dịch (volume).

Dữ liệu được sắp xếp theo thứ tự thời gian và kiểm tra tính toàn vẹn để phát hiện trùng lặp hoặc thiếu giá trị. Kết quả kiểm tra cho thấy không có bản ghi nào bị thiếu, do đó không cần thực hiện nội suy. Để ổn định quá trình huấn luyện mô hình và tránh rò rỉ dữ liệu (data leakage), giá đóng cửa được chuẩn hóa về khoảng  $[0, 1]$  bằng MinMaxScaler dựa trên tập huấn luyện, như biểu thức (1):

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad 1)$$

trong đó  $X_{min}$  và  $X_{max}$  lần lượt là giá trị nhỏ nhất và lớn nhất quan sát được trong tập huấn luyện.

Trong nghiên cứu này, dữ liệu chuỗi thời gian được chuyển đổi sang dạng học có giám sát thông qua kỹ thuật cửa sổ trượt (sliding window). Cụ thể, với cấu hình cửa sổ trượt  $10 \rightarrow 1$ , mười giá trị liên tiếp của chuỗi giá đóng cửa được sử dụng làm đầu vào để dự báo giá đóng cửa của ngày kế tiếp. Về mặt toán học, tập dữ liệu được xây dựng như công thức (2) và (3):

$$X_t = [y_{t-9}, y_{t-8}, \dots, y_t] \quad 2)$$

$$\hat{y}_{t+1} = f(X_t) \quad 3)$$

trong đó  $y_t$  là giá đóng cửa tại thời điểm  $t$ , và  $f(\cdot)$  là hàm dự báo được mô hình hóa bởi các mạng nơ-ron hồi quy (LSTM, GRU hoặc Bi-LSTM). Kỹ thuật cửa sổ trượt cho phép mô hình khai thác hiệu quả mối quan hệ phụ thuộc ngắn hạn trong chuỗi thời gian, đồng thời phù hợp với đặc điểm dữ liệu giá cổ phiếu hằng ngày tại thị trường Việt Nam.

Do bản chất chuỗi thời gian của dữ liệu, tập dữ liệu được phân chia theo thứ tự thời gian (temporal hold-out), không thực hiện xáo trộn nhằm tránh rò rỉ thông tin từ tương lai. Cụ thể, 80% dữ liệu đầu tiên được sử dụng cho huấn luyện, trong khi 20% dữ liệu còn lại được dùng cho kiểm tra. Trong tập huấn luyện, 10% dữ liệu cuối cùng được tách ra làm tập validation, tương đương với tỷ lệ 72% huấn luyện – 8% kiểm định – 20% kiểm tra.

### 3.2. Các mô hình mạng nơ-ron hồi quy (Recurrent Neural Networks – RNN)

Các mô hình mạng nơ-ron hồi quy được sử dụng trong nghiên cứu bao gồm LSTM, GRU và BiLSTM. Đây là những kiến trúc mạng học sâu phổ biến và hiệu quả trong xử lý dữ liệu chuỗi thời gian, đặc biệt là chuỗi dữ liệu tài chính.

### 3.2.1. Tổng quan các mô hình RNN được sử dụng trong nghiên cứu

LSTM được Hochreiter và Schmidhuber (1997) đề xuất nhằm khắc phục vấn đề mất dần đạo hàm (vanishing gradient) trong RNN truyền thống [20]. LSTM bổ sung ba cổng điều khiển bao gồm: cổng quên (forget gate), cổng nhập (input gate) và cổng xuất (output gate) giúp mô hình học và lưu trữ thông tin dài hạn trong quá trình lan truyền theo thời gian. Nhờ cơ chế này, LSTM có khả năng nắm bắt các mối quan hệ phụ thuộc dài hạn trong dữ liệu tài chính, vốn thường mang tính chu kỳ và biến động theo xu hướng thị trường.

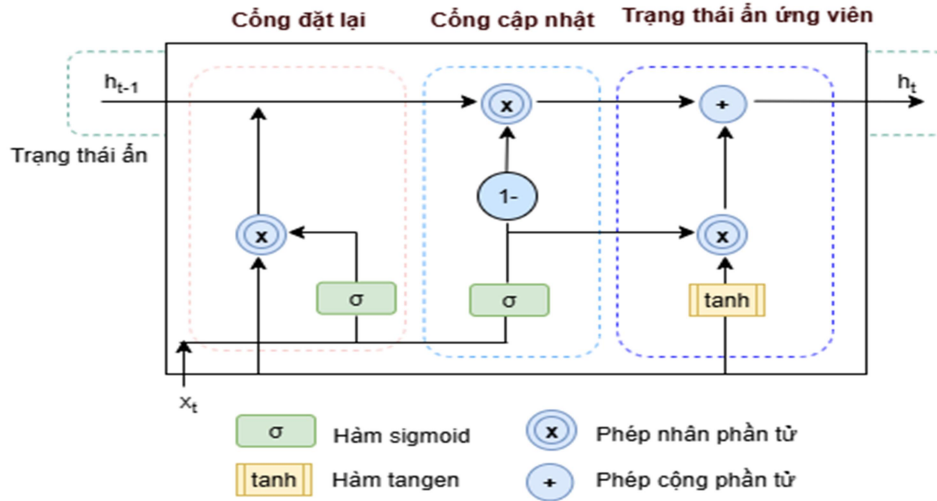
GRU được phát triển như một biến thể rút gọn của LSTM, giúp đơn giản hóa cấu trúc nhưng vẫn duy trì khả năng học phụ thuộc dài hạn. GRU kết hợp cổng quên và cổng nhập thành cổng cập nhật (update gate), đồng thời bổ sung cổng đặt lại (reset gate) để kiểm soát luồng thông tin giữa các bước thời gian.

BiLSTM mở rộng từ LSTM bằng cách cho phép mô hình học dữ liệu theo hai chiều thời gian – từ quá khứ đến tương lai và ngược lại. Cấu trúc này giúp khai thác tốt hơn ngữ cảnh của chuỗi, đặc biệt hữu ích trong các bài toán nhận dạng mẫu (pattern recognition). Tuy nhiên, BiLSTM có độ phức tạp cao hơn, yêu cầu tài nguyên tính toán lớn hơn so với LSTM và GRU.

Trong ba mô hình trên, GRU được lựa chọn để mô tả chi tiết trong phần tiếp theo vì đây là mô hình mang tính đối chứng trọng tâm trong nghiên cứu này do có cấu trúc gọn nhẹ, tốc độ huấn luyện nhanh và hiệu năng vượt trội trong các bài toán dự báo chuỗi thời gian tài chính quy mô trung bình như giá cổ phiếu.

### 3.2.2. Cấu trúc và cơ chế hoạt động của GRU

Mạng GRU là một biến thể của mạng nơ-ron hồi quy được đề xuất nhằm giải quyết vấn đề mất dần hoặc bùng nổ đạo hàm trong quá trình lan truyền ngược theo thời gian. Như đã đề cập ở trên, GRU là một phiên bản tinh gọn của LSTM, kết hợp cổng quên và cổng nhập thành cổng cập nhật, đồng thời bổ sung cổng đặt lại như Hình 2.



**Hình 2.** Kiến trúc mạng hồi tiếp nút có cổng (GRU)

Nhờ cấu trúc đơn giản hơn, GRU có ít tham số hơn LSTM, giúp quá trình huấn luyện nhanh hơn và giảm nguy cơ quá khớp khi dữ liệu không quá lớn. Ở thời điểm  $t$ , với đầu vào  $x_t \in R^d$  và trạng thái ẩn trước đó  $h_{t-1} \in R^h$ , các phương trình của GRU được định nghĩa như sau:

Cổng cập nhật (Update gate) được mô tả như công thức (4):

$$z_t = \sigma (W_z h_{t-1} + U_z x_t + b_z) \tag{4}$$

Cổng đặt lại (Reset gate) được thực hiện bằng công thức (5):

$$r_t = \sigma (W_r h_{t-1} + U_r x_t + b_r) \tag{5}$$

Trạng thái ẩn ứng viên (Candidate hidden state) được thể hiện trong công thức (6):

$$\tilde{h}_t = \tanh (W_h (h_{t-1} \odot r_t + U_h x_t + b_h)) \tag{6}$$

Trạng thái ẩn được cập nhật trong công thức (7):

$$h_t = z_t \odot \tilde{h}_t + (1 - z_t) \odot h_{t-1} \tag{7}$$

Trong đó:

$x_t$ : vec tơ giá cổ phiếu VCB tại thời điểm  $t$ ,

$h_{t-1}, h_t$ : trạng thái ẩn lần lượt tại thời điểm  $t-1$  và  $t$ ,

$\tilde{h}_t$ : trạng thái ẩn ứng viên,

$z_t, r_t$ : giá trị kích hoạt của cổng cập nhật và cổng đặt lại,

$W_z, W_r, W_h, U_z, U_r, U_h$ : lần lượt là ma trận trọng số của đầu vào và trạng thái ẩn,

$b_z, b_r, b_h$ : là các vec tơ bias,

$\sigma$ : hàm sigmoid,

$\tanh$ : là hàm hyperbolic tangen,

Ký hiệu  $\odot$  biểu diễn phép nhân phần tử (Hadamard product)

Cơ chế trên cho phép GRU kiểm soát lượng thông tin được giữ lại hoặc quên đi ở mỗi bước thời gian thông qua  $z_t$ , đồng thời điều chỉnh tác động của trạng thái ẩn trước đó bằng  $r_t$ . Điều này giúp mô hình học được cả các quan hệ phụ thuộc ngắn hạn và dài hạn một cách hiệu quả.

### 3.3. Giải thuật tối ưu hoá bầy đàn hạt PSO

Để nâng cao hiệu năng của các mô hình RNN, nghiên cứu này sử dụng giải thuật tối ưu bầy đàn hạt PSO nhằm tự động tìm kiếm cấu hình siêu tham số tối ưu. PSO là một phương pháp tối ưu metaheuristic dựa trên quần thể, mô phỏng hành vi tìm kiếm thức ăn của đàn chim hoặc đàn cá.

Trong PSO, một quần thể các hạt (particles) đại diện cho các nghiệm ứng viên trong không gian siêu tham số được khởi tạo ngẫu nhiên. Mỗi hạt  $i$  có vị trí  $x_i^t$  và vận tốc  $v_i^t$  tại vòng lặp  $t$ . Chất lượng của một nghiệm được đánh giá bằng hàm mục tiêu – trong nghiên cứu này là sai số dự báo trên tập kiểm định (MSE). Quá trình cập nhật vận tốc và vị trí của hạt tuân theo các phương trình (8) và (9).

$$v_i^{t+1} = w \cdot v_i^t + c_1 r_1 (pbest_i - x_i^t) + c_2 r_2 (gbest_i - x_i^t) \quad (8)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (9)$$

Trong đó:

- $w$  là hệ số quán tính, điều khiển mức ảnh hưởng của vận tốc trước đó,
- $c_1, c_2$  là hệ số nhận thức và xã hội, điều chỉnh mức độ hạt bị kéo về nghiệm tốt nhất cá nhân  $pbest_i$  và nghiệm tốt nhất toàn cục  $gbest$ ,
- $r_1, r_2 \sim U(0, 1)$  là các số ngẫu nhiên, tăng tính đa dạng của quá trình tìm kiếm.

Quy trình PSO bắt đầu bằng việc khởi tạo quần thể hạt ngẫu nhiên trong không gian siêu tham số, bao gồm số nút ẩn, tỷ lệ dropout, tốc độ học và kích thước batch. Mỗi hạt được đánh giá thông qua việc huấn luyện mô hình RNN với cấu hình siêu tham số tương ứng và tính toán MSE trên tập kiểm định. Sau đó, nghiệm tốt nhất cá nhân  $pbest_i$  và nghiệm tốt nhất toàn cục  $gbest$  được cập nhật nếu tìm thấy giá trị hàm mục tiêu tốt hơn. Vận tốc và vị trí của các hạt

được điều chỉnh theo phương trình (8), và (9) để dịch chuyển về nghiệm tối ưu tiềm năng. Quá trình đánh giá và cập nhật được lặp lại cho đến khi đạt số vòng lặp tối đa hoặc sai số hội tụ.

Không gian tìm kiếm được mở rộng đến 256 nút ẩn ở tầng đầu nhằm cho phép PSO linh hoạt khám phá các cấu hình có độ biểu diễn cao hơn trong giai đoạn tối ưu. Bảng 1 thể hiện không gian tìm kiếm các siêu tham số để tối ưu theo giải thuật PSO.

**Bảng 1.** Không gian tìm kiếm siêu tham số tối ưu theo giải thuật PSO

Siêu tham số	Khoảng tìm kiếm
Số nút tầng ẩn 1 (units 1)	[32, 256]
Số nút tầng ẩn 2 (units 2)	[16, 128]
Tỷ lệ dropout	[0,1, 0,5]
Tốc độ học (learning rate)	[ $10^{-4}$ , $10^{-2}$ ]
Kích thước batch	[16, 64]

Sau khi thuật toán hội tụ, nghiệm tối ưu *gbest* được lựa chọn làm cấu hình siêu tham số cuối cùng. Mô hình RNN tương ứng được huấn luyện lại trên toàn bộ tập huấn luyện (train + validation) với bộ siêu tham số tối ưu này, trước khi đánh giá hiệu năng trên tập kiểm tra. Cách tiếp cận này giúp loại bỏ tính chủ quan trong quá trình lựa chọn siêu tham số thủ công, đồng thời đảm bảo tính tái lập của kết quả thực nghiệm.

Cần lưu ý rằng trong nghiên cứu này, giải thuật PSO chỉ được sử dụng để tối ưu siêu tham số trên các kiến trúc mạng cố định (LSTM, GRU và BiLSTM), không nhằm tìm kiếm hay tối ưu cấu trúc mạng *no-ron*. Để đảm bảo khả năng tái lập thực nghiệm, giải thuật PSO trong nghiên cứu này được thiết lập với 10 hạt và 5 vòng lặp, sử dụng cấu trúc Global Best. Hệ số quán tính được cố định ở mức  $w = 0,9$ , trong khi các hệ số nhận thức và xã hội lần lượt là  $c_1 = 0,5$  và  $c_2 = 0,3$ .

Trong quá trình tối ưu, mỗi nghiệm ứng viên được đánh giá bằng cách huấn luyện mô hình RNN tương ứng trong 25 epoch trên tập huấn luyện, và giá trị MSE trên tập validation được sử dụng làm hàm mục tiêu cho PSO. Sau khi kết thúc quá trình tối ưu, bộ siêu tham số tốt nhất được sử dụng để huấn luyện lại mô hình cuối cùng trong 150 epoch trên toàn bộ tập huấn luyện (train + validation), trước khi đánh giá hiệu năng trên tập kiểm tra.

### 3.4. Chỉ số đánh giá hiệu năng của các mô hình

Để đánh giá một cách toàn diện hiệu năng dự báo của các mô hình RNN được tối ưu bằng PSO, nghiên cứu sử dụng bốn chỉ số thống kê phổ biến: MSE, RMSE, MAE và  $R^2$ . Các chỉ số này được định nghĩa như sau:

- Sai số bình phương trung bình (Mean Squared Error – MSE) được định nghĩa theo công thức:

$$MSE(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2 \quad (10)$$

MSE đo lường trung bình bình phương sai số giữa giá trị thực  $y_i$  và giá trị dự báo. Giá trị MSE càng nhỏ chứng tỏ mô hình càng chính xác.

- Căn bậc hai của MSE (Root Mean Squared Error – RMSE): biểu diễn sai số dưới cùng đơn vị với dữ liệu gốc, giúp trực quan hơn trong việc so sánh độ chênh lệch giữa giá dự báo và giá thực tế được biểu diễn như công thức:

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

- Sai số tuyệt đối trung bình (Mean Absolute Error – MAE): tính trung bình giá trị tuyệt đối của sai số. Khác với MSE, MAE ít nhạy cảm với các ngoại lệ (outlier), phản ánh sai số dự báo điển hình của mô hình, được trình bày ở công thức:

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

- Hệ số xác định (Coefficient of Determination –  $R^2$ ) được thể hiện ở công thức:

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{N-1} (y_i - \bar{y})^2} \quad (13)$$

Trong đó  $\bar{y}$  là giá trị trung bình của tập quan sát. Chỉ số  $R^2$  thể hiện tỷ lệ phương sai của dữ liệu được mô hình giải thích. Giá trị  $R^2$  càng gần 1 cho thấy mô hình càng phù hợp với dữ liệu.

Bốn chỉ số trên bổ sung cho nhau, trong đó MSE và RMSE nhấn mạnh sai số bình phương (phạt nặng sai số lớn), MAE cung cấp thước đo trung bình trực quan, còn  $R^2$  phản ánh mức độ giải thích biến thiên của mô hình. Việc sử dụng kết hợp chúng giúp đánh giá toàn diện cả độ chính xác tuyệt đối và khả năng khái quát hóa của mô hình.

## 4. Kết quả thực nghiệm và thảo luận

### 4.1. Thiết lập thí nghiệm

Các thí nghiệm được thực hiện trên tập dữ liệu giá đóng cửa hàng ngày của cổ phiếu VCB được mô tả tại mục 3.1, với tổng cộng 2.500 phiên giao dịch từ tháng 01/2015 đến tháng 01/2025. Dữ liệu được chia theo trình tự thời gian, trong đó 80% cho huấn luyện, 20% cho kiểm tra, nhằm bảo toàn cấu trúc chuỗi và tránh rò rỉ thông tin. Trong tập huấn luyện, 10% dữ liệu được tách ra làm tập kiểm định để hướng dẫn quá trình dừng sớm (early stopping) và tối ưu siêu tham số bằng PSO.

Các mô hình LSTM, GRU và BiLSTM đều được huấn luyện bằng thuật toán tối ưu Adam với hàm mất mát MSE. Số vòng lặp tối đa được đặt là 150 epoch, kết hợp dừng sớm với ngưỡng kiên nhẫn (patience) bằng 10 để ngăn hiện tượng quá khớp và tiết kiệm chi phí tính toán. Các siêu tham số số lượng nút ẩn, tỷ lệ dropout, tốc độ học và kích thước batch được thiết lập ở giá trị mặc định cho mô hình gốc và được tối ưu tự động bằng PSO cho mô hình tối ưu hóa.

Các thí nghiệm được triển khai bằng Python, sử dụng TensorFlow/Keras để xây dựng mô hình và pyswarms để thực hiện giải thuật PSO. Hiệu năng mô hình được đánh giá dựa trên các chỉ số MSE, RMSE, MAE và  $R^2$  được định nghĩa tại mục 3.4. Các chỉ số đánh giá được tính toán sau khi dữ liệu dự báo được chuyển ngược từ thang chuẩn hóa về thang giá gốc, nhằm đảm bảo ý nghĩa kinh tế của các sai số dự báo.

### 4.2. Kết quả huấn luyện mô hình gốc

Trước tiên, ba kiến trúc RNN (LSTM, GRU, BiLSTM) được huấn luyện với siêu tham số cố định (không tối ưu hóa) nhằm thiết lập đường cơ sở so sánh. Kết quả trên tập kiểm tra được trình bày trong Bảng 2.

**Bảng 2.** Hiệu năng của các mô hình RNN gốc (chưa tối ưu)

Mô hình	Loại	MSE	RMSE	MAE	$R^2$
LSTM	Gốc	3,0420	1,7441	1,4232	0,8008
GRU	Gốc	0,9357	0,9673	0,7786	0,9387
BiLSTM	Gốc	2,8425	1,6860	1,4895	0,8138

Kết quả tối ưu siêu tham số cho thấy giải thuật PSO đã tìm được các cấu hình phù hợp cho từng kiến trúc RNN. Có thể nhận thấy rằng số nút ẩn tối ưu ở tầng thứ nhất có xu hướng nằm ở mức cao, phản ánh nhu cầu tăng khả năng biểu diễn của mô hình khi xử lý chuỗi giá cổ phiếu có tính biến động. Điều này cũng lý giải cho việc không gian tìm kiếm của số nút ẩn được

mở rộng đến 256 nút, giúp PSO linh hoạt hơn trong quá trình khám phá nghiệm tối ưu. Kết quả thực nghiệm cũng cho thấy GRU vượt trội hơn cả LSTM và BiLSTM ở RMSE và  $R^2$ , chứng tỏ khả năng nắm bắt quan hệ tuần tự tốt hơn ngay cả khi chưa tối ưu siêu tham số. Tuy nhiên, giá trị RMSE vẫn còn khá cao, hàm ý rằng còn dư địa để cải thiện dự báo thông qua tối ưu hóa.

#### 4.3. Kết quả huấn luyện mô hình được tối ưu bằng PSO

Sau khi áp dụng giải thuật PSO để tìm cấu hình siêu tham số tốt nhất cho từng mô hình, các mô hình được huấn luyện lại với tham số tối ưu và đánh giá trên tập kiểm tra. Kết quả được trình bày trong Bảng 3.

**Bảng 3.** Hiệu năng của các mô hình RNN sau khi tối ưu bằng PSO

Mô hình	Loại	MSE	RMSE	MAE	$R^2$
LSTM	Tối ưu	1,1167	1,0567	0,8887	0,9269
GRU	Tối ưu	0,4693	0,6851	0,4972	0,9693
BiLSTM	Tối ưu	1,1344	1,0651	0,8682	0,9257

Kết quả cho thấy tối ưu hóa bằng PSO giúp giảm đáng kể MSE và RMSE ở cả ba mô hình. Đặc biệt, GRU sau khi tối ưu hóa bằng PSO đạt hiệu năng tốt nhất (RMSE = 0,6851 thấp nhất, và  $R^2 = 0,9693$  cao nhất). Điều này cho thấy GRU có khả năng cân bằng tốt giữa độ phức tạp mô hình và khả năng học các phụ thuộc ngắn hạn trong chuỗi giá cổ phiếu.

#### 4.4. So sánh hiệu năng của các mô hình trước và sau tối ưu

Để làm rõ hiệu quả của PSO, Bảng 4 so sánh hiệu năng của từng mô hình trước và sau khi tối ưu.

**Bảng 4.** So sánh mô hình gốc và mô hình tối ưu bằng PSO (kèm % cải thiện)

Mô hình	RMSE (Gốc)	RMSE (Tối ưu)	$\Delta$ RMSE (%) ↓	$R^2$ (Gốc)	$R^2$ (Tối ưu)	$\Delta$ $R^2$ ↑
BiLSTM	1,6860	1,0651	36,8%	0,8138	0,9257	+0,1119
GRU	0,9673	0,6851	29,2%	0,9387	0,9693	+0,0306
LSTM	1,7441	1,0567	39,4%	0,8008	0,9269	+0,1261

Sau khi áp dụng PSO, GRU đạt cấu hình tối ưu như Bảng 5. Cấu hình này giúp giảm RMSE từ 0,9673 xuống 0,6851 (giảm 29,2%) và nâng  $R^2$  lên 0,9693. Đây cũng chính là mức cao nhất trong ba mô hình.

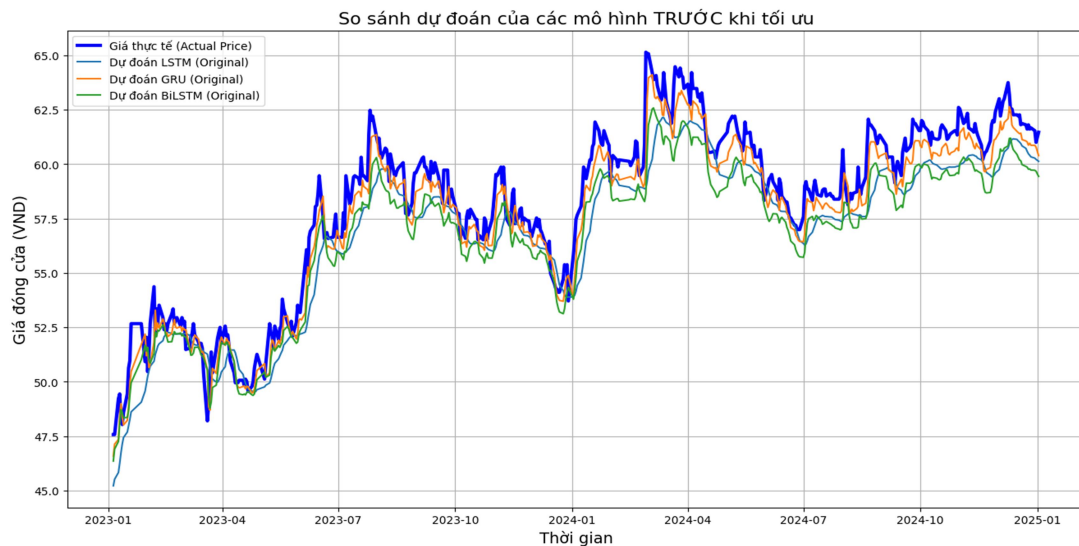
**Bảng 5.** Cấu hình siêu tham số tối ưu cho GRU sau khi áp dụng PSO

Tham số	Giá trị tối ưu
Số nút ẩn tầng 1 (units1)	192
Số nút ẩn tầng 2 (units2)	96
Dropout	0,27
Learning rate	0,0023
Batch size	32
Epochs (train lại)	150

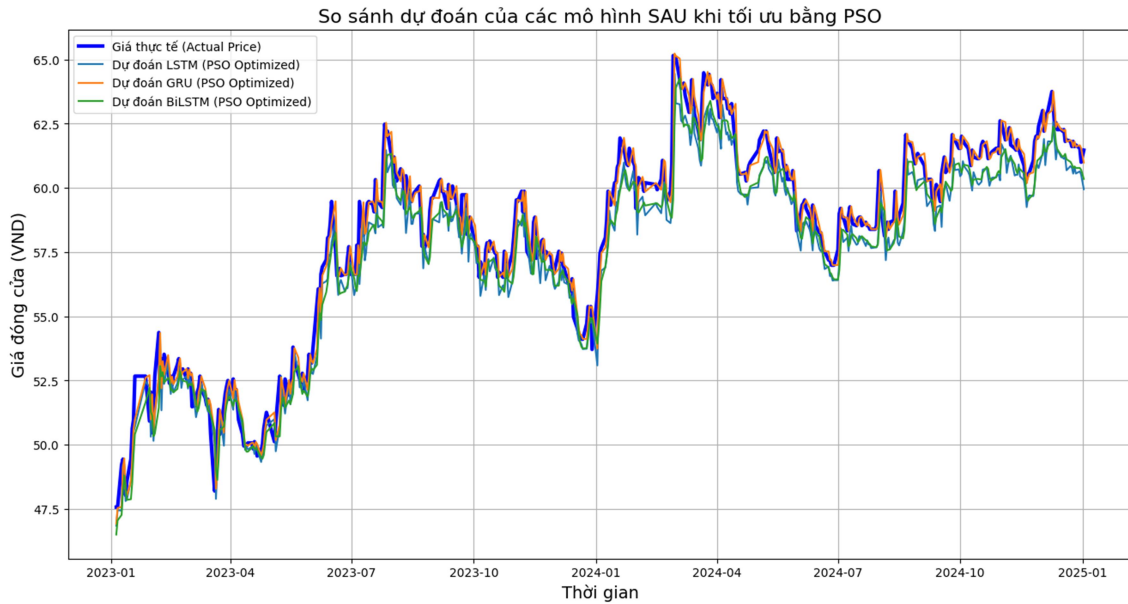
Điều này cho thấy GRU tận dụng tốt hơn thông tin tuần tự khi được điều chỉnh đúng mức độ phức tạp. Số tham số ít hơn LSTM giúp giảm nguy cơ quá khớp trong tập dữ liệu cỡ trung bình, trong khi cổng cập nhật và cổng đặt lại giúp mạng giữ được quan hệ dài hạn. Kết quả này củng cố nhận định rằng GRU là một trong những lựa chọn ưu tiên cho bài toán dự báo giá cổ phiếu tại thị trường Việt Nam.

#### 4.5. Trực quan hóa kết quả

Hình 3 và Hình 4 minh họa giá dự báo so với giá thực tế của các mô hình LSTM, GRU và Bi-LSTM trước và sau khi tối ưu.



**Hình 3.** Dự báo của GRU gốc bám sát xu hướng chung nhưng còn sai lệch đáng kể tại các giai đoạn biến động mạnh



**Hình 4.** Dự báo của GRU tối ưu bằng PSO gần với giá thực tế hơn, biên độ sai số thu hẹp rõ rệt, phản ánh sự cải thiện đã được thể hiện ở các chỉ số định lượng

Kết quả thực nghiệm cho thấy việc áp dụng PSO để tối ưu siêu tham số giúp cải thiện đáng kể hiệu năng dự báo của cả ba mô hình RNN. Bằng cách tìm kiếm có hệ thống trong không gian siêu tham số, PSO xác định được cấu hình cân bằng giữa độ phức tạp và khả năng khái quát hóa, từ đó giảm sai số trên cả tập kiểm định và kiểm tra.

GRU tiếp tục chứng minh là mô hình hiệu quả nhất, cả trước và sau khi tối ưu, nhờ cấu trúc gọn nhẹ và ít tham số hơn so với LSTM, giúp hạn chế quá khớp trong bối cảnh dữ liệu không quá lớn. BiLSTM mặc dù tận dụng được thông tin hai chiều nhưng độ phức tạp cao có thể không mang lại lợi ích tương xứng trong bài toán dự báo một bước trước (one-step ahead).

Về mặt ứng dụng, các kết quả này có ý nghĩa thực tiễn cho nhà đầu tư và nhà quản lý danh mục. Dự báo chính xác hơn giá đóng cửa giúp tối ưu hóa chiến lược mua – bán, ra quyết định phân bổ vốn hợp lý và cải thiện quản trị rủi ro. Hơn nữa, quy trình tối ưu được xây dựng trong nghiên cứu này có thể áp dụng cho các cổ phiếu hoặc chỉ số khác trên thị trường Việt Nam, hỗ trợ phát triển hệ thống giao dịch thuật toán (algorithmic trading) và ra quyết định dựa trên dữ liệu.

## 5. Hàm ý quản trị và chính sách

Kết quả nghiên cứu mang lại một số hàm ý quan trọng đối với quản trị đầu tư và điều hành chính sách tài chính, đặc biệt trong bối cảnh thị trường chứng khoán Việt Nam đang

hướng tới chuyển đổi số và ứng dụng các phương pháp phân tích dựa trên dữ liệu. Trước hết, về góc độ quản trị đầu tư, kết quả thực nghiệm cho thấy mô hình GRU được tối ưu hóa bằng giải thuật PSO có khả năng dự báo xu hướng biến động giá ngắn hạn với độ chính xác cao hơn so với các cấu hình mặc định. Do đó, mô hình này có thể được sử dụng như một công cụ hỗ trợ phân tích, giúp nhà đầu tư và các tổ chức tài chính cải thiện chất lượng thông tin đầu vào trong quá trình đánh giá thị trường và xây dựng kịch bản đầu tư, thay vì dựa hoàn toàn vào kinh nghiệm hoặc các chỉ báo truyền thống.

Bên cạnh đó, trong quản trị rủi ro danh mục, các mô hình dự báo có độ chính xác cao giúp các nhà quản lý quỹ và tổ chức tài chính ước lượng tốt hơn mức độ biến động và rủi ro tiềm ẩn của thị trường, từ đó hỗ trợ quá trình giám sát rủi ro, điều chỉnh cơ cấu danh mục và phân bổ nguồn lực một cách thận trọng hơn. Việc tích hợp các mô hình dự báo dựa trên học sâu vào hệ thống phân tích nội bộ có thể góp phần nâng cao tính nhất quán và minh bạch trong công tác quản trị rủi ro.

Đối với các thị trường mới nổi như Việt Nam, việc ứng dụng các mô hình dự báo dựa trên trí tuệ nhân tạo còn có ý nghĩa trong việc thu hẹp bất cân xứng thông tin giữa các nhóm nhà đầu tư, đồng thời thúc đẩy xu hướng ra quyết định dựa trên dữ liệu và bằng chứng thực nghiệm. Điều này góp phần cải thiện chất lượng hoạt động của thị trường và hướng tới một môi trường đầu tư minh bạch, hiệu quả hơn.

Ngoài ra, kết quả nghiên cứu cũng mang lại một số hàm ý đối với cơ quan quản lý và hoạch định chính sách vĩ mô. Các mô hình dự báo giá có độ chính xác cao có thể được xem xét tích hợp vào các hệ thống giám sát thị trường nhằm hỗ trợ phát hiện sớm các dấu hiệu biến động bất thường hoặc rủi ro tích tụ, từ đó cung cấp thêm cơ sở thông tin cho quá trình theo dõi và ổn định thị trường tài chính.

Tóm lại, nghiên cứu này cho thấy các mô hình dự báo dựa trên học sâu, khi được tối ưu hóa siêu tham số một cách hệ thống, không chỉ mang ý nghĩa về mặt kỹ thuật mà còn đóng vai trò là công cụ hỗ trợ phân tích quan trọng trong quản trị đầu tư và hoạch định chính sách tài chính hiện đại. Khung tối ưu hóa kết hợp PSO và GRU được đề xuất phù hợp với xu thế ứng dụng trí tuệ nhân tạo và chuyển đổi số trong lĩnh vực tài chính tại Việt Nam.

## 6. Kết luận

Nghiên cứu này đã đề xuất và đánh giá hiệu quả của việc kết hợp các mô hình mạng nơ-ron hồi quy (LSTM, GRU và BiLSTM) với giải thuật tối ưu bầy đàn hạt (PSO) trong bài toán dự báo giá đóng cửa cổ phiếu VCB. Bài toán được thiết lập dưới dạng dự báo chuỗi thời gian đơn

biến với kỹ thuật của số trượt  $10 \rightarrow 1$ , phù hợp với đặc điểm dữ liệu giá cổ phiếu hàng ngày tại thị trường Việt Nam.

Kết quả thực nghiệm cho thấy việc tối ưu hóa siêu tham số bằng PSO giúp cải thiện đáng kể độ chính xác dự báo của tất cả các mô hình được xét so với các cấu hình mặc định. Trong số đó, mô hình GRU sau khi tối ưu đạt hiệu năng tốt nhất, thể hiện qua việc giảm sai số dự báo và gia tăng hệ số xác định  $R^2$  trên tập kiểm tra. Điều này cho thấy vai trò quan trọng của việc lựa chọn siêu tham số phù hợp trong việc nâng cao khả năng học và tổng quát hóa của các mô hình học sâu.

Bên cạnh những kết quả đạt được, nghiên cứu cũng tồn tại một số hạn chế. Cụ thể, thực nghiệm chỉ được tiến hành trên một mã cổ phiếu vốn hóa lớn với mức độ biến động tương đối ổn định, và bài toán dự báo mới dừng ở khung ngắn hạn một bước trước. Do đó, các hướng nghiên cứu tiếp theo có thể mở rộng sang nhóm cổ phiếu vốn hóa vừa và nhỏ, xem xét dự báo đa bước, cũng như tích hợp thêm các biến đầu vào hoặc phương pháp tối ưu nâng cao nhằm đánh giá sâu hơn tính tổng quát của khung phương pháp đề xuất.

Tóm lại, nghiên cứu cung cấp bằng chứng thực nghiệm cho thấy việc kết hợp các mô hình học sâu với tối ưu hóa siêu tham số là một hướng tiếp cận hiệu quả trong dự báo giá cổ phiếu, đồng thời góp phần làm giàu thêm các nghiên cứu ứng dụng trí tuệ nhân tạo trong lĩnh vực tài chính tại Việt Nam.

## Tài liệu tham khảo

1. J. S. Bhullar (2024), Developing a Time Series Financial Market Forecasting Model Based on Machine Learning Tools and Techniques, *IJTBM*, vol. 14, no. 1, pp. 78–87, doi: 10.37648/ijtbm.v14i01.010.
2. S. Syaharuddin (2024), Time-Series Analysis in Financial Prediction: A Literature Review, *Sainstek: Jurnal Sains dan Teknologi*, doi: <http://dx.doi.org/10.31958/js.v16i2.13117>.
3. G. J. Ross (2013), Modeling Financial Volatility in the Presence of Abrupt Changes, *Physica A: Statistical Mechanics and its Applications*, vol. 392, no. 2, pp. 350–360, doi: 10.1016/j.physa.2012.08.015.
4. T.-N. Nguyen, M.-N. Tran, D. Gunawan, and R. Kohn (2022), A Statistical Recurrent Stochastic Volatility Model for Stock Markets, arXiv: arXiv:1906.02884. doi: 10.48550/arXiv.1906.02884.

5. M. Wiese, R. Knobloch, R. Korn, and P. Kretschmer (2020), "Quant GANs: Deep Generation of Financial Time Series," *Quantitative Finance*, vol. 20, no. 9, pp. 1419–1440, doi: 10.1080/14697688.2020.1730426.
6. Y. Gao, R. Wang, and E. Zhou (2021), "Stock Prediction Based on Optimized LSTM and GRU Models," *Scientific Programming*, vol. 2021, pp. 1–8, doi: 10.1155/2021/4055281.
7. Y. L. Sukestiyarno, D. T. Wiyanti, L. Azizah, and W. Widada (2024), "Algorithm Optimizer in GA-LSTM for Stock Price Forecasting," *Contemp. Math.*, doi: 10.37256/cm.5120243367.
8. G. Kumar, U. P. Singh, and S. Jain (2022), "An adaptive particle swarm optimization-based hybrid long short-term memory model for stock price time series forecasting," *Soft Computing*, vol. 26, no. 22, pp. 12115–12135, doi: 10.1007/s00500-022-07451-8.
9. N. T. Co, H. H. Son, N. T. Hoang, T. T. P. Lien, and T. M. Ngoc (2020), "Comparison Between ARIMA and LSTM-RNN for VN-Index Prediction," doi: 10.1007/978-3-030-39512-4\_168.
10. S. Pasak and R. Jayadi (2023), "Investment Decision on Cryptocurrency: Comparing Prediction Performance Using ARIMA and LSTM," *Journal of Information Systems and Informatics*, vol. 5, pp. 407–427, doi: 10.51519/journalisi.v5i2.473.
11. N. T. Hương and B. Q. Trung (2015), "Ứng dụng mô hình kết hợp ARIMA-GARCH để dự báo chỉ số VN-Index," *Tạp chí Khoa học và Công nghệ - Đại học Đà Nẵng*, pp. 118–122.
12. B. Aditya Pai, L. Devareddy, S. Hegde, and B. S. Ramya (2022), "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, pp. 653–662, doi: 10.1007/978-981-16-1342-5\_50.
13. Y. Khodke and S. Deshpande (2023), "Stock Price Prediction Using LSTM and GRU," *IJRASET*, vol. 11, no. 6, pp. 1163–1167, doi: 10.22214/ijraset.2023.53826.
14. M. J. Hamayel and A. Y. Owda (2021), "A Novel Cryptocurrency Price Prediction Model Using GRU, LSTM and bi-LSTM Machine Learning Algorithms," *AI*, vol. 2, no. 4, pp. 477–496, doi: 10.3390/ai2040030.

15. F. Barez, P. Bilokon, A. Gervais, and N. Lisitsyn (2023), Exploring the Advantages of Transformers for High-Frequency Trading, arXiv: arXiv:2302.13850. doi: 10.48550/arXiv.2302.13850.
16. X. Zhang (2022), Financial Time Series Forecasting Based on LSTM Neural Network optimized by Wavelet Denoising and Whale Optimization Algorithm, AJCIS, vol. 5, no. 7, doi: 10.25236/ajcis.2022.050701.
17. N. A. Hitam, A. R. Ismail, and F. Saeed (2019), An Optimized Support Vector Machine (SVM) based on Particle Swarm Optimization (PSO) for Cryptocurrency Forecasting, Procedia Computer Science, vol. 163, pp. 427–433, doi: 10.1016/j.procs.2019.12.125.
18. P. Deka, M. Cordeiro-Costas, R. Pérez-Orozco, M. Chabiński, and A. Szlęk (2025), Novel NSGA-II optimized LSTM and GRU models for short-term forecasting of residential heating load, Energy and Buildings, vol. 344, p. 115999, doi: 10.1016/j.enbuild.2025.115999.
19. W. Zhai (2023), Stock Price Prediction Based on Optimized LSTM Model, in Proceedings of the 2nd International Conference on Financial Innovation, FinTech and Information Technology, Chongqing, China, EAI, 2023. doi: 10.4108/eai.7-7-2023.2338038.
20. S. Hochreiter and J. Schmidhuber (1997), Long Short-Term Memory, Neural Computation, vol. 9, no. 8, pp. 1735–1780, doi: 10.1162/neco.1997.9.8.1735.