




## Journal of Mining and Earth Sciences

Website: <https://jmes.humg.edu.vn>



# Assessing AI model performance in time-series GNSS data analysis with different neural network structures



Truong Xuan Tran <sup>1</sup>, Tinh Duc Le <sup>2</sup>, Thao Phuong Thi Do <sup>1</sup>, Man Van Pham <sup>2</sup>, Trong Gia Nguyen <sup>1,3\*</sup>

<sup>1</sup> Hanoi University of Mining and Geology, Hanoi, Vietnam

<sup>2</sup> Naval Command, Vietnam Naval Service, Haiphong, Vietnam

<sup>3</sup> Geodesy and Environment Research Group, Hanoi University of Mining and Geology, Hanoi, Vietnam

### ARTICLE INFO

#### Article history:

Received 30<sup>th</sup> Aug. 2024

Revised 12<sup>th</sup> Dec. 2024

Accepted 04<sup>th</sup> Jan. 2025

#### Keywords:

Artificial Intelligent,  
Gamit/Globk,  
GNSS time-series,  
Vertical Land Movement.

### ABSTRACT

Artificial intelligence is widely used in time series data analysis in general, and specifically for GNSS time series data. The performance of each AI model used for analyzing GNSS time series data depends on the selection of the optimization function, loss function, the number of nodes in the hidden layers, and the number of epochs. The GRU (Gated Recurrent Unit) deep learning model has been proven to perform well in time series prediction. This paper presents the results of evaluating the performance of the GRU model with different parameter selections mentioned above. The input data for the model is the vertical coordinate component from the HYEN CORS station from 10/8/2019 to 18/3/2022, which is the result of analyzing GNSS data collected at this station using the Gamit/Globk software. The processing results show that when using the Adam optimizer and MSE loss function, the model's performance decreases rapidly as the number of nodes in the hidden layer reduces from 200÷100. In this case, the model's performance metrics include an  $R^2$  decrease from 85÷20%, and the MAE value increases from 3.77÷8.37 mm. When replacing the MSE loss function with the Huber loss function, the model's performance significantly improves, with the  $R^2$  increasing by 7%, and the MAE value decreasing from 3.77÷3.21mm. This is a relatively high performance for predicting data using an AI model with a training-to-testing ratio of 60÷40%.

Copyright © 2025 Hanoi University of Mining and Geology. All rights reserved.

\*Corresponding author

E - mail: [nguyengiatrong@humg.edu.vn](mailto:nguyengiatrong@humg.edu.vn)

DOI: 10.46326/JMES.2025.66(1).05



## Tạp chí Khoa học Kỹ thuật Mỏ - Địa chất

Trang điện tử: <https://tapchi.humg.edu.vn>



# Đánh giá hiệu suất của mô hình trí tuệ nhân tạo khi phân tích dữ liệu GNSS theo thời gian với số nút trong lớp ẩn và hàm mất mát khác nhau

Trần Xuân Trường<sup>1</sup>, Lê Đức Tình<sup>1</sup>, Đỗ Thị Phương Thảo<sup>1</sup>, Phạm Văn Mẫn<sup>2</sup>, Nguyễn Gia Trọng<sup>1,3\*</sup>

<sup>1</sup> Trường Đại học Mỏ - Địa chất, Hà Nội, Việt Nam

<sup>2</sup> Bộ tham mưu, Quân chủng Hải quân, Hải Phòng, Việt Nam.

<sup>3</sup> Nhóm nghiên cứu Trắc địa cao cấp - môi trường, Trường Đại học Mỏ - Địa chất, Hà Nội, Việt Nam

### THÔNG TIN BÀI BÁO

#### Quá trình:

Nhận bài 30/8/2024

Sửa xong 12/12/2024

Chấp nhận đăng 04/01/2025

#### Từ khóa:

Chuỗi dữ liệu GNSS theo thời gian,

Chuyển dịch thẳng đứng vỏ trái đất,

Gamit/Globk,

Trí tuệ nhân tạo.

### TÓM TẮT

Trí tuệ nhân tạo đang được sử dụng một cách rộng rãi trong phân tích chuỗi dữ liệu theo thời gian nói chung và dữ liệu GNSS theo thời gian nói riêng. Hiệu suất của mỗi mô hình trí tuệ nhân tạo sử dụng để phân tích chuỗi dữ liệu GNSS theo thời gian phụ thuộc vào việc lựa chọn hàm tối ưu, hàm mất mát, số nút trong lớp ẩn cũng như số epochs. Mô hình học sâu GRU (Gated Recurrent Unit) đã được khẳng định có hiệu suất tốt trong dự đoán chuỗi dữ liệu theo thời gian. Bài báo này giới thiệu kết quả xác định hiệu suất của mô hình GRU khi lựa chọn các thông số nêu trên khác nhau. Dữ liệu đầu vào của mô hình là thành phần tọa độ theo phương thẳng đứng của trạm CORS HYEN trong khoảng thời gian từ 10/8/2019 đến 18/3/2022, là kết quả của việc phân tích dữ liệu GNSS thu nhận được tại trạm này bằng phần mềm Gamit/Globk. Kết quả xử lý cho thấy, khi lựa chọn hàm tối ưu là Adam, hàm mất mát là MSE thì hiệu suất của mô hình giảm rất nhanh khi số nút trong lớp ẩn giảm từ 200÷100. Các giá trị đặc trưng cho hiệu suất của mô hình trong trường hợp này bao gồm  $R^2$  giảm từ 85÷20%, giá trị MAE tăng từ 3,77÷8,37 mm. Khi thay thế hàm mất mát MSE bằng hàm mất mát Huber, hiệu suất của mô hình được cải thiện đáng kể thông qua chỉ số phù hợp của mô hình  $R^2$  tăng 7% và giá trị MAE giảm từ 3,77÷3,21 mm. Đây là hiệu suất tương đối cao trong dự đoán dữ liệu với mô hình trí tuệ nhân tạo mà tỷ lệ giữa tập huấn luyện và tập kiểm tra tương ứng là 60÷40%.

© 2025 Trường Đại học Mỏ - Địa chất. Tất cả các quyền được bảo đảm.

\*Tác giả liên hệ

E - mail: [nguyengiatrong@humg.edu.vn](mailto:nguyengiatrong@humg.edu.vn)

DOI: 10.46326/JMES.2025.66(1).05

## 1. Mở đầu

Trí tuệ nhân tạo (AI) đóng vai trò quan trọng trong phân tích dữ liệu theo chuỗi thời gian, đặc biệt trong việc xử lý các chuỗi dữ liệu lớn và phức tạp. Các mô hình AI như Mạng Nơ-ron tái phát (RNN) và Bộ nhớ ngắn - dài hạn (LSTM) có khả năng học và dự đoán các xu hướng, mẫu, hoặc các sự kiện bất thường trong chuỗi thời gian. Nhờ khả năng tự động hóa và tối ưu hóa quá trình phân tích, AI giúp cải thiện đáng kể độ chính xác và tốc độ dự đoán trong nhiều lĩnh vực như tài chính, y tế, và hệ thống định vị GNSS (Xie và nnk., 2024).

Khi xây dựng, huấn luyện mô hình, các thông số cài đặt cần phải lựa chọn bao gồm độ trễ, kích thước cửa sổ trượt, số tầng, số lớp ẩn, số nơ ron trong mỗi lớp, phương pháp tối ưu (Alpaydin, 2020),... Khi sử dụng số nút quá ít, mô hình không đủ phức tạp để học được các đặc trưng của dữ liệu, dẫn đến kết quả kém chính xác. Trong trường hợp ngược lại, mô hình trở nên quá phức tạp và học cả những nhiễu, sai số từ dữ liệu huấn luyện. Điều này khiến mô hình hoạt động tốt trên dữ liệu huấn luyện nhưng lại kém hiệu quả trên dữ liệu mới (Ciaburro & Venkateswaran, 2017).

GNSS/CORS với ưu điểm cho phép xác định các thành phần tọa độ với độ chính xác cao được ứng dụng trong nhiều mục đích khác nhau (Rizos, 2008). Ưu điểm rất lớn khi ứng dụng dữ liệu trạm CORS trong nghiên cứu chuyển dịch kiến tạo mảng hoặc sụt lún bề mặt đất đó là xác định quy luật chuyển dịch bên cạnh lượng chuyển dịch theo thời gian nhờ chuỗi dữ liệu quan trắc theo thời gian (Andreas và nnk., 2018; Uzel và nnk., 2013).

Để phân tích chuỗi dữ liệu GNSS theo thời gian, có thể sử dụng các mô hình toán học truyền thống (Goudarzi, 2016) hoặc ứng dụng trí tuệ nhân tạo (Gao và nnk., 2022; Özbey và nnk., 2024). Gao và nnk. (2022) đã ứng dụng các mô hình học máy như LSTM, GBĐT, SVM để phân tích chuỗi dữ liệu GNSS theo thời gian với kết quả nâng cao độ chính xác lên khoảng 30% so với sử dụng phương pháp số bình phương nhỏ nhất.

Chuỗi dữ liệu thu nhận được từ các trạm CORS tại các khu vực thường xuyên xảy ra động đất đã được Crocetti và nnk. (2021) ứng dụng thuật toán rừng ngẫu nhiên phân tích để phát hiện ra các thời điểm gián đoạn trong chuỗi dữ liệu do ảnh hưởng của động đất với kết quả độ chính xác F-Score xấp xỉ 0,8.

Các mô hình VMD-LSTM, DVMD-LSTM đã được Chen và nnk. (2024) ứng dụng để phân tích các thành phần tọa độ theo thời gian thu được từ các trạm CORS với kết quả dự đoán vận tốc chuyển dịch của mô hình DVMD-LSTM cao hơn đến 36% do khả năng loại nhiễu trong chuỗi giá trị đo. Mô hình GRU đã được Le và nnk. (2024) đánh giá khả năng dự đoán chuyển dịch thẳng đứng vỏ trái đất từ dữ liệu thu được của hai trạm GNSS CORS tại Việt Nam. Trong nghiên cứu này, kích thước lô và số lần lặp được thay đổi để đánh giá hiệu suất của mô hình.

Hàm mất mát là một thành phần quan trọng trong học máy, dùng để đánh giá sai số giữa giá trị dự đoán và giá trị thực. Nó giúp tối ưu hóa quá trình học bằng cách điều chỉnh mô hình sao cho sai số này giảm dần. Có nhiều loại hàm mất mát khác nhau, phù hợp với từng bài toán như phân loại, hồi quy hay học không giám sát. Mỗi hàm mất mát đều có đặc điểm riêng, và việc chọn lựa hàm phù hợp có thể ảnh hưởng lớn đến hiệu suất của mô hình (Wang và nnk., 2020).

Mục tiêu của nghiên cứu này là khảo sát hiệu suất của mô hình trí tuệ nhân tạo GRU với số nút, hàm mất mát khác nhau.

## 2. Dữ liệu và phương pháp nghiên cứu

Dữ liệu sử dụng trong nghiên cứu này là dữ liệu thu nhận được bởi trạm GNSS CORS có tên HYEN (Hình 1) được cung cấp bởi Cục Đo đạc, Bản đồ và Thông tin địa lý Việt Nam với thông tin chi tiết được cho trong Bảng 1.

*Bảng 1. Thông tin về dữ liệu được sử dụng trong nghiên cứu.*

Tên trạm	Thời gian		Loại máy thu	Loại ăng ten	Tần suất thu tín hiệu (giây)
	Bắt đầu	Kết thúc			
HYEN	10/8/2019	18/3/2022	LEICA GR50	LEIAR25 R4 LEIT	30

Để xử lý dữ liệu GNSS theo chuỗi thời gian với yêu cầu độ chính xác cao cần sử dụng các phần mềm như Gamit/Globk (Cetin và nnk., 2019; Khorrami và nnk., 2024), Bernese (Haritonova và nnk., 2015),...

Dữ liệu của trạm HYEN trong trường hợp này được xử lý bằng phần mềm Gamit/Globk với phương pháp xử lý cũng như kết quả được công



Hình 1. Vị trí trạm GNSS CORS - HYEN.

bổ bởi nhóm nghiên cứu của Nguyễn Gia Trọng và cộng sự (Trọng và nnk., 2022). Kết quả của quá trình xử lý thu được các thành phần tọa độ hàng ngày của điểm. Hình 2 thể hiện giá trị thành phần theo phương thẳng đứng của điểm CTHO. Số liệu xác định được như trên sau đó được biên tập thành định dạng dữ liệu theo chuẩn quy định để dự báo với mô hình Gated Recurrent Unit (GRU).

Mô hình GRU có nhiều ưu điểm trong phân tích chuỗi dữ liệu theo thời gian. Đầu tiên, GRU khắc phục được vấn đề mất dần thông tin qua thời gian của mạng nơ-ron hồi tiếp truyền thống (RNN) nhờ cơ chế cổng giúp kiểm soát thông tin được lưu giữ hoặc bỏ qua. So với Long Short-Term


Memory (LSTM), GRU có cấu trúc đơn giản hơn vì không sử dụng cổng đầu ra, từ đó giảm bớt số lượng tham số cần huấn luyện, giúp tốc độ huấn luyện nhanh hơn. Mô hình GRU cũng thể hiện tốt trong việc xử lý các chuỗi dữ liệu dài mà không yêu cầu bộ nhớ lớn (Chen và nnk., 2024; Chollet, 2021).

Trong nghiên cứu này, lớp GRU xử lý dữ liệu tuần tự và được điều khiển bởi các cơ chế cổng (gates). Với trạng thái ẩn tại thời điểm  $t$ , công thức của GRU là:

Đối với cổng cập nhật:

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





Hình 2. Kết quả xác định chuyển dịch theo phương độ cao của điểm CTHO sử dụng phần mềm Gamit/Globk.

Trong đó:  $z_t$  - cổng cập nhật, xác định mức độ duy trì trạng thái trước đó  $h_{t-1}$ ;  $W_z$  - trọng số đầu vào đến cổng cập nhật;  $U_z$  - trọng số trạng thái ẩn trước đến cổng cập nhật;  $b_z$  - độ lệch của giá trị ước lượng được;  $x_t$  là ma trận chứa thông tin đầu vào tại thời điểm  $t$ .

Đối với cổng xóa:

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (2)$$

Với:  $r_t$  - cổng xóa, xác định mức độ "quên" thông tin từ trạng thái trước đó;  $W_r$ ,  $U_r$ ,  $b_r$  tương tự như các thành phần của  $z_t$ .

Trạng thái ẩn tạm thời:

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (3)$$

Trong đó:  $\odot$  - phép nhân phần tử (element-wise);  $W_h$  là ma trận trọng số áp dụng cho đầu vào  $x_t$ ;  $b_h$  là véc tơ được thêm vào sau các phép biến đổi tuyến tính để tăng tính linh hoạt của mô hình và giúp mạng GRU có thể học được nhiều mối quan hệ phức tạp hơn.

Trạng thái ẩn đầu ra:

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \tilde{h}_t \quad (4)$$

Chu trình tính với mô hình GRU như đã miêu tả ở trên được cụ thể hóa trong Hình 3.

Phương pháp xử lý dữ liệu trong trường hợp này được thể hiện trên Hình 4.

Hiệu suất của mô hình được đánh giá thông qua các thông số như sau (Bishop & Nasrabadi, 2006):

- MSE: là giá trị trung bình của bình phương sai số giữa giá trị dự đoán và giá trị thực tế.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

Trong đó:  $y_i$  - giá trị thực tế;  $\hat{y}_i$  - giá trị dự đoán;  $n$  - số lượng điểm dữ liệu; RMSE - căn bậc hai của MSE, giúp đưa sai số về cùng đơn vị với biến đầu ra.

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

- MAE - đo lường sai số trung bình tuyệt đối giữa các giá trị dự đoán và giá trị thực tế.

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

- F1-Score :

$$F1\text{-Score} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

Precision (Độ chính xác) :  $TP / (TP + FP)$

Recall (Độ nhạy) :  $TP / (TP + FN)$

- Kapa :

$$K = (P_o - P_e) / (1 - P_e) \quad (9)$$

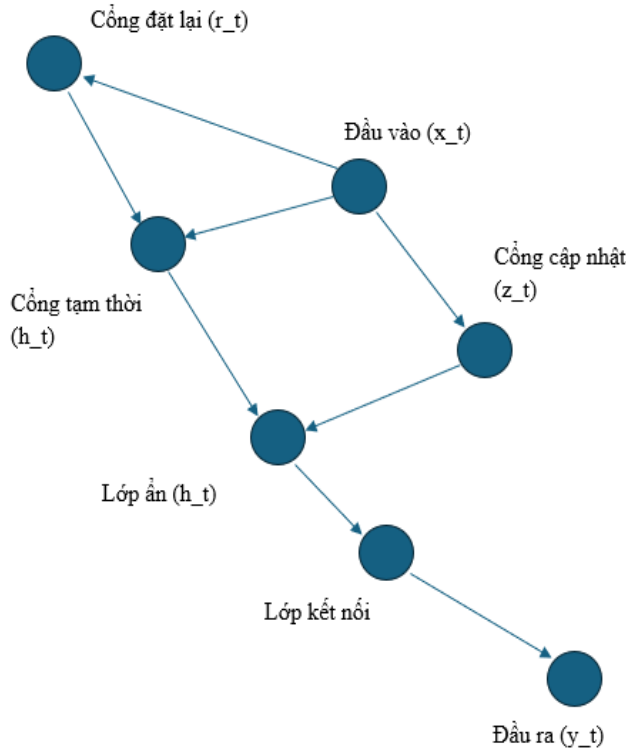
$P_0$  - Tỷ lệ quan sát được của các giá trị phù hợp giữa thực tế và dự đoán;  $P_e$  - Tỷ lệ giá trị phù hợp kỳ vọng nếu dự đoán là ngẫu nhiên; TP - True Positives, FP - False Positives, FN - False Negatives;

-  $R^2$  là đại lượng đo lường tỷ lệ phương sai của giá trị thực tế được giải thích bởi mô hình dự đoán và được xác định bởi công thức:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

### 3. Kết quả và thảo luận

Epochs và Batch-size là hai tham số quan trọng trong quá trình huấn luyện mô hình trí tuệ nhân tạo. Epochs biểu thị số lần toàn bộ tập dữ liệu được đưa qua mô hình trong quá trình huấn luyện,

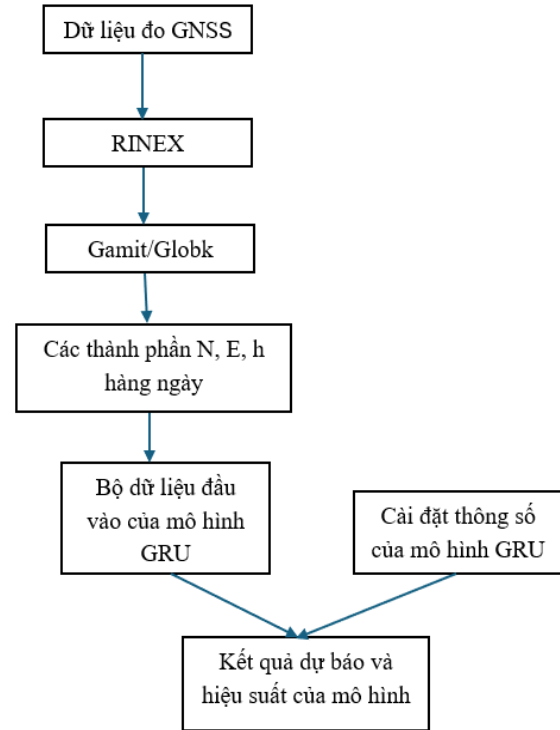


Hình 3. Tiến trình xử lý với hàm GRU.

giúp cải thiện khả năng học của mô hình qua nhiều chu kỳ. Batch-size là số mẫu dữ liệu được đưa vào mô hình trong mỗi lần cập nhật trọng số; nó ảnh hưởng đến tốc độ và độ chính xác của quá trình huấn luyện. Một batch-size nhỏ có thể dẫn đến huấn luyện nhanh nhưng không ổn định, trong khi batch-size lớn giúp mô hình ổn định hơn nhưng đòi hỏi nhiều tài nguyên tính toán. Việc lựa chọn đúng các tham số này rất quan trọng để đạt hiệu quả tối ưu.

Hàm mất mát (loss function) là một hàm dùng để đo lường sự sai lệch giữa giá trị dự đoán và giá trị thực tế trong quá trình huấn luyện mô hình học máy. Việc lựa chọn hàm mất mát phù hợp giúp tối ưu hóa hiệu suất của mô hình. Số nút trong lớp ẩn (hidden layer) cũng đóng vai trò quan trọng, ảnh hưởng đến khả năng học và biểu diễn các mối quan hệ trong dữ liệu. Số lượng nút càng nhiều, mô hình càng có khả năng học sâu và phức tạp hơn, nhưng cũng có thể dẫn đến hiện tượng quá khớp (overfitting) nếu không được điều chỉnh hợp lý.

Dựa trên phương pháp nghiên cứu được cho trong Hình 3, các công thức đánh giá hiệu suất mô hình từ công thức (5) đến công thức (10), nhóm



Hình 4. Sơ đồ khối của phương pháp dự đoán với mô hình GRU.

nghiên cứu đã xây dựng chương trình dự đoán với các phương án như sau:

- Bộ dữ liệu đầu vào được chia thành bộ dữ liệu huấn luyện và bộ dữ liệu kiểm tra với tỷ lệ 60% và 40%.
- Thay đổi số lượng nút trong mạng nơ ron với các giá trị 50, 100 và 200;
- Thay đổi số lượng epochs lần lượt là 50, 100 và 200;
- Batch\_size = 16.

Thuật toán tối ưu mô hình được lựa chọn là Adam, hàm mất mát sử dụng hàm MSE.

### 3.1 Kết quả đánh giá hiệu suất của mô hình khi thay đổi số nút

Kết quả dự đoán với số nút trong mạng nơ ron khác nhau được cho trong Bảng 2.

Bảng 2. Hiệu suất của mô hình GRU với số nút khác nhau.

Số nút	MSE (mm)	RMSE (mm)	MAE (mm)	R <sup>2</sup>	F1-Score	Kapa
200	24,85	4,99	3,77	0,8479	1,0	1,0
100	130,86	11,44	8,37	0,1994	0,8053	0,6105
50	501,44	22,39	16,54	-2,0680	0,6755	0,3526

Từ Bảng 2 có thể thấy, khi số nút được cài đặt là 200, hiệu suất của mô hình khá tốt thể hiện qua các thông số như MSE, RMSE, MAE là nhỏ nhất. Giá trị  $R^2 = 84,79\%$  cho thấy mức độ phù hợp khá cao của mô hình so với dữ liệu đầu vào. Tuy nhiên, vẫn còn tới xấp xỉ 15% nhiễu chưa xử lý hết.

Hiệu suất của mô hình có xu hướng giảm dần khi giá trị của số nút được cài đặt giảm. Trong trường hợp số nút là 50, mô hình dự báo lúc này không phù hợp với dữ liệu đầu vào thể hiện qua giá trị  $R^2 = -2,0680$  và giá trị MAE lên tới 16,54 mm.

Hình 5 và 6 dưới đây biểu diễn giá trị của thành phần h trong trường hợp sử dụng số nút khác nhau. Từ Hình 5 và 6 có thể thấy, giá trị dự đoán được còn tồn tại nhiễu dự đoán của mô hình cao có thể cần đưa thêm kỹ thuật làm mượt theo hàm trung bình di động hoặc sử dụng trình tối ưu khác để loại bớt nhiễu trong trường hợp này.

### 3.2 Kết quả hiệu suất của mô hình khi thay đổi số epochs

Để đánh giá hiệu suất của mô hình, mức độ phù hợp giữa giá trị của số nút với giá trị của epochs, đã tiến hành khảo sát với số epochs lần lượt thay đổi là 100, 150 và 200. Kết quả đánh giá như sau:


#### a. Kết quả đánh giá sự thay đổi của epochs khi số nút là 200

Từ Bảng 3 có thể thấy, hiệu suất của mô hình gần như không thay đổi khi thay đổi số epochs dao động từ 100÷200 trong trường hợp số nút là 200.


**Bảng 3.** Hiệu suất của mô hình GRU với số nút là 200 và số epochs khác nhau.

Epochs	MSE (mm)	RMSE (mm)	MAE (mm)	$R^2$	F1-Score	Kapa
200	24,85	4,99	3,77	0,8479	1,0	1,0
150	32,07	5,66	3,85	0,8038	0,9947	0,9895
100	29,22	5,41	3,93	0,8212	0,9947	0,9894

#### b. Kết quả đánh giá sự thay đổi của epochs khi số nút là 100.



**Hình 5.** Giá trị h dự đoán trên tập dữ liệu huấn luyện trong trường hợp số nút là 200, epochs = 200, batch\_size = 16.



**Hình 6.** Giá trị h dự đoán trên tập dữ liệu kiểm tra trong trường hợp số nút là 200, epochs = 200, batch\_size = 16.

Dữ liệu từ Bảng 4 cho thấy, trong trường hợp số nút trong lớp ẩn là 100, hiệu suất của mô hình không thay đổi đáng kể khi thay đổi số lượng epochs lần lượt là 200, 150 và 100.

*Bảng 4. Hiệu suất của mô hình GRU với số nút là 100 và số epochs khác nhau.*

Epochs	MSE (mm)	RMSE (mm)	MAE (mm)	R <sup>2</sup>	F1-Score	Kapa
200	130,86	11,44	8,37	0,1994	0,8053	0,6105
150	125,64	11,21	8,40	0,2313	0,8158	0,6316
100	128,52	11,34	8,64	0,2137	0,7737	0,5474

### 3.3 Kết quả hiệu suất của mô hình khi thay đổi hàm mất mát

Để khảo sát hiệu suất của mô hình trong trường hợp lựa chọn hàm mất mát khác nhau, đã lựa chọn hàm mất mát Huber để đánh giá hiệu suất dự đoán của mô hình.

Hàm mất mát Huber có ưu điểm nổi bật trong xử lý các bài toán hồi quy khi kết hợp tính chất của cả hàm mất mát bình phương và hàm trị tuyệt đối. Nó giúp giảm tác động của các ngoại lệ, đồng thời duy trì hiệu quả khi dữ liệu có nhiễu. Với khả năng điều chỉnh thông qua tham số chuyển tiếp giữa các giai đoạn hàm bình phương và trị tuyệt đối, Huber phù hợp với dữ liệu có nhiễu vừa phải, đảm bảo tính ổn định và chính xác cao trong các bài toán hồi quy (Meyer, 2021).

Kết quả đánh giá hiệu suất của mô hình trong trường hợp sử dụng hàm tối ưu Adam, hàm mất mát Huber được cho trong Bảng 5.

*Bảng 5. Hiệu suất của mô hình GRU với hàm tối ưu Adam, hàm mất mát Huber.*

Epochs	MSE (mm)	RMSE (mm)	MAE (mm)	R <sup>2</sup>	F1-Score	Kapa
200	13,21	3,64	3,21	0,9192	1,0	1,0

So sánh số liệu trong Bảng 2 và Bảng 5 có thể thấy:

- Giá trị RMSE giảm được 27% trong khi giá trị của MAE giảm được 15% khi thay hàm mất mát MSE bằng hàm mất mát Huber;

- Mức độ phù hợp của mô hình đã tăng lên đến 91,92% tương ứng với tỷ lệ nhiễu chỉ còn gần 8% (tương ứng tăng 6% so với trường hợp sử dụng hàm mất mát MSE).

Mức độ phù hợp của mô hình đã được thống kê như trên là mức độ phù hợp tương đối cao nếu so với kết quả của các tác giả (Vân Phong và nnk., 2023) khi phân tích dữ liệu GNSS theo chuỗi thời gian.


Đồ thị biểu diễn hàm mất mát, giá trị dự báo trên tập dữ liệu huấn luyện, tập dữ liệu kiểm tra được cho trong các Hình 7, 8 và 9.

## 4. Kết luận

Từ các kết quả nghiên cứu trong bài báo cho thấy, trí tuệ nhân tạo đang được sử dụng rộng rãi trong phân tích các loại dữ liệu theo chuỗi thời gian. Hiệu suất của mô hình trí tuệ phụ thuộc vào số nơ ron (số nút) trong mỗi lớp ẩn, số epochs cũng như hàm tối ưu, hàm mất mát được lựa chọn.


Khi sử dụng hàm GRU, hàm tối ưu Adam, hàm mất mát MSE hiệu suất của mô hình giảm khá nhanh khi số nút trong lớp ẩn giảm từ 200÷100. Mức độ phù hợp của mô hình (chỉ số R<sup>2</sup>) giảm từ 84,79% (đối với trường hợp số nút là 200) xuống chỉ còn 20% (ứng với trường hợp số nút là 100). Khi số nút giảm còn 50, mô hình không còn phù hợp để dự đoán. Bên cạnh đó, độ chính xác của mô hình cũng tăng lên gấp đôi khi số nút giảm một nửa từ 200÷100.

Trong trường hợp cùng số lượng nút trong một lớp ẩn, hiệu suất dự đoán của mô hình không




*Hình 7. Đồ thị biểu diễn giá trị mất mát khi sử dụng hàm mất mát Huber.*





Hình 8. Đồ thị biểu diễn giá trị thực, giá trị dự báo đối với tập dữ liệu huấn luyện.



Hình 9. Đồ thị biểu diễn giá trị thực, giá trị dự báo đối với tập dữ liệu kiểm tra.

thay đổi khi giá trị của epochs thay đổi từ 100 lên 150 và 200.

Khi sử dụng hàm mất mát Huber thay thế cho hàm MSE, hiệu suất cũng như độ chính xác của mô hình được nâng lên đáng kể như mức độ phù hợp của mô hình tăng lên 7% (92% so với 85%) đồng thời giá trị MAE giảm đi 15% (3,21 mm so với 3,77 mm).

Để khẳng định mức độ phù hợp của việc lựa chọn số nút trong lớp ẩn, hàm tối ưu, hàm mất mát cần tiếp tục phân tích với nhiều bộ dữ liệu với đặc điểm khác nhau.

### Đóng góp của các tác giả

Trần Xuân Trường - đề xuất ý tưởng, viết bản thảo bài báo, kiểm chứng; Lê Đức Tình - phân tích dữ liệu, viết bản thảo bài báo; Đỗ Thị Phương Thảo - phân tích dữ liệu, viết bản thảo bài báo; Phạm Văn Mẫn - phân tích dữ liệu; Nguyễn Gia Trọng -

đề xuất ý tưởng, xây dựng mô đun chương trình, chỉnh sửa bài báo.

### Tài liệu tham khảo

- Alpaydin, E. (2020). Introduction to machine learning: MIT press.
- Andreas, H., Abidin, H. Z., Sarsito, D. A., Meilano, I., & Susilo, S. (2018). Investigating the tectonic subsidence on Java Island using GNSS GPS campaign and continuous. *Paper presented at the AIP Conference Proceedings*.
- Bishop, C. M., & Nasrabadi, N. M. (2006). Pattern recognition and machine learning (Vol. 4): Springer.
- Cetin, S., Aydin, C., & Dogan, U. (2019). Comparing GPS positioning errors derived from GAMIT/GLOBK and Bernese GNSS software

- packages: A case study in CORS-TR in Turkey. *Survey Review*, 51(369), 533-543.
- Chen, H., He, X., & Lu, T. (2024). Deep Learning Based GNSS Time Series. In *Positioning Navigation Using Machine Learning Methods* (pp. 99).
- Chollet, F. (2021). Deep learning with Python: *Simon and Schuster*.
- Ciaburro, G., & Venkateswaran, B. (2017). Neural Networks with R: Smart models using CNN, RNN, deep learning, and artificial intelligence principles: *Packt Publishing Ltd*.
- Crocetti, L., Schartner, M., & Soja, B. (2021). Discontinuity detection in GNSS station coordinate time series using machine learning. *Remote sensing*, 13(19), 3906.
- Gao, W., Li, Z., Chen, Q., Jiang, W., & Feng, Y. (2022). Modelling and prediction of GNSS time series using GBDT, LSTM and SVM machine learning approaches. *Journal of Geodesy*, 96(10), 71.
- Goudarzi, M. A. (2016). GPS inferred velocity and strain rate fields in eastern Canada.
- Haritonova, D., Balodis, J., Janpaule, I., & Morozova, K. (2015). Earth's Surface Displacements from the GPS Time Series. Paper presented at the IOP Conference Series: *Materials Science and Engineering*.
- Khorrami, F., Ejigu, Y. G., Näränen, J., Raja-Halli, A., & Nordman, M. (2024). Exploring Non-tidal Atmospheric Loading Deformation Correction in GNSS Time Series Analysis Using GAMIT/GLOBK Software. In *Springer*.
- Le, D. T., Huynh, N. D., & Nguyen, G. T. Q. (2024). Exploring the training results of machine learning models using different batch sizes and epochs: A case study with GNSS time series data. *J. Hydro-Meteorol*, 19, 90 - 99.
- Meyer, G. P. (2021). An alternative probabilistic interpretation of the huber loss. Paper presented at the Proceedings of the IEEE/CVF conference on computer vision and pattern recognition.
- Özbey, V., Ergintav, S., & Tarı, E. (2024). GNSS Time Series Analysis with Machine Learning Algorithms: A Case Study for Anatolia. *Remote Sensing*, 16(17), 3309.
- Rizos, C. (2008). The contribution of GNSS CORS infrastructure to the mission of Modern Geodesy. Paper presented at the 7th Int. *Symp. & Exhibition on Geoinformation*.
- Trọng, N. G., Nghĩa, N. V., Khải, P. C., Thành, N. H., Hà, L. L., Dũng, V. T., Quân, N. V., Quang, P. N. (2022). Xác định chuyển dịch trên phạm vi lãnh thổ Việt Nam dựa vào dữ liệu của các trạm CORS thuộc mạng lưới VNGEONET. *Tạp chí Khí tượng Thủy văn*, 739, 59-66.
- Uzel, T., Eren, K., Gulal, E., Tiryakioglu, I., Dindar, A. A., & Yilmaz, H. (2013). Monitoring the tectonic plate movements in Turkey based on the national continuous GNSS network. *Arabian Journal of Geosciences*, 6, 3573-3580.
- Vân Phong, D., Trọng, N. G., Chiến, N. V., Thành, N. H., Hà, L. L., Quân, N. V., & Quang, P. N. (2023). Phân tích chuyển dịch thẳng đứng vỏ Trái đất sử dụng hàm ANN từ kết quả xử lý chuỗi dữ liệu GNSS theo thời gian. *Tạp chí Khí tượng thủy văn*, 752, 41 - 50.
- Wang, Q., Ma, Y., Zhao, K., & Tian, Y. (2020). A comprehensive survey of loss functions in machine learning. *Annals of Data Science*, 1-26.
- Xie, Y., Wang, J., Li, H., Dong, A., Kang, Y., Zhu, J., Wang, Y., Yang, Y. (2024). Deep Learning CNN-GRU Method for GNSS Deformation Monitoring Prediction. *Applied Sciences*, 14(10), 4004.