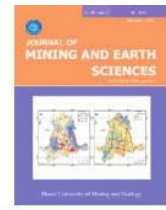




Journal of Mining and Earth Sciences

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



Predicting elevation values using Gated Recurrent Unit (GRU) neural networks



Nghia Viet Nguyen¹, Trong Gia Nguyen^{1,2,*}

¹ Faculty of Geomatics and Land Administration, Hanoi University of Mining and Geology, Hanoi, Vietnam

² Geodesy and Environment Research Group, Hanoi University of Mining and Geology, Hanoi, Vietnam

ARTICLE INFO

Article history:

Received 08th Jan. 2025

Revised 27th Apr. 2025

Accepted 15th May 2025

Keywords:

Deep learning,
GNSS,
GRU,
Prediction,
Subsidence.

ABSTRACT

This paper focuses on the development and evaluation of a GNSS height point prediction model based on the Gated Recurrent Unit (GRU), an advanced variant of recurrent neural networks designed for time series data. The input data consists of height coordinate sequences (h) extracted from GNSS data processed at the CPHU station using the specialized Gamit/Globk software, achieving millimeter-level accuracy. Unlike many previous studies, the GRU model in this research was trained on the entire continuous data sequence without splitting it into separate training and testing sets. The prediction performance was assessed over the period from March 9th, 2022, to March 17th, 2022. The model was tested using two optimization algorithms, Adam and SGD, in combination with two commonly used loss functions, MSE and Huber. The performance of each configuration was evaluated using metrics including MSE, RMSE, MAE, and the coefficient of determination (R^2). The results indicate that the GRU model combined with the Adam optimizer and MSE loss function yielded the best prediction performance, with an R^2 value of approximately 0.54 and an MAE of 4.24 mm. In contrast, using SGD and Huber led to a significant decrease in performance, with R^2 values ranging from only 0.33 to 0.42. Additionally, the size of the sliding window (lag) also influenced the model's predictive capability: a smaller window size (lag = 10) allowed the model to better adapt to noisy data.

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

*Corresponding author

E - mail: nguyengiatrong@humg.edu.vn

DOI: 10.46326/JMES.2025.66(3).03



Tạp chí Khoa học Kỹ thuật Mỏ - Địa chất

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

Dự đoán giá trị độ cao sử dụng mạng nơ ron hồi tiếp (GRU)

Nguyễn Viết Nghĩa¹, Nguyễn Gia Trọng^{1,2,*}

¹ Khoa Trắc địa - Bản đồ và Quản lý đất đai, Trường Đại học Mỏ - Địa chất, Hà Nội, Việt Nam

² 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 08/01/2025

Sửa xong 27/4/2025

Chấp nhận đăng 15/5/2025

Từ khóa:

Dự đoán,

GNSS,

GRU,

Học sâu,

Sụt lún bề mặt đất.

TÓM TẮT

Bài báo này tập trung vào việc xây dựng và đánh giá mô hình dự báo giá trị độ cao điểm GNSS dựa trên mạng nơ-ron hồi tiếp GRU (Gated Recurrent Unit), một biến thể tiên tiến trong học sâu dành cho dữ liệu chuỗi thời gian. Dữ liệu đầu vào là chuỗi tọa độ độ cao h được trích xuất từ kết quả xử lý GNSS tại trạm CPHU, sử dụng phần mềm chuyên dụng Gamit/Globk, với độ chính xác đạt mức milimét. Không giống nhiều nghiên cứu khác, mô hình GRU trong nghiên cứu này được huấn luyện dựa trên toàn bộ chuỗi dữ liệu liên tục mà không chia tách thành tập huấn luyện và kiểm tra riêng biệt. Khoảng thời gian đánh giá dự báo độ cao điểm trong tương lai từ ngày 9/3/2022 đến 17/3/2022. Mô hình được thử nghiệm với hai thuật toán tối ưu hóa là Adam và SGD, kết hợp với hai hàm mất mát phổ biến là MSE và Huber. Hiệu quả của từng cấu hình được đánh giá thông qua các chỉ số MSE, RMSE, MAE và hệ số xác định R^2 . Kết quả cho thấy, mô hình GRU sử dụng thuật toán Adam cùng hàm mất mát MSE mang lại hiệu suất dự báo tốt nhất với hệ số R^2 đạt khoảng 0,54 và sai số MAE ở mức 4,24 mm. Ngược lại, khi thay thế bằng SGD và Huber, hiệu quả giảm xuống rõ rệt với R^2 chỉ còn từ 0,33÷0,42. Ngoài ra, độ lớn của cửa sổ trượt (lag) cũng ảnh hưởng đến khả năng dự báo: cửa sổ ngắn (độ lớn bằng 10) giúp mô hình thích ứng tốt hơn với dữ liệu có nhiễu.

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

*Tác giả liên hệ

E - mail: nguyengiatrong@humg.edu.vn

DOI: 10.46326/JMES.2025.66(3).03

1. Mở đầu

Độ cao bề mặt thay đổi do cả nguyên nhân nội sinh và nguyên nhân ngoại sinh. Chuyển dịch thẳng đứng vỏ trái đất là nguyên nhân nội sinh gây nên sự thay đổi độ cao của điểm. Khai thác tài nguyên quá mức (khai thác khoáng sản, nước ngầm), quá trình nén ép phù sa làm bề mặt đất bị sụt lún. Tại các vùng có địa hình thấp như vùng đồng bằng sông Cửu Long hoặc thành phố Hồ Chí Minh, sụt lún quá mức làm trầm trọng thêm hiện tượng ngập lụt (do mưa hoặc triều cường), xâm nhập mặn (Construction, 2019). Do đó, xác định giá trị sụt lún của bề mặt, dự đoán giá trị độ cao điểm (gián tiếp xác định sụt lún) là công việc cần phải được thực hiện thường xuyên và liên tục. Đối với các công trình xây dựng, dự báo độ lún giúp đánh giá và theo dõi độ ổn định của công trình từ khi bắt đầu xây dựng đến khi vận hành công trình (Quốc, 2022). Dự đoán được chính xác giá trị độ cao của điểm có vai trò quan trọng trong nghiên cứu, giảm thiểu thiệt hại do động đất gây nên (Cho, 2015). Để dự báo độ cao hoặc giá trị chuyển dịch của điểm (bề mặt) có thể sử dụng các mô hình truyền thống (Khánh & Dương, 2011) hoặc trí tuệ nhân tạo (Long, 2016).

Mạng nơ ron nhân tạo nhiều lớp (MLP - Multilayer Perceptron) đã được sử dụng trong dự báo lún bề mặt mỏ với kết quả xác định được có sai số trung phương bằng 5% độ lún cực đại (Long, 2016).

Vân Phong và nnk. (2023) đã ứng dụng mạng ANN để phân tích kết quả xác định chuyển dịch thẳng đứng vỏ trái đất với dữ liệu đầu vào là giá trị độ cao của điểm thu nhận được sau khi xử lý dữ liệu GNSS bằng phần mềm Gamit/Globk. Tuy nhiên, nghiên cứu này mới chỉ dự đoán giá trị độ cao trong khoảng thời gian có dữ liệu đo mà chưa dự đoán giá trị độ cao tương lai. Mô hình GRU đã được triển khai trong một nghiên cứu tương tự (Le và nnk., 2024) với kết quả thống kê các đặc trưng cho hiệu suất dự báo của mô hình đạt được rất cao.

Inazu và nnk. (2016) sử dụng định vị độ cao tàu bằng GNSS và phương pháp PPP động học để phát hiện sóng thần **lớn hơn 10^{-1} m**. Dữ liệu AIS từ 92 tàu được kiểm tra khả năng dự báo sóng thần ở Nankai Trough. Kết quả cho thấy độ chính xác tương đương hoặc vượt trội so với 71 trạm quan sát ngoài khơi hiện có.

Kiani (2020) nghiên cứu dự đoán lún hoặc nâng đất bằng chuỗi thời gian vị trí GNSS, sử dụng 8 thuật toán học máy gồm Gaussian Processes, multilayer perceptron, và support vector regression. Thuật toán Gaussian Processes vượt trội, đạt độ chính xác đến 4 mm, trung bình 2 cm. Quy trình gồm hai bước: tiền xử lý (loại bỏ tín hiệu nhiễu) và dự đoán vị trí GNSS.

Các mô hình máy vector hỗ trợ (SV - Support Vector Machine), rừng ngẫu nhiên (RF - Random Forest), k-láng giềng gần nhất (K-Nearest Neighbors), và hồi quy tuyến tính bội (MLR - Multiple Linear Regression) đã được ứng dụng để dự đoán vận tốc chuyển dịch từ kết quả đo GNSS với kết quả xác định độ chính xác chuyển dịch lên tới $\pm 0,6$ mm/năm (Solak, 2024).

Crocetti và nnk. (2024) sử dụng ML và XGBoost kết hợp biến môi trường để mô hình hóa dịch chuyển GNSS, thay thế hoặc bổ sung các mô hình dựa trên vật lý. Phân tích 3553 trạm GNSS tại Châu Âu cho thấy cải thiện độ chính xác từ 4,4% đến 22,9%. Kết quả giúp giảm RMSE và cung cấp hiểu biết sâu hơn qua phân tích SHAP.

Các nghiên cứu của Le và nnk. (2024), Trọng & Quý (2024) đã cho kết quả dự đoán rất tốt khi phân tích nội tại (chưa có phần dự đoán cho các giá trị trong tương lai) cho các chuỗi dữ liệu theo chuỗi thời gian với mô hình GRU. Với dự đoán dữ liệu cho các thời điểm trong tương lai, cấu trúc dữ liệu đầu vào của mô hình trí tuệ nhân tạo hoàn toàn khác so với trước đó. Nghiên cứu này sử dụng mô hình GRU để dự đoán độ cao của điểm trong tương lai.

2. Dữ liệu và phương pháp nghiên cứu

2.1. Dữ liệu nghiên cứu

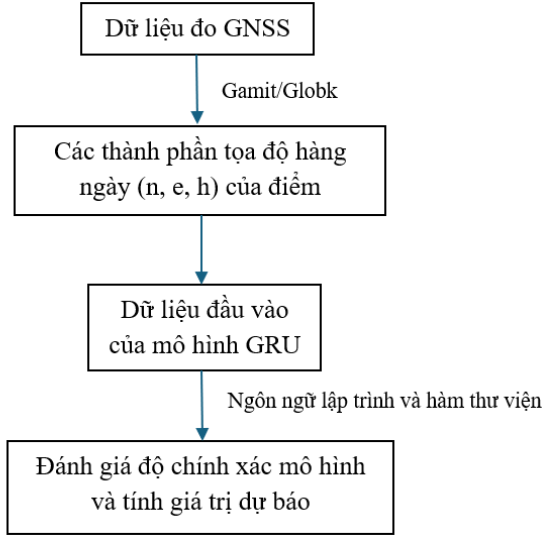
Dữ liệu sử dụng trong nghiên cứu này là dữ liệu thu nhận được bởi trạm thu tín hiệu GNSS liên tục CPHU thuộc mạng lưới VNGEONET được cung cấp bởi Cục Đo đạc, Bản đồ và Thông tin địa lý Việt Nam. Thông tin về dữ liệu đo tại Bảng 1.

Bảng 1. Thông tin dữ liệu tại trạm đo CPHU.

Tên trạm	Thời gian thu dữ liệu		Loại máy thu	Loại ăng ten	Giãn cách tín hiệu (second)
	Bắt đầu	Kết thúc			
CPHU	2019/08/10	2022/03/18	LEICA GR50	LEIAR25. R4LEIT	30

2.2. Phương pháp nghiên cứu

Phương pháp nghiên cứu được thể hiện trên Hình 1.



Hình 1. Phương pháp dự báo giá trị độ cao của điểm với mô hình GRU.

Dữ liệu GNSS sau khi thu nhận được chuyển sang định dạng dữ liệu RINEX để xử lý bằng các phần mềm xử lý độ chính xác cao như Bernese, Gamit/Globk. Nghiên cứu này sử dụng kết quả xử lý bằng phần mềm Gamit/Globk để thu được kết quả xác định các thành phần chuyển dịch với độ chính xác ở mức mm (Trọng và nnk., 2022). Kết quả của quá trình xử lý như trên là các thành phần tọa độ hàng ngày (n, e, h) của điểm trong đó h là thành phần độ cao trắc địa trong khung quy chiếu trái đất quốc tế ITRF-14.

GRU (Đơn vị hồi tiếp có cổng) là một loại mạng nơ-ron hồi tiếp (RNN) được thiết kế để khắc phục một số hạn chế của RNN truyền thống, chẳng hạn như vấn đề mất mát gradient khi học trên chuỗi dữ liệu dài. GRU sử dụng cơ chế cổng để kiểm soát thông tin nào cần lưu giữ hoặc loại bỏ trong quá trình tính toán, từ đó giúp mô hình học được các mối quan hệ dài hạn tốt hơn (Chollet, 2021).

Giả sử có đầu vào tại thời điểm t là x_t , trạng thái ẩn thời điểm $(t-1)$ là h_{t-1} , các bước tính toán với mô hình GRU như sau (Goodfellow và nnk., 2016):

Đối với cổng cập nhật:

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

Trong đó: W_z - ma trận trọng số; b_z - véc tơ trọng số bù; σ - hàm sigmod (đầu ra nằm trong khoảng $[0,1]$).

Đối với cổng thiết lập lại:

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

Các kí hiệu trong công thức (2) có ý nghĩa tương tự như trong công thức (1).

Trạng thái ẩn tạm thời:

$$\tilde{h}_t = \tanh(W \cdot [r_t \odot h_{t-1}, x_t] + b) \quad (3)$$

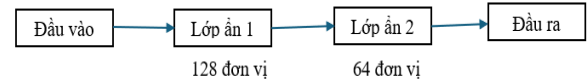
Trong đó: \odot - phép nhân từng phần tử (Hadamard); \tanh - hàm kích hoạt đầu ra nằm trong khoảng $(-1, 1)$.

Trạng thái ẩn hiện tại:

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

Trong đó: $(1 - z_t)$ được đề xuất để kiểm soát mức độ giữ lại của trạng thái cũ; z_t - tham số kiểm soát mức độ cập nhật của trạng thái mới.

Trong nghiên cứu này, mô hình GRU được xây dựng như trong Hình 2.



Hình 2. Xây dựng mô hình GRU.

Khi xây dựng mô hình, cần lưu ý đến việc lựa chọn thuật toán tối ưu, hàm mất mát, giá trị của batch-size cũng như độ lớn của cửa sổ trượt.

Trong các bài toán dự báo và hồi quy, các chỉ số đánh giá hiệu suất mô hình thường được sử dụng bao gồm Sai số bình phương trung bình (Mean Squared Error - MSE), Căn bậc hai của MSE (Root Mean Squared Error - RMSE), Sai số tuyệt đối trung bình (Mean Absolute Error - MAE), và Hệ số xác định (R^2) (Goodfellow và nnk. 2016).

Sai số trung bình được định nghĩa bởi công thức:

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

Trong đó: y_i là giá trị thực tế, \hat{y}_i là giá trị dự báo và n là số lượng điểm dữ liệu. MSE đo lường độ lớn trung bình của sai số dự đoán, trong đó các sai số được bình phương để đảm bảo không có giá trị âm và nhấn mạnh các sai số lớn.

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

Giá trị MAE đo lường sai số dự báo trung bình mà không nhấn mạnh các sai số lớn như trong MSE. MAE mang tính trực quan và không bị ảnh hưởng bởi các giá trị ngoại lai.

Hệ số xác định (R^2) được biểu diễn qua công thức:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

Trong đó: \bar{y} - trị trung bình của y . Chỉ số này đo lường mức độ phù hợp của mô hình, với giá trị từ 0÷1. R^2 càng gần 1 thì mô hình càng giải thích tốt phương sai của dữ liệu.

Ngôn ngữ lập trình được lựa chọn để xây dựng chương trình máy tính là ngôn ngữ Python (Ceder, 2018), với các hàm thư viện được sử dụng như pandas (Chen, 2017), numpy (Gupta & Bagchi, 2024), matplotlib (Tosi, 2009), tensorflow (Karim, 2018).

Từ tệp dữ liệu đầu vào, các giá trị độ cao từ ngày 9/3/2022 đến ngày 18/3/2022 được loại ra khỏi tập hợp và không được sử dụng để xây dựng mô hình. Các giá trị nêu trên được sử dụng để đánh giá kết quả dự báo của mô hình. Mục tiêu của bài báo là dự đoán giá trị độ cao điểm trong tương lai do đó toàn bộ dữ liệu được đưa vào làm dữ liệu xây dựng mô hình mà không chia thành bộ dữ liệu huấn luyện, bộ dữ liệu kiểm tra như thông thường.

3. Kết quả và thảo luận

Với lý thuyết cũng như chương trình máy tính được lựa chọn, xây dựng như trong mục 2, tính toán thực nghiệm với dữ liệu của trạm CORS CPHU thu được các kết quả như sau:

3.1. Kết quả dự đoán với kỹ thuật tối ưu Adam và hàm mất mát MSE

Kỹ thuật tối ưu là một yếu tố quan trọng trong việc huấn luyện các mô hình trí tuệ nhân tạo (AI), đặc biệt là khi dự đoán giá trị tương lai. Các thuật toán tối ưu như Gradient Descent giúp điều chỉnh các tham số của mô hình để giảm thiểu hàm mất mát, từ đó cải thiện độ chính xác của dự đoán (Kingma, 2014). Hàm mất mát, ví dụ như hàm MSE (Mean Squared Error), đo lường sự sai lệch giữa giá trị dự đoán và giá trị thực tế, là tiêu chí

chủ yếu để tối ưu hóa mô hình. Một yếu tố khác cũng ảnh hưởng đến quá trình huấn luyện là batch-size, chỉ ra số lượng mẫu được xử lý trong mỗi bước tính toán. Batch-size lớn có thể làm giảm thời gian huấn luyện nhưng đồng thời cũng tăng chi phí tính toán. Thêm vào đó, lag (độ trễ) trong dự đoán giá trị tương lai có thể là một thách thức khi mô hình không kịp bắt kịp sự biến động nhanh của dữ liệu (Chollet, 2021).

Khi tính toán thực nghiệm lựa chọn giá trị của Epochs là 100, batch-size = 8, độ lớn khung cửa sổ trượt (lag) lần lượt được chọn là 10 và 20. Các thông số của mô hình ở đây được lựa chọn một cách ngẫu nhiên và không tiến hành đánh giá kết quả dự báo với các thông số siêu mô hình (hyperparameters) khác nhau. Kết quả thống kê hiệu suất của mô hình cho trong Bảng 2.

Bảng 2. Thống kê hiệu suất của mô hình GRU với kỹ thuật tối ưu Adam và hàm mất mát MSE.

TT	Lag	MSE (mm)	RMSE (mm)	MAE (mm)	R^2
1	10	31,35	5,60	4,28	0,5404
2	20	30,95	5,56	4,24	0,5452

Dữ liệu Bảng 2 cho thấy, khi thay đổi độ lớn khung cửa sổ trượt thì hiệu suất của mô hình gần như không thay đổi. Kết quả giá trị h dự báo trong khoảng thời gian từ 9/3/2022 đến 17/3/2022 được cho trong Bảng 3.

Bảng 3. Độ cao dự báo của điểm sử dụng mô hình GRU với thuật toán tối ưu Adam và hàm mất mát MSE.

TT	Thời gian	Giá trị thực (mm)	h_lag10 (mm)	h_lag20 (mm)
1	9/3/2022	133115,22	133115,10	133109,85
2	10/3/2022	133115,16	133116,18	133111,72
3	11/3/2022	133120,73	133115,24	133111,80
4	12/3/2022	133114,70	133114,53	133109,34
5	13/3/2022	133120,47	133114,38	133105,74
6	14/3/2022	133119,98	133114,81	133105,83
7	15/3/2022	133120,70	133112,45	133107,68
8	16/3/2022	133120,22	133114,97	133108,55
9	17/3/2022	133126,37	133115,65	133112,74

Từ các giá trị trong Bảng 3, xác định được độ lệch độ cao điểm dự báo được cho trong Bảng 4. Dữ liệu ở Bảng 4 cho thấy, tuy hiệu suất của mô hình khi thay đổi độ lớn khung cửa sổ trượt thay

đổi không đáng kể nhưng giá trị độ cao của điểm khác nhau tương đối nhiều. Ở hai thời điểm dự báo đầu tiên, chênh lệch tuyệt đối lớn nhất giữa hai phương án lên tới 5 mm. Xét trong toàn bộ thời gian dự báo, giá trị chênh lệch tuyệt đối giữa hai phương án là 3 mm.

Bảng 4. Độ lệch giá trị dự báo trong trường hợp sử dụng kỹ thuật tối ưu Adam, hàm mất mát MSE.

TT	Thời gian	Độ lệch giá trị dự báo (mm)	
		h_lag10	h_lag20
1	9/3/2022	-0,12	-5,37
2	10/3/2022	1,02	-3,44
3	11/3/2022	-5,49	-8,93
4	12/3/2022	-0,17	-5,36
5	13/3/2022	-6,09	-14,73
6	14/3/2022	-5,17	-14,15
7	15/3/2022	-8,25	-13,02
8	16/3/2022	-5,25	-11,67
9	17/3/2022	-10,72	-13,63

Hình 3 và 4 biểu diễn giá trị độ cao dự báo trên toàn tập dữ liệu khi sử dụng thuật toán tối ưu Adam, hàm mất mát MSE, batch-size = 8 và độ lớn khung cửa sổ trượt lần lượt bằng 10 và 20.

Từ Hình 3 và 4 cho thấy, kết quả dự báo khi thay đổi độ lớn của khung cửa sổ trượt là tương đối giống nhau và không có sự khác biệt lớn. Điều

này cũng phù hợp với kết quả thống kê đặc trưng hiệu suất của mô hình trong Bảng 2.

3.2. Kết quả dự đoán với kỹ thuật tối ưu SGD và hàm mất mát Huber

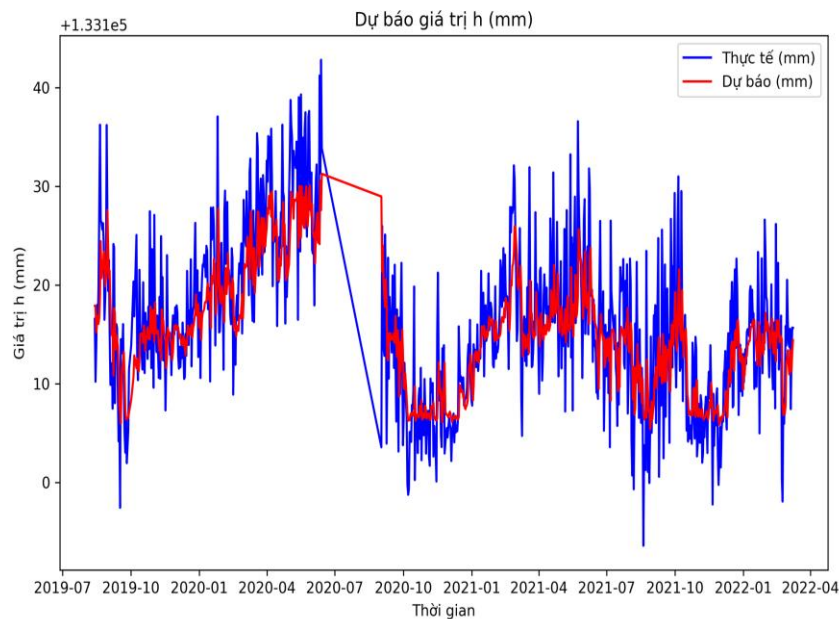
Trong trường hợp này, chỉ thay đổi thuật toán tối ưu Adam bằng SGD, thay hàm mất mát MSE bằng hàm mất mát Huber. Các thông số còn lại giữ nguyên như phương án trước đó. Kết quả thống kê hiệu suất của mô hình được cho trong Bảng 5.

Bảng 5. Thống kê hiệu suất của mô hình với thuật toán tối ưu SGD, hàm mất mát Huber.

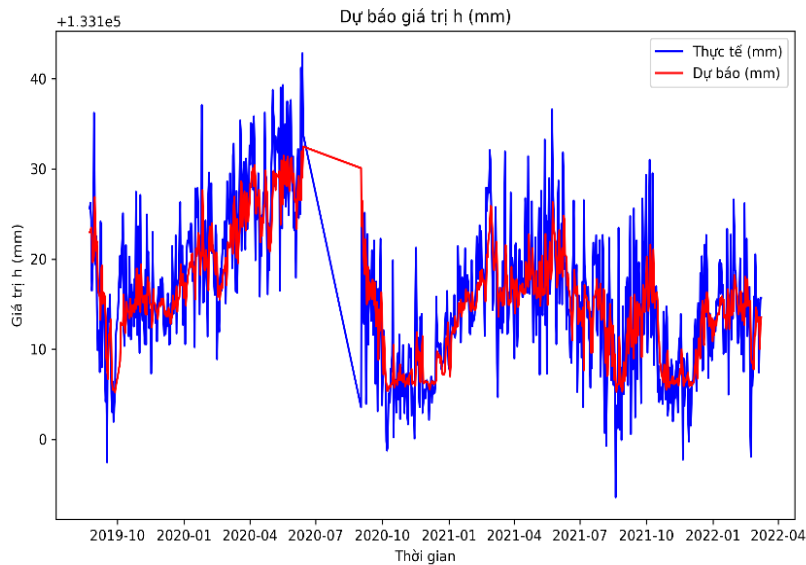
TT	Lag	MSE (mm)	RMSE (mm)	MAE (mm)	R ²
1	10	39,37	6,27	4,90	0,4227
2	20	45,49	6,74	5,25	0,3316

Từ dữ liệu của Bảng 2 và Bảng 5 cho thấy, trong trường hợp sử dụng thuật toán tối ưu SGD, hàm mất mát Huber hiệu suất dự đoán của mô hình GRU giảm đi đáng kể. Cụ thể, giá trị của MAE cao hơn khoảng 1 mm, giá trị của R² giảm đi 12% trong trường hợp giá trị của khung cửa sổ trượt bằng 10 và giảm tới 21% khi giá trị khung cửa sổ bằng 20.

Hệ R² trong nghiên cứu này chỉ đạt khoảng 50% trong quá trình xây dựng mô hình phản ánh rằng mô hình GRU mới chỉ giải thích được một



Hình 3. Giá trị độ cao dự báo trên toàn tập dữ liệu với thuật toán tối ưu Adam, hàm mất mát MSE, batch-size = 10 và độ lớn khung cửa sổ trượt bằng 10.



Hình 4. Giá trị độ cao dự báo trên toàn tập dữ liệu với thuật toán tối ưu Adam, hàm mất mát MSE, batch-size = 10 và độ lớn khung cửa sổ trượt bằng 20.

phần biến động của dữ liệu đầu vào. Nguyên nhân của kết quả này có thể đến từ nhiều yếu tố: (1) Dữ liệu đầu vào có mức độ nhiễu cao và biến động mạnh theo thời gian, làm giảm khả năng mô hình học được mối quan hệ ổn định giữa đầu vào và đầu ra; (2) Các đặc trưng đầu vào sử dụng có thể chưa đủ hoặc chưa phù hợp để mô hình nắm bắt các yếu tố ảnh hưởng đến giá trị dự báo; (3) Cấu hình mô hình (số lớp, số nút ẩn, hàm kích hoạt) hoặc tham số huấn luyện chưa được tối ưu hoá hoàn toàn. Để cải thiện R^2 , cần thực hiện các bước như: chọn thêm đặc trưng đầu vào có ý nghĩa, áp dụng kỹ thuật xử lý nhiễu và kiểm tra các kiến trúc mạng sâu hơn hoặc mô hình lai kết hợp.

Giá trị độ cao dự báo được trong trường hợp này cho trong Bảng 6.

Bảng 6. Giá trị dự báo độ cao điểm khi sử dụng kỹ thuật tối ưu SGD, hàm mất mát Huber.

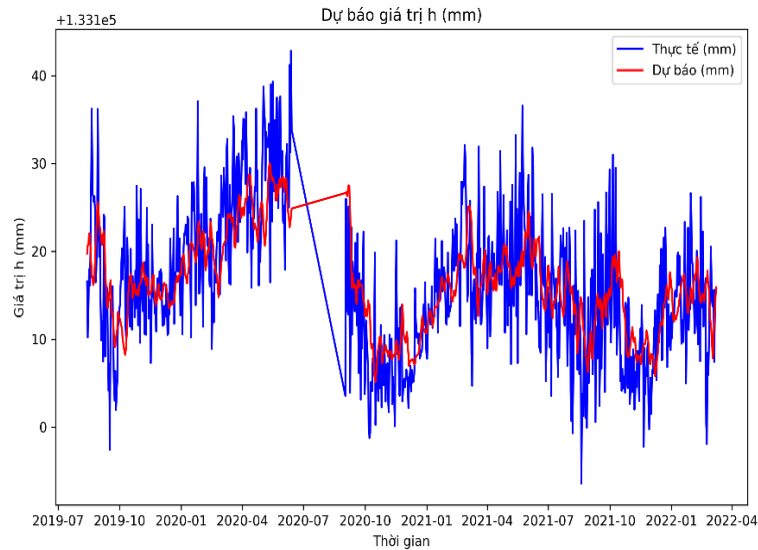
TT	Thời gian	Giá trị thực (mm)	h_lag10 (mm)	h_lag20 (mm)
1	9/3/2022	133115,22	133114,41	133114,07
2	10/3/2022	133115,16	133114,64	133114,23
3	11/3/2022	133120,73	133114,75	133114,30
4	12/3/2022	133114,70	133114,87	133114,35
5	13/3/2022	133120,47	133114,98	133114,39
6	14/3/2022	133119,98	133115,08	133114,42
7	15/3/2022	133120,70	133115,17	133114,45
8	16/3/2022	133120,22	133115,30	133114,47
9	17/3/2022	133126,37	133115,38	133114,50

Giá trị độ lệch của độ cao dự báo được khi sử dụng thuật toán tối ưu SGD, hàm mất mát Huber cho trong Bảng 7.

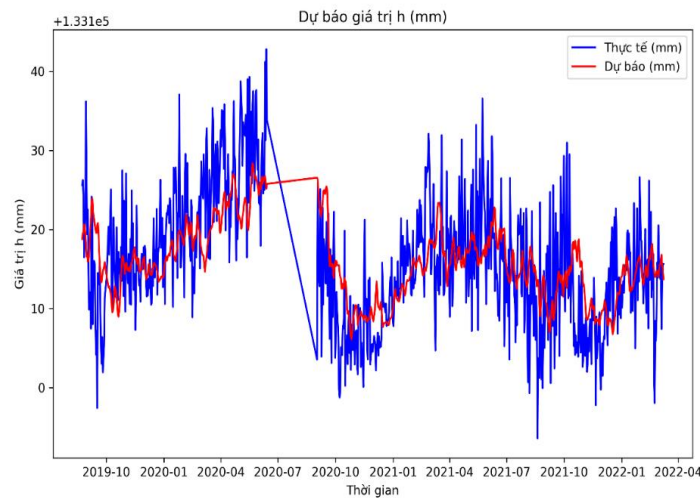
Bảng 7. Độ lệch giá trị dự báo trong trường hợp sử dụng kỹ thuật tối ưu SGD, hàm mất mát Huber.

TT	Thời gian	Độ lệch giá trị dự báo	
		h_lag10 (mm)	h_lag20 (mm)
1	9/3/2022	-0,81	-1,15
2	10/3/2022	-0,52	-0,93
3	11/3/2022	-5,98	-6,43
4	12/3/2022	0,17	-0,35
5	13/3/2022	-5,49	-6,08
6	14/3/2022	-4,90	-5,56
7	15/3/2022	-5,53	-6,25
8	16/3/2022	-4,92	-5,75
9	17/3/2022	-10,99	-11,87

Bảng 7 cho thấy, tuy hiệu suất của mô hình tương đối thấp nhưng giá trị độ lệch độ cao dự báo được trong cả hai trường hợp độ lớn khung cửa sổ trượt là 10 và 20 đều rất nhỏ. Bên cạnh đó, giá trị tuyệt đối độ lệch lớn nhất trong trường hợp này cũng chỉ cao hơn so với trường hợp sử dụng thuật toán tối ưu Adam, hàm mất mát MSE 0,3 mm (10,99 mm so với 10,72 mm). Hình 5 và 6 biểu diễn giá trị độ cao dự báo được đối với toàn bộ tập dữ liệu sử dụng thuật toán tối ưu SGD, hàm mất mát Huber.



Hình 5. Giá trị độ cao dự báo trên toàn tập dữ liệu với thuật toán tối ưu SGD, hàm mất mát huber, $batch-size = 10$ và độ lớn khung cửa sổ trượt bằng 10.



Hình 6. Giá trị độ cao dự báo trên toàn tập dữ liệu với thuật toán tối ưu SGD, hàm mất mát huber, $batch-size = 10$ và độ lớn khung cửa sổ trượt bằng 20.

Kích thước cửa sổ trượt 10 cho kết quả dự báo tốt hơn so với kích thước 20 có thể được lý giải qua hai khía cạnh chính: độ trễ phản ứng và mức độ biến động của dữ liệu. Khi cửa sổ trượt nhỏ hơn (ví dụ: 10), mô hình GRU tập trung vào các thông tin gần thời điểm hiện tại hơn, từ đó phản ứng nhanh hơn với các thay đổi hoặc biến động ngắn hạn trong chuỗi thời gian. Điều này đặc biệt quan trọng khi dữ liệu có tính dao động mạnh, không ổn định theo chu kỳ dài. Ngược lại, cửa sổ trượt lớn hơn (20) làm tăng độ trễ phản ứng vì mô hình phải xử lý lượng thông tin dài hơn, dễ làm

"mờ" tín hiệu ngắn hạn và giảm độ nhạy với các biến động cục bộ. Do đó, với tập dữ liệu có đặc tính nhiễu và thay đổi thường xuyên như tại trạm CPHU, sử dụng cửa sổ trượt nhỏ giúp mô hình nắm bắt tốt hơn xu hướng ngắn hạn, từ đó cải thiện độ chính xác của dự báo.

So sánh Hình 3÷6 có thể thấy, khi sử dụng thuật toán tối ưu SGD, hàm mất mát Huber, đường dự báo nằm ở trung tâm hơn so với giá trị thực tế. Điều này dẫn đến độ lệch giữa giá trị dự báo với giá trị thực tế lớn hơn.

4. Kết luận

Dự báo giá trị độ cao của điểm trong tương lai có ý nghĩa quan trọng trong các nghiên cứu về tai biến địa chất (sụt lún bề mặt, chuyển dịch thẳng đứng vỏ trái đất, động đất) cũng như trong vận hành công trình an toàn.

Bài báo đã trình bày việc áp dụng mô hình GRU trong dự đoán giá trị độ cao điểm cho các thời điểm trong tương lai, với dữ liệu cụ thể tại trạm CPU kéo dài gần 3 năm. Thông qua việc thử nghiệm các kỹ thuật tối ưu, hàm mất mát và độ lớn khung cửa sổ trượt khác nhau. Kết quả thực nghiệm cho thấy, mô hình GRU cho kết quả dự báo rất tốt đối với các giá trị ngắn hạn (thời gian dự báo sau 1 và 2 ngày) thể hiện qua giá trị độ lệch tuyệt đối nhỏ hơn 1 mm trong trường hợp sử dụng giá trị độ lớn khung cửa sổ trượt bằng 10. Mô hình phản ứng tốt hơn với cửa sổ trượt nhỏ, nhưng vẫn cần cải tiến để nâng cao độ chính xác và khả năng phản ánh các biến động đột ngột của dữ liệu đo thực tế.

Mô hình GRU có mức độ phù hợp với dữ liệu đầu vào (thông qua giá trị R^2) tốt hơn khi sử dụng thuật toán tối ưu Adam và hàm mất mát MSE (tốt hơn tới 12%) so với sử dụng thuật toán tối ưu SGD và hàm mất mát Huber.

Trong cả hai trường hợp là sử dụng thuật toán tối ưu Adam, hàm mất mát MSE và thuật toán tối ưu SGD, hàm mất mát Huber thì kết quả dự báo độ cao của điểm tốt hơn khi độ lớn khung cửa sổ trượt có giá trị bằng 10.

Trong nghiên cứu này, các giá trị trong tương lai chưa được cập nhật vào dữ liệu được sử dụng để xây dựng mô hình. Trong thời gian tới, nội dung này cần phải được tiếp tục nghiên cứu.

Lời cảm ơn

Tập thể tác giả chân thành cảm ơn Cục Đo đạc, Bản đồ và Thông tin địa lý Việt Nam đã cung cấp số liệu; đề tài cấp Bộ Tài nguyên và Môi trường mã số TNMT.ĐL.2025.06.03 đã cung cấp kinh phí thực hiện nghiên cứu này.

Đóng góp của tác giả

Nguyễn Viết Nghĩa - Đánh giá các kết quả thực nghiệm và biên tập bản thảo; xử lý dữ liệu thành phần, kiểm soát lỗi của chương trình; Nguyễn Gia Trọng- lên ý tưởng thiết kế, viết phần phương

pháp và hoàn thiện bản thảo; Xử lý dữ liệu thành phần và hoàn thiện bản thảo.

Tài liệu tham khảo

- Ceder, N. (2018). *The quick Python book*: Simon and Schuster.
- Chen, D. Y. (2017). *Pandas for everyone: Python data analysis*: Addison-Wesley Professional.
- Cho, J. M. (2015). Estimation of the crustal deformation caused by earthquake and its use in updating published coordinates of geodetic control points-A case study of the 2011 Tohoku Earthquake's impact in South Korea. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry, Cartography*, 33(6), 485-495.
- Chollet, F. (2021). *Deep learning with Python*: Simon and Schuster.
- Construction, M. o. (2019). Trouble underground - Land Subsidence in the Mekong Delta. In (pp. https://www.eda.admin.ch/dam/countries/countries-content/vietnam/vn/sdc-publications/ground-subsidence_VN.pdf): Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH.
- Crocetti, L., Schartner, M., Schneider, R., Schindler, K. & Soja, B. (2024). Modelling and Analysing GNSS Displacements with Machine Learning and Environmental Variables. *JGR: Solid Earth*. <https://doi.org/10.22541/essoar.172838522.21948627/v1>.
- Goodfellow, I., Bengio, Y. & Courville, A. (2016). Regularization for deep learning. *Deep learning*, 216-261.
- Gupta, P. & Bagchi, A. (2024). Introduction to NumPy. In *Essentials of Python for Artificial Intelligence and Machine Learning* (pp. 127-159): Springer.
- Inazu, D., Waseda, T., Hibiya, T. & Ohta, Y. (2016). Assessment of GNSS-based height data of multiple ships for measuring and forecasting great tsunamis. *Geoscience Letters*, 3, 1-13.
- Karim, M. R. (2018). *TensorFlow: Powerful Predictive Analytics with TensorFlow: Predict valuable insights of your data with TensorFlow*: Packt Publishing Ltd.

- Khánh, T. & Dương, P. Đ. (2011). Phân tích độ ổn định hệ thống mốc độ cao cơ sở trong quan trắc lún công trình. *Tạp chí Khoa học Đo đạc và Bản đồ*, 8(8), 52-56.
- Kiani, M. (2020). A precise machine learning aided algorithm for land subsidence or upheave prediction from GNSS time series. *arXiv preprint arXiv:03772*.
- Kingma, D. P. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Le D. T., Quoc, H. N. D., & Trong, N. G. (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.
- Long, N. Q. (2016). Đánh giá khả năng ứng dụng mạng nơ-ron nhân tạo dự báo lún bề mặt mỏ do khai thác hầm lò. *Tạp chí Khoa học Kỹ thuật Mỏ-Địa chất*, 55, 79-88.
- Quốc, L. B. (2022). Dự đoán lún bề mặt do tải trọng đặc trưng khi thi công công trình ngầm trong đất yếu ở TP Hồ Chí Minh. *Tạp chí Xây dựng*, 90 - 93.
- Solak, H. İ. (2024). Prediction of GNSS Velocity Accuracies Using Machine Learning Algorithms for Active Fault Slip Rate Determination and Earthquake Hazard Assessment. *Applied Sciences*, 15(1), 113.
- Tosi, S. (2009). *Matplotlib for Python developers*: Packt Publishing Ltd.
- Trọng, N. G., Nghĩa, N. V., Khải, P. C., Thành, N. H., Hà, L. L., Dũng, V. T.,... 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.
- Trọng, N. G. & Quý, B. N. (2024). Phân tích chuỗi dữ liệu nghiệm triều sử dụng mạng nơ ron hồi tiếp với nút có cổng (GRU). *Tạp chí Khí tượng Thủy văn*, 765, 39-46.
- 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.