

Bài báo khoa học

Đánh giá hiệu suất của mô hình CNN(Conv1D), CNN(Conv3D) trong phân tích dữ liệu GNSS

Lê Đức Tinh¹, Đỗ Thị Phương Thảo¹, Trần Đức Thắng², Đặng Trọng Hợp³, Nguyễn Gia Trọng^{1,4*}

¹ Trường Đại học Mở - Địa chất; leductinh@humg.edu.vn;

dothiphuongthao@humg.edu.vn; nguyengiatrong@humg.edu.vn

² Công ty Cổ phần Tư vấn Xây dựng Điện; duchangp10pecc1@gmail.com

³ Cục Chuyển đổi số và Thông tin Dữ liệu Tài nguyên Môi trường, Bộ Tài nguyên và Môi trường; dangtronghop244@gmail.com

⁴ Nhóm nghiên cứu Trắc địa cao cấp - môi trường, Trường Đại học Mở - Địa chất

*Tác giả liên hệ: nguyengiatrong@humg.edu.vn; Tel.: +84-963124980

Ban Biên tập nhận bài: 15/8/2024; Ngày phản biện xong: 29/10/2024; Ngày đăng bài: 25/3/2025

Tóm tắt: Nghiên cứu này đánh giá khả năng ứng dụng của mô hình học sâu CNN(Conv1D), CNN(Conv3D) trong phân tích dữ liệu 3D thay đổi theo thời gian với trường hợp điển hình là chuỗi dữ liệu GNSS theo thời gian. Theo đó, dữ liệu thu nhận được của trạm GNSS CORS có tên HYEN từ 10/8/2019 đến 18/3/2022 sau khi được xử lý bằng phần mềm Gamit/Globk để nhận được các thành phần tọa độ N, E, h hàng ngày. Nghiên cứu sử dụng ngôn ngữ lập trình python, với các hàm thư viện như pandas, sklearn, tensorflow... Nghiên cứu đã xây dựng mô đun chương trình dự đoán cho mô hình CNN(Conv1D), CNN(Conv3D). Kết quả thực nghiệm cho thấy, mô hình học sâu cho hiệu quả dự đoán tốt hơn dù tỷ lệ phân chia dữ liệu giữa tập dữ liệu huấn luyện với tập dữ liệu kiểm tra (60% - 40%) so với tỷ lệ tương ứng của mô hình ANN cao hơn (80% - 20%). Hiệu suất của mô hình CNN(Conv3D) khi dự đoán chuỗi dữ liệu GNSS theo thời gian thấp hơn so với kết quả dự đoán sử dụng mô hình CNN(Conv1D). Tuy nhiên, khi đưa thêm thời gian làm 1 lớp của dữ liệu đầu vào, hiệu suất dự đoán với mô hình CNN(Conv3D) được cải thiện một cách rõ nét. Các thông số đặc trưng cho hiệu suất dự đoán của mô hình CNN(Conv1D) như RMSE = 0,67 mm, MAE = 0,53 mm, $R^2 = 99,7\%$ là rất cao chứng tỏ hiệu quả của mô hình trong dự đoán chuỗi dữ liệu GNSS theo thời gian.

Từ khóa: Học sâu; Học sâu một chiều; Học sâu 3 chiều; Dữ liệu theo chuỗi thời gian.

1. Mở đầu

Hiện nay, dữ liệu địa không gian thường tồn tại dưới dạng chuỗi thời gian, chẳng hạn như dữ liệu GNSS [1] và dữ liệu nghiệm triều [2]. Khi xử lý các loại dữ liệu này, trí tuệ nhân tạo (AI) đã chứng minh được hiệu quả vượt trội trong việc phân tích và dự báo so với các mô hình toán học truyền thống. Nghiên cứu [3] đã đề xuất áp dụng mạng hồi quy tự hồi phi tuyến (NAR) và mạng hồi quy tự hồi có đầu vào ngoại lai (NARX) để dự báo chính xác các thay đổi vị trí 3D, đạt độ chính xác trong khoảng 2 mm. Một mô hình học sâu ST-3Dnet đã được đề xuất để dự báo lưu lượng giao thông trong các hệ thống giao thông thông minh [4]. Kết quả thử nghiệm trên nhiều tập dữ liệu cho thấy mô hình ST-3Dnet vượt trội so với các mô hình như ARIMA, LSTM và GRU về độ chính xác dự báo. Một nghiên cứu khác [5] đã giới thiệu mô hình 3D CNN-GRU để dự báo nồng độ PM_{2.5} theo giờ và ngày, với độ chính xác đạt 84% cho dự báo theo giờ và 78% theo ngày, cao hơn các mô hình LSTM, GRU, ANN, SVR và ARIMA.

Mô hình 3D-CNN cũng đã được áp dụng để tăng cường độ chính xác trong nhận diện cảm xúc, tích hợp với biến đổi sóng hồi (EWT), BiLSTM, GRU và AT. Kết quả thử nghiệm cho thấy mô hình phát triển đạt độ chính xác phân loại lần lượt là 90,57% và 90,59% cho các trục valence và arousal, dựa trên cơ sở dữ liệu DEAP [6]. Nghiên cứu [7] đề xuất một mô hình học sâu kết hợp 3D-CNN với GRU nhằm cải thiện hiệu quả nhận diện chất lượng không khí, giúp giảm thiểu dao động ngẫu nhiên trong giá trị dự báo của hạt bụi và cung cấp các cảnh báo sớm đáng tin cậy cho các chất ô nhiễm không khí nhờ khả năng trích xuất đặc trưng và khử nhiễu tốt.

Ứng dụng 3D-CNN trong dự báo động lực học chất lỏng cũng được ghi nhận trong [8]. Mô hình 3D-CNN này kết hợp với biểu diễn trung gian có số chiều thấp để tránh quá khớp, đạt các giá trị sMAPE và RRMSE lần lượt là 1,068 và 0,026. Nhiệt độ đất, một yếu tố quan trọng trong nông nghiệp có sự biến thiên theo không gian và thời gian, được dự báo bằng mô hình EEMD-Conv3D. Kết quả cho thấy các mô hình học sâu tích hợp EEMD có hiệu suất cao hơn. Đặc biệt, mô hình EEMD-Conv3D đạt hiệu suất tốt nhất với R^2 từ 0,9826 đến 0,9893, RMSE từ 1,3096 đến 1,6497 và MAE từ 0,9656 đến 1,2056 cho dự báo nhiệt độ đất từ một đến năm ngày trước [9].

Mô hình tích chập 3D còn được ứng dụng để dự đoán lưu lượng truyền phát mạng di động, cho thấy hiệu suất vượt trội hơn các mô hình như ARIMA và n-to-n [10], đồng thời cho phép tích hợp khả năng dự báo từ nhiều trạm phát sóng. Do sự dịch chuyển của vỏ trái đất, các thành phần tọa độ của điểm trên bề mặt thay đổi theo thời gian [11]. Một số nghiên cứu trước đây đã áp dụng các mô hình học sâu một chiều để dự báo chuỗi thời gian của dữ liệu GNSS [12] đạt hiệu suất cao. Tuy nhiên, các mô hình một chiều cho kết quả chưa tốt khi sử dụng dữ liệu đầu vào gồm các thành phần tọa độ 3 chiều, đặc biệt đối với một số tập dữ liệu cụ thể. Mục tiêu của nghiên cứu này là ứng dụng mô hình học sâu 3D để dự báo chuỗi thời gian của dữ liệu GNSS.

2. Dữ liệu và phương pháp nghiên cứu

2.1. Giới thiệu về dữ liệu và quy trình tính toán thực nghiệm

Dữ liệu sử dụng trong nghiên cứu này là dữ liệu GNSS liên tục thu nhận được bởi trạm GNSS HYEN thuộc mạng lưới VNGEONET được xây dựng và vận hành bởi Cục Đo đạc, Bản đồ và Thông tin địa lý Việt Nam [13]. Thông tin chi tiết về dữ liệu GNSS thu nhận được cho trong bảng 1.


Bảng 1. Thông tin về dữ liệu thu nhận bởi trạm HYEN.

Tên trạm	Thời gian		Loại máy thu	Loại ăng ten	Tần suất (giây)
	Bắt đầu	Kết thúc			
HYEN	2019/08/10	2022/03/18	LEICA GR50	LEIAR25.R4	LEIT 30

Phương pháp nghiên cứu sử dụng trong nghiên cứu này được tiến hành như trong hình 1.

Dữ liệu GNSS sau khi thu nhận bởi các trạm CORS sẽ được chuyển về định dạng dữ liệu RINEX sau đó được xử lý bằng phần mềm Gamit/Globk [14], Bernese [15] để thu được các thành phần tọa độ hàng ngày của điểm với độ chính xác cao.

Trong nghiên cứu này, đã sử dụng phần mềm Gamit/Globk để xử lý dữ liệu GNSS



Hình 1. Phương pháp nghiên cứu

theo thời gian với kết quả xác định các thành phần tọa độ hàng ngày của điểm được biểu diễn như trong hình 2.

2.2 Mô hình CNN(Conv1D) và CNN(Conv3D)

Mô hình mạng nơ-ron tích chập 1 chiều (Conv1D) là một dạng của mạng nơ-ron tích chập (CNN) được sử dụng chủ yếu trong xử lý chuỗi thời gian và dữ liệu tuần tự, chẳng hạn như phân tích tín hiệu âm thanh, chuỗi thời gian tài chính, hoặc dữ liệu y tế. Conv1D hoạt động bằng cách trích xuất các đặc trưng từ các đoạn nhỏ của chuỗi thông qua các bộ lọc, giúp mô hình nhận diện các mẫu quan trọng trong dữ liệu [16].

Phương trình cơ bản của lớp tích chập trong mô hình này là:

$$y(t) = \sum_{i=0}^{k-1} x(t+i).w(i) + b \quad (1)$$

Trong đó $x(t)$ là giá trị đầu vào tại thời điểm t ; $w(i)$ là trọng số của bộ lọc tại vị trí i ; b là hệ số điều chỉnh (bias); k là kích thước của bộ lọc.

Trong nghiên cứu này, mô hình CNN(Conv1D) được xây dựng với một lớp ẩn với 64 bộ lọc, kích thước kernel là 2, hàm kích hoạt ReLU, và chế độ padding là 'same'.

Mô hình CNN với Conv3D là một phiên bản mở rộng của CNN truyền thống, trong đó lớp tích chập 3 chiều (Conv3D) được sử dụng để xử lý dữ liệu không chỉ theo chiều cao và chiều rộng (như trong Conv2D), mà còn theo chiều thứ ba, thường là thời gian hoặc độ sâu. Điều này làm cho Conv3D trở nên lý tưởng cho các bài toán liên quan đến video, hình ảnh y tế ba chiều (CT, MRI), hoặc bất kỳ loại dữ liệu nào có không gian ba chiều.

Trong mô hình này, lớp Conv3D sử dụng các bộ lọc kernel 3 chiều để trích xuất các đặc trưng về không gian và thời gian. Ví dụ, với dữ liệu đầu vào có kích thước $D \times H \times W \times C$ trong đó D là độ sâu (chiều thời gian hoặc số lượng khung hình), H là chiều cao của ảnh, W là chiều rộng của ảnh, C là số kênh (channels, ví dụ: RGB có 3 kênh) thì công thức dự đoán với mô hình Conv3D trong trường hợp này như sau:

$$Daura(i,j,k) = \sum_{d=1}^D \sum_{h=1}^H \sum_{w=1}^W X(d+i, h+j, w+k)K(d, h, w) \quad (2)$$


Trong đó X là dữ liệu đầu vào; K là bộ lọc (kernel); i, j, k là các bước trượt (strides) của kernel qua các chiều không gian.

Ưu điểm của mô hình CNN(Conv3D) đó là khả năng trích xuất đặc trưng về không gian và thời gian giúp cho mô hình có thể hiểu được mối quan hệ giữa các khung hình hoặc độ sâu trong dữ liệu. Bên cạnh đó, mô hình này còn giúp tối ưu hóa xử lý video và dữ liệu 3D [17].

Khi ứng dụng mô hình CNN(Conv3D) để dự đoán chuỗi giá trị các thành phần tọa độ GNSS theo thời gian, mô hình được xây dựng có 1 lớp ẩn. Lớp ẩn này là lớp Conv3D với 64 bộ lọc, kích thước kernel là (1, 1, 2), và hàm kích hoạt là ReLU. Lớp này trích xuất các đặc trưng từ đầu vào.

2.3. Đánh giá hiệu suất của mô hình

Để đánh giá hiệu suất của mô hình trí tuệ nhân tạo, có thể thông qua các thông số như MSE, RMSE, MAE, R^2 , Kapa, F1-Score [18].



Hình 2. Các thành phần tọa độ hàng ngày của điểm HYEN.

MSE đo độ sai lệch bình phương trung bình giữa giá trị thực tế và giá trị dự đoán. MSE không chỉ phản ánh độ chính xác mà còn đặc biệt nhạy cảm với các giá trị ngoại lệ lớn. Cách tính MSE là lấy trung bình các bình phương của sai số giữa các giá trị dự đoán và giá trị thực tế [19]. Công thức tính toán trong trường hợp này là:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

MSE tăng nhanh khi xuất hiện sai số lớn, do đó, mô hình cần phải kiểm soát tốt các điểm ngoại lệ.

RMSE là căn bậc hai của MSE, và nó cho phép biểu diễn độ sai lệch trung bình theo cùng đơn vị với biến đích. RMSE dễ hiểu hơn khi trực quan hóa sai số trong dự đoán vì nó đưa kết quả về cùng quy mô với giá trị thực tế. RMSE được tính như sau [19]:

$$RMSE = \sqrt{MSE} \quad (4)$$

MAE đo độ sai lệch trung bình giữa giá trị dự đoán và giá trị thực tế mà không bình phương sai số, do đó nó không bị ảnh hưởng quá mạnh bởi các giá trị ngoại lệ lớn như MSE [19].

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

R^2 thể hiện phần trăm biến thiên của giá trị thực tế được mô hình giải thích, tức là mô hình dự đoán có tốt hơn việc đoán giá trị trung bình hay không. R^2 bằng 1 nghĩa là mô hình hoàn hảo [19].

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

Kappa là chỉ số đánh giá mức độ thỏa thuận giữa dự đoán và thực tế, có điều chỉnh để loại bỏ yếu tố ngẫu nhiên. Kappa thường được sử dụng trong bài toán phân loại. Kappa lớn hơn 0 cho thấy mô hình tốt hơn so với đoán ngẫu nhiên [19].

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (7)$$

Trong đó p_o là tỷ lệ đồng thuận quan sát và p_e là tỷ lệ đồng thuận mong đợi khi đoán ngẫu nhiên.

F1-Score là trung bình điều hòa của Precision và Recall, dùng để đánh giá hiệu suất của mô hình phân loại, đặc biệt trong trường hợp có mất cân bằng lớp [19].

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

F1-Score giúp cân bằng giữa việc giảm thiểu false positives và false negatives, phù hợp khi cần tối ưu cả hai loại lỗi này.

Dựa trên lý thuyết đã trình bày ở trên, nhóm nghiên cứu đã xây dựng chương trình dự đoán dữ liệu với mô hình CNN(Conv1D), CNN(Conv3D) với ngôn ngữ python [20, 21] trong đó có sử dụng các hàm thư viện như pandas, numpy, sklearn [22, 23] ...

3. Kết quả và thảo luận

Trong nội dung thực nghiệm này, sử dụng dữ liệu đầu vào là các thành phần tọa độ N, E, h để dự đoán thành phần h.

3.1. Kết quả dự đoán với mô hình CNN(Conv1D)


Mô hình CNN(Conv1D) trong trường hợp này được xây dựng sử dụng hàm tối ưu là hàm Adam, hàm mất mát là huber với Batch-size là 16 và số epoch là 200. Trong các nghiên

cứu đã công bố, tỷ lệ phân chia giữa tập dữ liệu huấn luyện và tập dữ liệu kiểm tra dao động trong khoảng từ 70%-30% và 80%-20%. Để khẳng định hiệu suất của các mô hình đề xuất, tỷ lệ phân chia dữ liệu trong trường hợp này đối với tập dữ liệu huấn luyện và tập dữ liệu kiểm tra tương ứng là 60% - 40%. Kết quả thống kê các tham số đặc trưng cho hiệu suất của mô hình trong trường hợp này được cho trong bảng 2.


Bảng 2. Các tham số hiệu suất mô hình CNN(Conv1D) khi dự đoán thành phần h.

Trạm	MSE (mm)	RMSE (mm)	MAE (mm)	R ²	F1-Score	Kapa
HYEN	3,48	1,87	0,19	0,9787	1.0	1.0


Từ bảng 2 có thể thấy, hiệu suất của mô hình CNN(Conv1D) trong trường hợp này cao hơn kết quả đã công bố khi sử dụng mô hình ANN mà trong đó chỉ sử dụng giá trị h làm dữ liệu đầu vào và tỷ lệ phân chia dữ liệu tương ứng cho tập dữ liệu huấn luyện và tập dữ liệu kiểm tra là 80% - 20% [1]. Đồ thị biểu diễn hàm mất mát, giá trị dự báo trên tập dữ liệu huấn luyện, giá trị dự báo trên tập dữ liệu kiểm tra được cho như trong các hình 3, 4 và 5.



Hình 3. Đồ thị biểu diễn hàm mất mát khi dự đoán với hàm CNN(Conv1D).



Hình 4. Đồ thị biểu diễn giá trị dự báo trên tập dữ liệu huấn luyện với mô hình CNN(Conv1D).



Hình 5. Đồ thị biểu diễn giá trị dự báo trên tập dữ liệu kiểm tra với mô hình CNN(Conv1D).

3.2. Kết quả dự đoán với mô hình CNN(Conv3D)

Các tham số của mô hình, tỷ lệ phân chia dữ liệu trong trường hợp này tương tự như đối với mô hình CNN(Conv1D) đã đề cập ở trên. Các thông số hiệu suất của mô hình được thống kê như trong bảng 3.

Bảng 3. Các tham số hiệu suất mô hình CNN(Conv3D) khi dự đoán thành phần h.


Trạm	MSE (mm)	RMSE (mm)	MAE (mm)	R ²	F1-Score	Kapa
HYEN	19,11	4,37	3,19	0,8831	0,9632	0,9263

Từ các dữ liệu trong bảng 2 và bảng 3 cho thấy, các thông số đặc trưng cho hiệu suất của mô hình khi dự đoán trong trường hợp này kém hiệu quả hơn so với kết quả dự đoán sử dụng hàm CNN(Conv1D). Kết quả xử lý với phần mềm Gamit/Globk ngoài 3 thành phần tọa độ là N, E và h, còn có thành phần là thời gian các ngày có dữ liệu. Nghiên cứu này đã tiến hành khảo sát hiệu quả dự đoán của mô hình CNN(Conv3D) trong trường hợp dữ liệu đầu vào là các giá trị thời gian, N, E và h. Kết quả thống kê hiệu suất của mô hình CNN(Conv3D) trong trường hợp này được cho trong bảng 4.


Bảng 4. Hiệu suất dự đoán của các mô hình khi thêm thành phần thời gian vào dữ liệu đầu vào.

Mô hình	MSE (mm)	RMSE (mm)	MAE (mm)	R ²	F1-Score	Kapa
CNN(Conv1D)	28,83	5,37	0,50	0,8236	1,0	1,0
CNN(Conv3D)	12,36	3,52	2,50	0,9243	0,9579	0,9158

Như vậy có thể thấy rằng, khi đưa thêm thành phần thời gian vào dữ liệu đầu vào, hiệu suất dự đoán với mô hình CNN(Conv3D) đã được cải thiện trong khi hiệu suất dự đoán của mô hình CNN(Conv1D) giảm đi rõ rệt. Đồ thị biểu diễn hàm mất mát, giá trị dự đoán trên tập dữ liệu huấn luyện và tập dữ liệu kiểm tra đối với mô hình CNN(Conv3D) trong trường hợp này được cho tương ứng trong các hình 6, 7, và 8.




Hình 6. Đồ thị biểu diễn hàm mất mát khi dự đoán với hàm CNN(Conv3D).



Hình 7. Đồ thị biểu diễn giá trị dự báo trên tập dữ liệu huấn luyện với mô hình CNN(Conv3D).

3.3. Kết quả dự đoán với số lượng bộ lọc khác nhau

Trong kết quả dự đoán ở các phần trên, hàm CNN(Conv1D) sử dụng 64 bộ lọc trong lớp ẩn, trong khi đó mô hình CNN(Conv3D) sử dụng 128 bộ lọc trong lớp ẩn. Trong phần này, thay đổi số lượng bộ lọc trong một lớp ẩn của cả hai mô hình lên 256. Kết quả đánh giá hiệu suất của các mô hình cho trong bảng 5 và bảng 6.




Hình 8. Đồ thị biểu diễn giá trị dự báo trên tập dữ liệu kiểm tra với mô hình CNN(Conv3D).

Bảng 5. Các tham số hiệu suất mô hình CNN(Conv1D) với 256 bộ lọc trong lớp ẩn.

Trạm	MSE (mm)	RMSE (mm)	MAE (mm)	R ²	F1-Score	Kapa
HYEN	0,45	0,67	0,53	0,9972	0,9947	0,9895

Từ bảng 4 và bảng 5 có thể thấy, khi tăng số lượng bộ lọc trong lớp ẩn của mô hình CNN(Conv1D) lên 256, hiệu suất của mô hình đạt rất cao. Hình 9, 10a, 10b thể hiện hàm mất mát, giá trị dự đoán và giá trị thực trên tập dữ liệu huấn luyện và tập dữ liệu kiểm tra khi dự đoán sử dụng mô hình CNN(Conv1D).



Hình 9. Đồ thị hàm mất mát khi dự đoán sử dụng mô hình CNN(Conv1D) với 256 bộ lọc trong lớp ẩn.


Hiệu suất dự đoán với mô hình CNN(Conv1D) như đã thể hiện trong bảng 5 là tốt hơn so với các kết quả đã công bố trước đó trên thế giới [24, 25]. Trong nghiên cứu [24], giá trị RMSE và MAE tốt nhất là 1,49 và 1,33 ứng với mô hình RF trong khi R² đạt giá trị tương đương là 99,7%. Trong khi đó, giá trị RMSE tốt nhất trong nghiên cứu [25] chỉ đạt được ở mức xấp xỉ 3 mm. Điều này càng có ý nghĩa khi mà tỷ lệ phân chia giữa tập dữ liệu huấn luyện và tập dữ liệu kiểm tra trong nghiên cứu này nhỏ hơn đối với tập dữ liệu huấn luyện các công bố đã có.

Bảng 6. Các tham số hiệu suất mô hình CNN(Conv3D) với 256 bộ lọc trong lớp ẩn.

Trạm	MSE (mm)	RMSE (mm)	MAE (mm)	R ²	F1-Score	Kapa
HYEN	3,25	1,80	1,48	0,9801	0,9789	0,9579

Từ bảng 4 và bảng 6 cho thấy, khi tăng số lượng bộ lọc trong lớp ẩn của mô hình CNN(Conv3D) cho thấy hiệu quả tăng rõ rệt với giá trị của RMSE, MAE giảm gần 50%, mức độ phù hợp của mô hình với bộ dữ liệu đầu vào tăng gần 6% và đạt tới 98%. Nếu so sánh với hiệu suất dự đoán sử dụng mô hình CNN(Conv1D) thì hiệu suất ở đây kém hơn nhiều. Tuy nhiên, nếu so sánh với kết quả đã được công bố bởi [24, 25] thì kết quả ở đây

hoàn toàn có thể chấp nhận được. Đồ thị biểu diễn hàm mất mát, giá trị dự đoán trên tập dữ liệu huấn luyện, tập dữ liệu kiểm tra trong trường hợp này được cho trong các hình 10c-10e.



Hình 10. Giá trị dự báo của tập dữ liệu huấn luyện khi dự đoán sử dụng mô hình: (a) CNN(Conv1D), (b) CNN(Conv3D), (c) Đồ thị hàm mất mát khi dự đoán sử dụng mô hình CNN(Conv3D) với 256 bộ lọc trong lớp ẩn; Giá trị dự báo của tập dữ liệu huấn luyện khi dự đoán sử dụng mô hình: (d) CNN(Conv3D), (e) CNN(Conv1D) với 256 bộ lọc trong lớp ẩn.

4. Kết luận

Qua nội dung nghiên cứu của bài báo này cho thấy hiệu suất dự đoán dữ liệu của các mô hình học sâu CNN(Conv1D), CNN(Conv3D) rất cao. Khi phân chia tỷ lệ giữa bộ dữ liệu huấn luyện và bộ dữ liệu kiểm tra tương ứng là 60% - 40% thì hiệu suất của mô hình học sâu vẫn cao hơn so với hiệu suất dự đoán của mô hình trí tuệ thông thường với tỷ lệ phân chia tương ứng là 80% và 20%. Hơn thế nữa, hiệu suất cao của mô hình học sâu như đã nêu ở trên đạt được với dữ liệu đầu vào là cả 3 thành phần tọa độ chứ không chỉ là thành phần h.

Trong trường hợp dự đoán chuỗi dữ liệu GNSS theo thời gian, mô hình CNN(Conv1D) cho hiệu suất cao hơn so với mô hình CNN(Conv3D). Điều này có thể do bộ dữ liệu đầu vào chưa có đủ chiều sâu theo các chiều khác nhau do đó mức độ phù hợp giữa mô hình với dữ liệu đầu vào chưa thực sự tốt. Tuy nhiên, khi sử dụng 256 bộ lọc trong lớp ẩn thì giá trị RMSE = 1,8 mm, MAE = 1,48 mm cũng đã chứng tỏ hiệu suất của mô hình này. Khi sử dụng mô hình CNN(Conv1D), giá trị RMSE = 0,67 mm và MAE = 0,53 mm là độ chính xác rất cao so với các công bố tương tự đã có.

Khi đưa thêm thời gian làm một thành phần của dữ liệu đầu vào, hiệu suất dự đoán với mô hình CNN(Conv3D) được cải thiện một cách rõ rệt đã chứng tỏ mức độ phù hợp giữa lý thuyết với kết quả thực nghiệm trong nghiên cứu này.

Tuy nhiên, các kết quả thống kê trên đây mới chỉ là kết quả thử nghiệm đối với 1 bộ dữ liệu đầu vào. Để khẳng định hơn nữa mức độ phù hợp của mô hình CNN(Conv3D) đối với các dữ liệu thay đổi theo cả không gian và thời gian cần có các nghiên cứu kiểm chứng tiếp theo với nhiều loại dữ liệu và mức độ thay đổi theo không gian và thời gian nhiều hơn.

Đóng góp của tác giả: Xây dựng ý tưởng nghiên cứu: L.D.T., D.T.P.T., T.D.T., D.T.H., N.G.T.; Lựa chọn phương pháp nghiên cứu: N.G.T., L.D.T., D.T.P.T.; Xử lý số liệu: N.G.T., L.D.T.; Viết bản thảo bài báo: N.G.T., D.T.P.T., T.D.T.; Chính sửa bài báo: N.G.T., L.D.T.

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 dữ liệu GNSS thu nhận được bởi trạm CORS trong nghiên cứu này. Bên cạnh đó, Tập thể tác giả cũng chân thành cảm ơn đề tài cấp Bộ Tài nguyên và Môi trường mã số TNMT.2024.02.07 đã tài trợ kinh phí cho nhóm nghiên cứu.

Lời cam đoan: Tập thể tác giả cam đoan bài báo này là công trình nghiên cứu của tập thể tác giả, chưa được công bố ở đâu, không được sao chép từ những nghiên cứu trước đây; không có sự tranh chấp lợi ích trong nhóm tác giả.

Tài liệu tham khảo

1. Phong, D.V.; Trọng, N.G.; Chiến N.V.; Thành N.H.; Hà, L.L.; Quân, N.V., Quang, P.N. 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* **2023**, 752, 42–50.
2. Trọng, N.G.; Quý, B.N. 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* **2024**, 765, 39–46.
3. Alevizakou, E.G.; Siolas, G.; Pantazis, G. Short-term and long-term forecasting for the 3D point position changing by using artificial neural networks. *ISPRS Int. J. Geo-Inf.* **2018**, 7(3), 86.
4. Guo, S.; Lin, Y.; Li, S.; Chen, Z.; Wan, H. Deep Spatial–Temporal 3D Convolutional Neural Networks for Traffic Data Forecasting. *IEEE Trans. Intell. Transp. Syst.* **2019**, 20(10), 3913–3926.
5. Faraji, M.; Nadi, S.; Ghaffarpasand, O.; Homayoni, S. An integrated 3D CNN-GRU deep learning method for short-term prediction of PM2.5 concentration in urban environment. *Sci. Total Environ.* **2022**, 834, 155324.
6. Çelebi, M.; Öztürk, S.; Kaplan, K. An emotion recognition method based on EWT-3D–CNN–BiLSTM–GRU–AT model. *Comput. Biol. Med.* **2024**, 169, 107954.
7. Elbaz, K.; et al. Real time image-based air quality forecasts using a 3D-CNN approach with an attention mechanism. *Chemosphere* **2023**, 333, 138867.
8. Lopez-Martin, M.; Clainche, S.L.; Carro, B. Model-free short-term fluid dynamics estimator with a deep 3D-convolutional neural network. *Expert Syst. Appl.* **2021**, 177, 114924.
9. Yu, F.; Hao, H.; Li, Q. An Ensemble 3D convolutional neural network for spatiotemporal soil temperature forecasting. *Sustainability* **2021**, 13(16), 9174.
10. Mejia, J.; Ochoa-Zezzati, A.; Cruz-Mejía, O. Traffic forecasting on mobile networks using 3D convolutional layers. *Mobile Networks Appl.* **2020**, 25(6), 2134–2140.
11. Lê, H.M.; et al. Chuyển động hiện đại vỏ trái đất theo số liệu GPS liên tục tại Việt Nam và khu vực Đông Nam Á. *Tạp chí Các khoa học Trái đất* **2014**, 36(1), 1–13.
12. Tinh, L.D.; Quoc, H.N.D.; Trong, N.G. 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.* **2024**, 19, 90–99.
13. Trọng, N.G.; Nghĩa, N.V.; Khải, P.C.; Thành, N.H.; Hà, L.L.; Dũng, V.T.; Quân, N.V.; Quang, P.N. 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* **2022**, 739, 59–66.
14. Cetin, S.; Aydin, C.; Dogan, U. Comparing GPS positioning errors derived from GAMIT/GLOBK and Bernese GNSS software packages: A case study in CORS-TR in Turkey. *Surv. Rev.* **2019**, 51(369), 533–543.
15. Dương, N.A.; Kimata, F.; Tô, T.Đ.; Xuyên, N.Đ.; Nguyễn, P.Đ.; Hải, V.Q.; Công, D.C. Đánh giá chuyển động hiện đại đứt gãy Lai Châu–Điện Biên sử dụng chuỗi số liệu đo GPS 2002-2010. *VN J. Earth Sci.* **2011**, 33(4), 690–694.
16. Chollet, F. Deep learning with Python. Simon and Schuster, 2021.
17. Mittal, S. A survey of accelerator architectures for 3D convolution neural networks. *J. Syst. Archit.* **2021**, 115, 102041.

18. Alpaydin, E. Introduction to machine learning, MIT Press, 2020.
19. Kelleher, J.D. Deep learning, MIT Press, 2019.
20. Lawhead, J. Learning Geospatial Analysis with Python: Understand GIS fundamentals and perform remote sensing data analysis using Python 3.7. Packt Publishing Ltd, 2019.
21. Campesato, O. Python 3 for Machine Learning. Mercury Learning and Information, 2020.
22. Chen, D.Y. Pandas for everyone: Python data analysis. Addison-Wesley Professional, 2017.
23. Raschka, S.; Mirjalili, V. Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2. Packt publishing Ltd, 2019.
24. Wang, J.; Nie, G.; Gao, S.; Wu, S.; Li, H.; Ren, X. Landslide deformation prediction based on a GNSS time series analysis and recurrent neural network model. *Remote Sens.* **2021**, 13(6), 1055.
25. Gao, W.; Li, Z.; Chen, Q.; Jiang, W.; Feng, Y. Modelling and prediction of GNSS time series using GBDT, LSTM and SVM machine learning approaches. *J. Geod.* **2022**, 96(10), 71.

Evaluating the Performance of CNN (Conv1D) and CNN (Conv3D) Models in GNSS Data Analysis

Le Duc Tinh¹, Do Thi Phuong Thao¹, Tran Duc Thang², Dang Trong Hop³, Nguyen Gia Trong^{1,4*}

¹ Hanoi University of Mining and Geology; leductinh@humg.edu.vn; dothiphuongthao@humg.edu.vn; nguyengiatrong@humg.edu.vn

² Power engineering consulting joint stock company 1; duchangp10pecc1@gmail.com

³ The Department of DigitalTransformation and Data for NaturalResources and Environment, Hanoi, Vietnam; dangtronghop244@gmail.com

⁴ Geodesy and Environment research group, Hanoi University of Mining and Geology

Abstract: This study evaluates the applicability of the CNN(Conv1D), CNN (Conv3D) deep learning model in analyzing time-varying 3D data, with a case study on GNSS time series data. Specifically, data collected from the GNSS CORS station named HYEN from August 10, 2019, to March 18, 2022, were processed using Gamit/Globk software to obtain daily N, E, and h coordinate components. Using the Python programming language and libraries such as pandas, sklearn, and tensorflow, the research team developed prediction modules for the CNN (Conv1D) and CNN (Conv3D) models. Experimental results indicate that deep learning models provide better prediction accuracy, even with a data split ratio between the training and test sets of 60%-40%, compared to the higher corresponding ratio of 80%-20% for the ANN model. The performance of the CNN (Conv3D) model in predicting GNSS time series data was lower than that of the CNN (Conv1D) model. However, when time was added as an additional input layer, the predictive performance of the CNN (Conv3D) model improved significantly. The performance metrics for the CNN (Conv1D) model, such as RMSE = 0.67 mm, MAE = 0.53 mm, and $R^2 = 99.7\%$, were very high, demonstrating the model's effectiveness in predicting GNSS time series data.

Keywords: Deep learning; 1D deep learning; 3D deep learning; Time series data.