

# Một phương pháp dựa trên mạng nơ-ron tích chập một chiều kết hợp tăng cường dữ liệu để khôi phục dữ liệu bị thiếu trong hệ thống giám sát sức khỏe kết cấu cầu

Trần Thế Hiệp\*, Bùi Tiến Thành, Nguyễn Thạch Bích, Nguyễn Thị Thanh Yên

Khoa Công trình, Trường Đại học Giao thông Vận tải, 3 Cầu Giấy, phường Láng Thượng, quận Đống Đa, Hà Nội, Việt Nam

Ngày nhận bài 16/4/2025; ngày chuyển phản biện 17/4/2025; ngày nhận phản biện 28/4/2025; ngày chấp nhận đăng 9/5/2025

## Tóm tắt:

Bài báo đề xuất một phương pháp học sâu sử dụng mạng nơ-ron tích chập một chiều (1D CNN) để khôi phục dữ liệu dao động bị thiếu trong hệ thống giám sát sức khỏe kết cấu (SHM). Dữ liệu được thu thập từ mô hình cầu dây văng trong phòng thí nghiệm dưới dạng chuỗi thời gian đơn biến có các đoạn bị thiếu ngẫu nhiên. Để cải thiện khả năng học của mô hình và tính tổng quát, kỹ thuật tăng cường dữ liệu bằng nhiễu Gaussian được áp dụng trong quá trình huấn luyện. Mô hình được đánh giá bằng các chỉ số RMSE, MAE và hệ số tương quan  $R^2$ . Kết quả nghiên cứu cho thấy, mô hình 1D CNN có khả năng trích xuất đặc trưng cục bộ vượt trội từ tín hiệu đầu vào, đồng thời có tốc độ huấn luyện nhanh, độ ổn định cao và kiến trúc gọn nhẹ, rất phù hợp với các ứng dụng trong môi trường thực tế. Đồng thời, việc bổ sung nhiễu Gaussian với độ lệch chuẩn hợp lý, giúp cải thiện đáng kể độ chính xác khôi phục so với mô hình không tăng cường dữ liệu. Phương pháp đề xuất cho thấy tiềm năng ứng dụng trong phục hồi dữ liệu bị mất hoặc hỏng trong các hệ thống SHM thực tế, góp phần nâng cao độ tin cậy của việc phân tích và chẩn đoán kết cấu.

**Từ khóa:** công trình cầu, dao động, giám sát sức khỏe kết cấu, khôi phục dữ liệu dao động, mạng nơ-ron tích chập một chiều, tăng cường dữ liệu.

**Chỉ số phân loại:** 1.2, 2.1

## A one-dimensional convolutional neural network-based approach with data augmentation for missing data recovery in bridge SHM systems

The Hiep Tran\*, Tien Thanh Bui, Thach Bich Nguyen, Thi Thanh Yen Nguyen

Faculty of Civil Engineering, University of Transport and Communications, 3 Cau Giay Street, Lang Thuong Ward, Dong Da District, Hanoi, Vietnam

Received 16 April 2025; revised 28 April 2025; accepted 9 May 2025

## Abstract:

This article proposes a deep learning approach that uses one-dimensional convolutional neural networks (1D CNN) to reconstruct missing vibration data in structural health monitoring (SHM) systems. The data were collected from a laboratory-scale cable-stayed bridge model, represented as univariate time series with randomly missing segments. In order to enhance the model's learning capability and generalisation, Gaussian noise-based data augmentation is applied during training. The models are evaluated using RMSE, MAE, and  $R^2$  metrics. The research results show that the 1D CNN model demonstrates superior capability in extracting local features from input signals, while also offering fast training speed, high stability, and a lightweight architecture, making it highly suitable for real-world applications. In addition, incorporating Gaussian noise with an appropriate standard deviation can significantly improve the reconstruction accuracy compared to the non-augmented data model. The proposed method has demonstrated strong potential for recovering lost or corrupted data in practical SHM systems, thereby improving the reliability of structural analysis and diagnostics.

**Keywords:** bridge engineering, data augmentation, dynamic response, one-dimensional convolutional neural network, structural health monitoring, vibration data reconstruction.

**Classification numbers:** 1.2, 2.1

\*Tác giả liên hệ: Email: tranthehiep@utc.edu.vn

## 1. Đặt vấn đề

Hệ thống giám sát sức khỏe công trình (SHM) đóng vai trò thiết yếu trong việc duy trì sự an toàn, độ tin cậy và hiệu quả khai thác lâu dài của các kết cấu hạ tầng quy mô lớn như cầu, đập, nhà cao tầng và các công trình dân dụng quan trọng khác [1]. Bằng cách tích hợp các cảm biến đo dao động, biến dạng, nhiệt độ hoặc nội lực, SHM cho phép thu thập và theo dõi liên tục các phản ứng của kết cấu trong suốt vòng đời vận hành. Nhờ đó, hệ thống hỗ trợ phát hiện sớm các biểu hiện hư hỏng tiềm tàng, đánh giá tuổi thọ còn lại và xây dựng kế hoạch bảo trì tối ưu để đảm bảo an toàn chịu lực, an toàn khai thác và tuổi thọ của công trình [2, 3].

Tuy nhiên, trong quá trình vận hành thực tiễn, dữ liệu thu thập từ hệ thống SHM thường đối mặt với các vấn đề mất mát do nhiều nguyên nhân như nhiễu tín hiệu, lỗi truyền tải hoặc hư hỏng cảm biến [4]. Những thiếu hụt này có thể làm giảm độ tin cậy trong phân tích đánh giá kết cấu và ảnh hưởng đến hiệu quả của các quyết định kỹ thuật. Do vậy, việc nghiên cứu các giải pháp phục hồi dữ liệu đo bị mất trở nên cấp thiết nhằm đảm bảo tính đầy đủ và liên tục của thông tin phục vụ cho quá trình giám sát và phân tích kết cấu.

Các phương pháp truyền thống như phương pháp suy luận thống kê, phương pháp biểu diễn thưa... đã được sử dụng [5, 6]. Mặc dù có ưu điểm về tính đơn giản và hiệu quả tính toán, những phương pháp này thường hoặc phải giả định tính tuyến tính, hoặc sử dụng phân phối chuẩn trong dữ liệu - những giả định không phù hợp với bản chất phi tuyến, phức tạp và phụ thuộc thời gian của tín hiệu dao động trong các hệ thống SHM [7].

Để có cái nhìn tổng quan về các hướng tiếp cận đã được áp dụng cho bài toán phục hồi dữ liệu chuỗi thời gian, bảng 1 trình bày đặc điểm, dữ liệu sử dụng, phương pháp tiếp cận và hạn chế của một số phương pháp phổ biến, bao gồm cả các mô hình học máy truyền thống và mô hình học sâu.

Trong số các mô hình học sâu, mạng nơ-ron 1D CNN [8] nổi bật nhờ khả năng trích xuất đặc trưng cục bộ trong chuỗi thời gian và đã được áp dụng hiệu quả trong các nghiên cứu gần đây về khôi phục dữ liệu SHM. Nhiều nghiên cứu đã tập trung vào việc sử dụng CNN để phục hồi dữ liệu tại những vị trí bị mất. B.K. Oh và cs (2020) [9] cũng như P. Moeinifard và cs (2021) [10] đã đề xuất các mô hình CNN sử dụng dữ liệu từ các cảm biến ổn định để dự đoán giá trị tại các cảm biến bị lỗi.

Một hướng tiếp cận khác là khai thác mối quan hệ phi tuyến giữa các phản ứng kết cấu nhằm phục vụ cho mục tiêu khôi phục dữ liệu. P. Ni và cs (2022) [11] đề xuất phương

**Bảng 1. So sánh các phương pháp học máy trong bài toán dự đoán và khôi phục dữ liệu chuỗi thời gian.**

Phương pháp	Đặc điểm chính	Loại dữ liệu thường sử dụng	Cách tiếp cận	Hạn chế
Hồi quy tuyến tính (Linear Regression)	Đơn giản, dễ triển khai, dễ giải thích	Dữ liệu tuyến tính, ít nhiễu	Ước lượng tuyến tính giữa các điểm dữ liệu theo thời gian	Không mô hình hóa được mối quan hệ phi tuyến và chuỗi dài
Hồi quy sử dụng thuật toán tăng cường độ dốc cực đại (XGBRegressor)	Tăng cường cây quyết định, hạn chế quá khớp hiệu quả	Dữ liệu phi tuyến, có nhiễu	Tăng cường cây quyết định, tối ưu hàm mất mát	Không tận dụng được đặc trưng tuần tự của chuỗi
Hồi quy sử dụng thuật toán tăng cường độ dốc nhẹ (LGBMRegressor)	Tối ưu tốc độ và bộ nhớ tốt hơn XGB	Dữ liệu lớn, giàu đặc trưng	Tăng cường cây quyết định dựa trên biểu đồ tàn suất	Thiếu khả năng học đặc trưng thời gian sâu
Mạng nơ-ron nhân tạo (ANN hoặc MLP)	Học được các quan hệ phi tuyến phức tạp	Dữ liệu phi tuyến, tín hiệu cảm biến	Mạng kết nối đầy đủ, học lan truyền ngược	Thiếu khả năng ghi nhớ thứ tự thời gian
Mạng nơ-ron hồi tiếp (RNN)	Có khả năng ghi nhớ trạng thái quá khứ ngắn hạn	Chuỗi thời gian	Mạng hồi tiếp với bộ nhớ trạng thái	Khó huấn luyện khi độ dài chuỗi lớn, do gặp phải vấn đề tiêu biến đạo hàm lan truyền ngược (vanishing gradient)
Mạng nơ-ron tích chập một chiều (1D CNN)	Mạng tích chập một chiều, trích xuất đặc trưng cục bộ trong chuỗi	Chuỗi thời gian liên tục	Áp dụng các kernel tích chập để học mẫu lặp theo thời gian	Mạnh trong trích xuất đặc trưng cục bộ của chuỗi thời gian, đặc biệt hiệu quả với dữ liệu dao động

pháp đo gián tiếp độ võng bằng cách sử dụng CNN để học ánh xạ giữa các phản ứng kết cấu khác và độ võng cần dự đoán. Y. Li và cs (2022) [12] phát triển một mô hình học sâu dựa trên kiến trúc mã hóa - giải mã tự động (autoencoder), kết hợp với các kết nối bỏ qua (skip connections) để tái tạo phản ứng toàn trường của kết cấu.

Từ góc độ tối ưu kiến trúc mạng, G. Fan và cs (2021a) [13] đề xuất mô hình CNN với kết nối dày đặc kết hợp với kỹ thuật biến đổi điểm ảnh phụ (sub-pixel transformation) và dropout, giúp nâng cao hiệu suất truyền gradient, đồng thời giảm độ phức tạp tính toán. Một số nghiên cứu khác, chẳng hạn như G. Fan và cs (2021b) [14], áp dụng mạng CNN tiến truyền hoàn toàn (fully feedforward CNN) với các kết nối dư để phục hồi dữ liệu đo bị mất. N.T.C Nhung và cs (2024) [15] đã nghiên cứu phục hồi dữ liệu cảm biến trong giám sát sức khỏe kết cấu ứng dụng học mạng nơ-ron

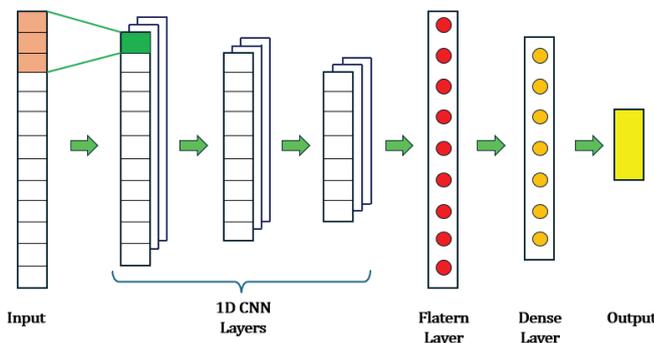
tích chập kết hợp mạng nơ-ron hồi quy. L.V. Vu và cs (2024) [16] đã nghiên cứu khôi phục dữ liệu cho hệ thống giám sát sức khỏe công trình cầu sử dụng mô hình mạng tích chập đồ thị và mạng bộ nhớ ngắn dài hạn.

Mặc dù một số nghiên cứu trước đây đã sử dụng 1D CNN để phục hồi dữ liệu đo bị thiếu trong hệ thống SHM, hầu hết các công trình này tập trung vào việc khai thác mối quan hệ giữa các cảm biến trong điều kiện dữ liệu khá sạch, ít nhiễu và thường chưa chú trọng nhiều đến khả năng tổng quát hóa của mô hình trong bối cảnh dữ liệu thực tế phức tạp. Bên cạnh đó, quy trình xử lý dữ liệu đầu vào và chiến lược huấn luyện vẫn còn tương đối đơn giản, chưa khai thác triệt để các kỹ thuật hỗ trợ như tăng cường dữ liệu.

Trong nghiên cứu này, một hướng tiếp cận mới được xây dựng dựa trên việc kết hợp mô hình 1D CNN với chiến lược tăng cường dữ liệu nhằm nâng cao khả năng phục hồi dữ liệu đo dao động bị thiếu trong môi trường thực tế - nơi dữ liệu có thể bị nhiễu, mất mát liên tục hoặc không đều. Khác với các nghiên cứu trước đây, phương pháp được đề xuất được áp dụng cho mô hình cầu dây văng trong phòng thí nghiệm, trong đó dữ liệu đo được chủ động làm nhiễu để mô phỏng điều kiện đo thực tế của công trình cầu thật. Hướng tiếp cận này cho phép đánh giá hiệu quả phục hồi của mô hình một cách thực tiễn và có kiểm soát, góp phần nâng cao độ tin cậy của hệ thống SHM trong điều kiện vận hành thực tế, đồng thời đảm bảo khả năng áp dụng rộng rãi cho các kết cấu và môi trường đo khác nhau.

## 2. Phương pháp nghiên cứu đề xuất

Mạng nơ-ron tích chập một chiều là một trong những kiến trúc mạng học sâu mạnh mẽ và phổ biến trong việc xử lý dữ liệu chuỗi thời gian. Trong bối cảnh giám sát sức khỏe kết cấu, nơi các tín hiệu dao động được thu thập từ các cảm biến để đánh giá tình trạng của kết cấu, mô hình 1D CNN đặc biệt hiệu quả nhờ khả năng trích xuất đặc trưng cục bộ từ chuỗi tín hiệu và thực hiện việc phục hồi dữ liệu bị thiếu với tốc độ huấn luyện cao.



Hình 1. Cấu trúc mô hình 1D CNN.

Mô hình được đề xuất (hình 1) trong nghiên cứu này được thiết kế với ba tầng 1D CNN liên tiếp, sử dụng số lượng bộ lọc giảm dần từ 128 đến 64 và 32, tất cả đều sử dụng hàm kích hoạt ReLU và đệm theo tính chất nguyên nhân (padding 'causal') nhằm bảo toàn cấu trúc thời gian của chuỗi tín hiệu. Trong nghiên cứu này, chuẩn hóa theo lô (Batch normalization) được áp dụng giữa các tầng 1D CNN để ổn định phân phối đầu ra trung gian, kết hợp với kỹ thuật loại bỏ ngẫu nhiên (Dropout) với tỷ lệ 0,2 nhằm hạn chế quá khớp (overfitting). Cuối cùng, đầu ra được làm phẳng và đưa qua một lớp hoàn toàn kết nối (Dense) để dự đoán trực tiếp các bước tín hiệu tiếp theo. Cấu trúc tổng quát như sau:

Conv1D(128 filters, kernel size=3, activation=ReLU) → BatchNorm → Dropout(0.2)

Conv1D(64 filters, kernel size=3, activation=ReLU) → BatchNorm → Dropout(0.2)

Conv1D(32 filters, kernel size=3, activation=ReLU) → BatchNorm → Dropout(0.2)

Flatten → Dense(output\_steps)

Mô hình được huấn luyện bằng thuật toán tối ưu Adam với tốc độ học (learning rate) được thiết lập là 0,001, cùng hàm mất mát là sai số bình phương trung bình (MSE). Kỹ thuật dừng sớm (early stopping) được áp dụng nhằm ngăn ngừa hiện tượng quá khớp, với tham số patience =10. Theo đó, quá trình huấn luyện sẽ tự động dừng nếu hiệu suất trên tập xác thực không được cải thiện sau 10 vòng huấn luyện (epoch) liên tiếp, đồng thời khôi phục lại các trọng số tối ưu đạt được trước đó. Kích thước batch trong quá trình huấn luyện được đặt là 64, trong khi số epoch tối đa thiết lập là 1000, cho phép mô hình có đủ khả năng học nếu cần nhưng vẫn đảm bảo dừng sớm khi cần thiết để tránh quá khớp (overfitting).

Các siêu tham số được lựa chọn thông qua quá trình tinh chỉnh có kiểm soát, kết hợp giữa tham khảo các nghiên cứu liên quan trong lĩnh vực SHM và thực nghiệm trên nhiều cấu hình khác nhau. Việc lựa chọn cuối cùng dựa trên hiệu quả dự đoán của mô hình trên tập kiểm tra và tập xác thực, được đánh giá thông qua các chỉ số định lượng gồm RMSE, MAE và R<sup>2</sup>. Đáng chú ý, các giá trị RMSE, MAE và R<sup>2</sup> được trình bày trong bài là giá trị trung bình thu được từ 6 lần huấn luyện độc lập cho mỗi mô hình, nhằm đảm bảo tính ổn định và độ tin cậy trong đánh giá hiệu suất của phương pháp đề xuất.

Mô hình 1D CNN được xây dựng dựa trên nguyên lý tích chập, trong đó tín hiệu đầu vào được "lọc" thông qua các bộ lọc (kernels) có kích thước cố định. Đối với dữ liệu chuỗi thời gian một chiều, tín hiệu đầu vào  $x=[x_1, x_2, \dots, x_T]$

có thể là một dãy các giá trị dao động tại các thời điểm khác nhau và mỗi bộ lọc sẽ trượt qua chuỗi tín hiệu để tính toán đặc trưng tại các vị trí khác nhau trong chuỗi.

Công thức tính đầu ra  $y_t$  của phép tích chập tại vị trí  $t$  là:

$$y_t = (x * w)_t = \sum_{i=0}^{k-1} w_i \cdot x_{t+i} \quad (1)$$

trong đó:  $x$  là tín hiệu đầu vào,  $w_i$  là trọng số của bộ lọc tại vị trí  $i$ , và  $k$  là chiều dài của bộ lọc,  $x_{(t+i)}$  là giá trị tín hiệu tại vị trí  $t+i$  trong chuỗi tín hiệu. Sau khi tính toán phép tích chập, đầu ra sẽ được chuyển qua một hàm kích hoạt phi tuyến (như ReLU), giúp tăng khả năng học các mối quan hệ phi tuyến trong dữ liệu.

$$ReLU(y_t) = \text{Max}(0, y_t) \quad (2)$$

Các lớp tích chập có thể xếp chồng để học đặc trưng ở nhiều mức độ. Để tăng độ ổn định và tốc độ hội tụ, mô hình áp dụng chuẩn hóa theo lô (Batch normalization) sau mỗi lớp tích chập một chiều (Conv1D), giúp ổn định phân phối đầu ra và giảm hiện tượng mất/bùng nổ gradient (vanishing/exploding gradient). Đồng thời, loại bỏ ngẫu nhiên (Dropout) với tỷ lệ 0,2 cũng được sử dụng nhằm giảm quá khớp (overfitting) bằng cách vô hiệu hóa ngẫu nhiên một phần các đơn vị (neurons) trong khi huấn luyện. Sự kết hợp giữa Conv1D, Batch normalization và Dropout giúp mô hình vừa học đặc trưng hiệu quả, vừa đảm bảo khả năng khái quát tốt.

Trong bài toán phục hồi dữ liệu dao động bị thiếu trong hệ thống SHM, 1D CNN đóng vai trò như một công cụ trích xuất đặc trưng mạnh mẽ từ chuỗi tín hiệu không đầy đủ. Mô hình học cách nhận diện các mẫu dao động ngắn hạn và mối quan hệ lân cận trong chuỗi quan sát, từ đó dự đoán chính xác các giá trị bị mất dựa trên các đặc trưng đã học.

Phương pháp được đề xuất có một số ưu điểm nổi bật khi so sánh với các phương pháp truyền thống và kiến trúc học sâu hiện nay, cụ thể:

*So với LSTM (Long short-term memory) và GRU (Gated recurrent unit) truyền thống:* Dù LSTM và GRU là các mô hình hiệu quả cho chuỗi thời gian, chúng đòi hỏi số lượng tham số lớn và dễ gặp hiện tượng suy giảm gradient khi độ dài chuỗi tăng. 1D CNN tận dụng khả năng trích xuất đặc trưng cục bộ nhanh chóng, số tham số ít hơn, huấn luyện nhanh hơn và đặc biệt phù hợp với dữ liệu SHM - nơi nhiều và mất mát dữ liệu chủ yếu xảy ra ở quy mô cục bộ.

*So với Autoencoder:* Autoencoder có xu hướng học biểu diễn tổng thể toàn chuỗi, nên khó nắm bắt biến động ngắn

hạn - vốn là đặc trưng của dữ liệu cảm biến bị thiếu cục bộ. Trong khi đó, mô hình 1D CNN trong nghiên cứu này được thiết kế để tập trung vào các vùng lân cận khu vực thiếu hụt, nhờ đó khôi phục tín hiệu một cách chi tiết và chính xác hơn.

*So với các kiến trúc CNN khác:* Các nghiên cứu trước chủ yếu sử dụng CNN cho bài toán phân loại trạng thái kết cấu hoặc phát hiện bất thường. Cho đến nay, vẫn còn hạn chế các nghiên cứu sử dụng CNN thuần 1D để xử lý trực tiếp bài toán tái tạo dữ liệu thiếu theo dạng chuỗi thời gian liên tục, đặc biệt trong bối cảnh dự báo ngắn hạn như được đề xuất trong nghiên cứu này.

*Về chiến lược kết hợp nhiễu Gaussian:* Việc thêm nhiễu Gaussian vào dữ liệu huấn luyện giúp mô hình học được sự biến thiên tự nhiên của tín hiệu cảm biến trong môi trường thực tế, nhờ đó tăng khả năng tổng quát hóa và giảm hiện tượng quá khớp. Điều này đặc biệt quan trọng trong SHM, nơi tín hiệu thường chịu ảnh hưởng từ nhiều nguồn nhiễu không kiểm soát. Độ lệch chuẩn của nhiễu được lựa chọn và điều chỉnh thông qua thực nghiệm, từ đó tối ưu hiệu quả khôi phục dữ liệu bị thiếu.

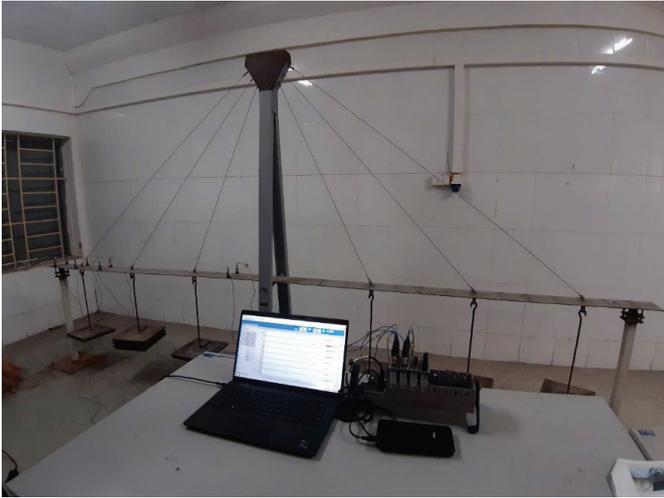
Nghiên cứu này đề xuất một hướng tiếp cận hiệu quả cho bài toán phục hồi dữ liệu dao động bị thiếu trong SHM, với kiến trúc 1D CNN tối ưu cho việc khai thác đặc trưng cục bộ của tín hiệu, kết hợp với chiến lược tăng cường dữ liệu bằng nhiễu Gaussian. Phương pháp vừa đảm bảo tính hiệu quả về dự đoán, vừa phù hợp thực tiễn với đặc thù của dữ liệu SHM - vốn nhiều nhiễu và thiếu dữ liệu cục bộ.

### 3. Kiểm tra và đánh giá hiệu suất

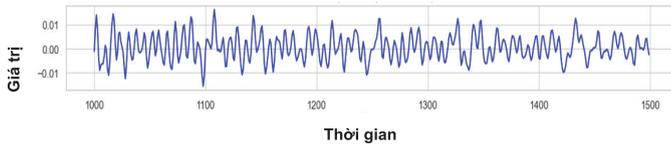
Trong nghiên cứu này, mô hình 1D CNN được áp dụng để khôi phục dữ liệu đo bị thiếu từ mô hình cầu trong phòng thí nghiệm. Huấn luyện mô hình được thực hiện trên máy tính chạy Windows 10, sử dụng CPU Intel Core i7-12700F và GPU RTX 3060 (12 GB). Mô hình được xây dựng bằng Python 3.10 với các thư viện Keras và TensorFlow.

#### 3.1. Mô hình cầu và dữ liệu đo

Một mô hình cầu dây văng dài 3,5 m được xây dựng tại Phòng Thí nghiệm DX, Trường Đại học Giao thông Vận tải (hình 2), để đánh giá hiệu quả mô hình 1D CNN trong khôi phục dữ liệu. Dầm chính của cầu có tiết diện hình chữ nhật với kích thước 0,12×0,005 m. Tháp cầu được thiết kế theo dạng chữ “A” với chiều cao đạt 1,6 m và được liên kết cứng với nền móng thông qua các bu lông có đường kính 10 mm. Hai đầu của dầm chính được gối đỡ bằng các liên kết dạng lò xo và được cố định xuống nền bằng các trụ cầu. Các trụ



Hình 2. Mô hình cầu trong phòng thí nghiệm.



Hình 3. Một phần của gia tốc (m/s<sup>2</sup>) đo được trong phòng thí nghiệm.

cầu cũng được liên kết cứng với nền móng thông qua các bu lông có đường kính 10 mm. Các cảm biến gia tốc PCB-353B34 được lắp đặt để ghi nhận dao động (hình 3), dữ liệu thu bằng hệ CompactDAQ với module NI-9234, kích thích dao động bằng búa tay và xử lý qua MATLAB/LABVIEW.

Nhằm tăng tính phong phú cho tập dữ liệu huấn luyện và nâng cao khả năng khái quát của mô hình, nghiên cứu áp dụng kỹ thuật tăng cường dữ liệu bằng cách bổ sung nhiễu Gaussian. Cụ thể, độ lệch chuẩn của dữ liệu gốc được sử dụng để điều chỉnh cường độ nhiễu. Nhiễu được tạo ra từ phân phối chuẩn, sau đó được cộng trực tiếp vào tín hiệu đầu vào để tạo thành dữ liệu tăng cường.

Phương pháp này giúp tái hiện các điều kiện đo đạc trong thực tế, nơi dữ liệu thường bị ảnh hưởng bởi nhiễu ngẫu nhiên và sai số từ thiết bị cảm biến. Việc huấn luyện mô hình với dữ liệu có nhiễu giúp hệ thống học được các đặc trưng ổn định và ít bị ảnh hưởng bởi nhiễu loạn, từ đó cải thiện độ chính xác và độ tin cậy trong các tác vụ dự báo chuỗi thời gian trong môi trường thực tế.

Xét tín hiệu gốc  $x = [x_1, x_2, \dots, x_n]$ , ký hiệu  $\epsilon \sim N(0, \sigma^2)$  là nhiễu Gaussian có trung bình bằng 0. Trong đó, độ lệch chuẩn  $\sigma$  của nhiễu được xác định theo mức độ biến động của tín hiệu ban đầu, được thiết lập theo tỷ lệ như sau:

$$\sigma = a \times std(x) \quad (3)$$

Độ lệch chuẩn của tín hiệu gốc được tính như sau:

$$std(x) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4)$$

trong đó:  $a$  là mức độ nhiễu,  $\bar{x}$  là giá trị trung bình của tín hiệu. Tín hiệu sau khi được tăng cường, ký hiệu  $x'$  được xác định như sau:

$$x' = x + \epsilon \quad (5)$$

Sau khi được tăng cường bằng cách bổ sung nhiễu, tập dữ liệu dao động được sử dụng để huấn luyện mô hình nhằm tăng khả năng thích ứng với môi trường có nhiễu và tính bất định cao. Dữ liệu này được chia thành ba phần riêng biệt: tập huấn luyện, tập xác thực và tập kiểm tra, theo tỷ lệ lần lượt là 70, 15 và 15%. Trong mỗi tập, dữ liệu tiếp tục được xử lý để tách thành hai thành phần: đầu vào  $X$  và nhãn mục tiêu  $y$ , phục vụ cho bài toán khôi phục dữ liệu dao động.

### 3.2. Đánh giá hiệu suất mô hình

Trong nghiên cứu này, một mô hình 1D CNN được xây dựng nhằm giải quyết bài toán khôi phục dữ liệu dao động bị thiếu, thu thập từ mô hình cầu dây văng quy mô phòng thí nghiệm. Để đánh giá hiệu suất dự đoán của mô hình một cách định lượng, ba chỉ số phổ biến được sử dụng để đo lường độ sai lệch giữa giá trị dự đoán  $\hat{y}_i$  và giá trị quan sát thực tế  $y_i$ . Các chỉ số này được định nghĩa như sau:

Sai số căn bậc hai trung bình (RMSE):

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

Sai số tuyệt đối trung bình (MAE):

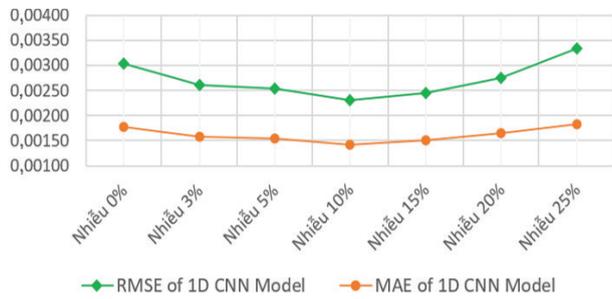
$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

Hệ số xác định ( $R^2$ )

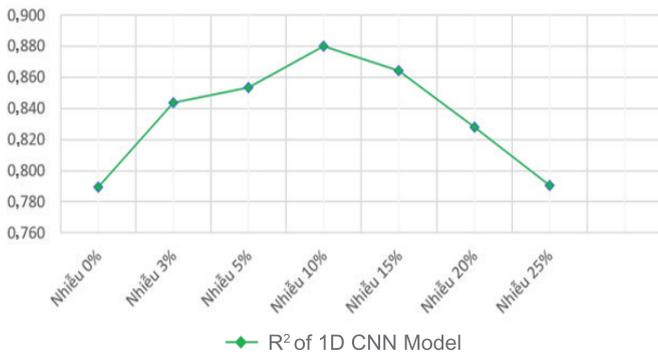
$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

trong đó:  $\bar{y}$  là giá trị trung bình của các quan sát thực tế và  $n$  là số lượng mẫu. Giá trị RMSE và MAE càng thấp cho thấy mô hình dự đoán càng chính xác. Trong khi đó, hệ số  $R^2$  càng cao cho thấy mô hình phù hợp tốt hơn với dữ liệu thực tế.

Để đánh giá tác động của dữ liệu huấn luyện được tăng cường bằng nhiễu đến hiệu suất của mô hình, các mô hình đã được huấn luyện với dữ liệu được bổ sung nhiễu Gaussian ở nhiều mức độ khác nhau: 0, 3, 5, 10, 15, 20 và 25% độ lệch chuẩn. Hiệu suất của các mô hình được so sánh thông qua ba chỉ số: RMSE, MAE và hệ số xác định  $R^2$ , được thể hiện trong các biểu đồ ở hình 4, 5 và bảng 2.



Hình 4. So sánh RMSE và MAE giữa các mô hình có mức độ nhiễu khác nhau.



Hình 5. So sánh R² giữa các mô hình có mức độ nhiễu khác nhau.

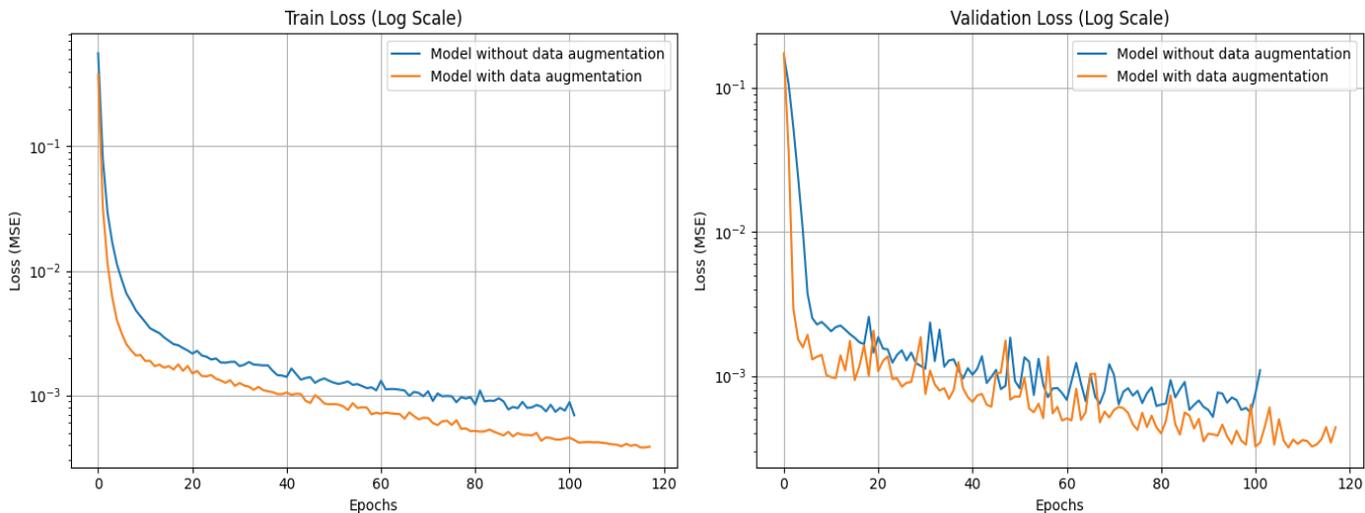
Bảng 2. Tổng hợp kết quả các chỉ số đánh giá các mô hình với mức độ nhiễu Gaussian khác nhau.

Chỉ số đánh giá	Mức độ tăng cường dữ liệu bằng bổ sung nhiễu Gaussian						
	0%	3%	5%	10%	15%	20%	25%
RMSE	0,00304	0,00262	0,00254	0,00231	0,00246	0,00275	0,00335
MAE	0,00178	0,00157	0,00153	0,00141	0,00150	0,00166	0,00182
R²	0,7897	0,8436	0,8534	0,8798	0,8642	0,8278	0,7907

Hình 4 và bảng 2 cho thấy, mô hình đạt RMSE=0,00304 với dữ liệu gốc (0% nhiễu). Đáng chú ý, khi áp dụng nhiễu nhẹ (3-10%), hiệu suất được cải thiện rõ rệt, với RMSE thấp nhất là 0,00231 và MAE thấp nhất là 0,00141 tại mức nhiễu 10%. Hình 5 và bảng 2 cho thấy, chỉ số R² cũng tăng từ 0,7897 (0% nhiễu) lên 0,8798 (10% nhiễu), cho thấy khả năng khái quát hóa được cải thiện. Tuy nhiên, khi mức nhiễu vượt quá 15%, các chỉ số hiệu suất bắt đầu suy giảm. Kết quả này cho thấy, việc tăng cường dữ liệu bằng nhiễu Gaussian ở mức vừa phải giúp cải thiện độ chính xác và tính ổn định của mô hình, trong khi nhiễu quá lớn gây hiệu ứng ngược. Những phát hiện này có ý nghĩa thực tiễn quan trọng đối với các hệ thống giám sát sức khỏe kết cấu cầu, nơi dữ liệu thu nhận từ cảm biến thường không tránh khỏi bị ảnh hưởng bởi nhiễu và sai số đo lường. Việc lựa chọn mức tăng cường phù hợp là cần thiết để cân bằng giữa tính kháng nhiễu và độ ổn định trong quá trình huấn luyện mô hình học sâu.

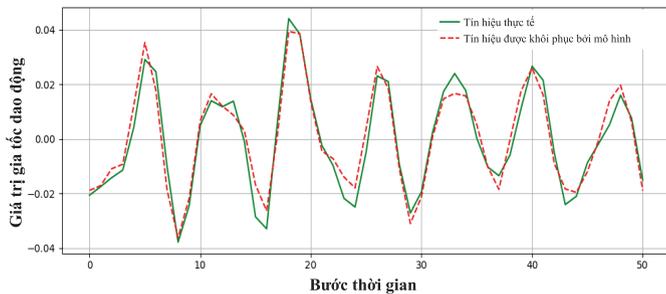
Đường cong mất mát huấn luyện và xác thực, được đo bằng sai số bình phương trung bình (MSE) của hai mô hình không có và có tăng cường dữ liệu bằng nhiễu 10% độ lệch chuẩn, được trình bày trong hình 6.

Như thể hiện trong hình 6, mô hình đề xuất 1D CNN có tăng cường dữ liệu cho kết quả vượt trội hơn so với mô hình không có tăng cường dữ liệu ở cả giai đoạn huấn luyện và kiểm tra. Mô hình đạt giá trị mất mát thấp hơn, hội tụ nhanh hơn và duy trì độ ổn định huấn luyện cao hơn. Cần lưu ý rằng, số epochs huấn luyện khác nhau giữa các mô hình do áp dụng kỹ thuật dừng sớm (early stopping), nhằm dừng huấn luyện khi mất mát kiểm tra không còn cải thiện, từ đó đảm bảo mỗi mô hình được huấn luyện với số epochs tối ưu và tránh hiện tượng quá khớp.

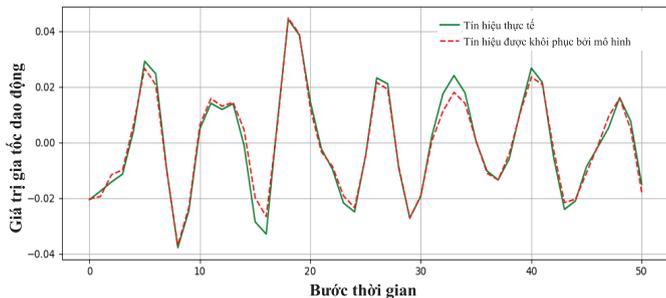


Hình 6. Mất mát MSE trong quá trình huấn luyện trên tập dữ liệu huấn luyện (training) và tập dữ liệu xác thực (validation).

Hình 7 và hình 8 trình bày sự so sánh kết quả khôi phục tín hiệu dao động giữa mô hình 1D CNN trong hai trường hợp: có và không áp dụng kỹ thuật tăng cường dữ liệu. Trục hoành biểu thị các bước thời gian, trong khi trục tung thể hiện giá trị gia tốc dao động (m/s<sup>2</sup>). Đường màu xanh nét liền đại diện cho tín hiệu thực tế (Actual), còn đường màu đỏ nét đứt là tín hiệu được khôi phục bởi mô hình (Reconstructed). Cùng một tập dữ liệu được sử dụng trong cả hai trường hợp nhằm đảm bảo tính nhất quán và khả năng so sánh trực quan giữa các kết quả.



Hình 7. Tín hiệu dao động thực tế (Actual) và tín hiệu khôi phục (Reconstructed) sử dụng mô hình 1D CNN (không có tăng cường dữ liệu).



Hình 8. Tín hiệu dao động thực tế (Actual) và tín hiệu khôi phục (Reconstructed) sử dụng mô hình 1D CNN (có tăng cường dữ liệu).

Bảng 3. So sánh hiệu suất mô hình đề xuất 1D CNN với các phương pháp hồi quy và học sâu.

Mô hình đánh giá	Ký hiệu	RMSE	MAE	R <sup>2</sup>
LinearRegression	A	0,002660	0,001552	0,816325
XGBRegressor	B	0,003213	0,001632	0,766892
LGBMRegressor	C	0,002894	0,001561	0,812039
MLP (or Dense)	D	0,002717	0,001498	0,833750
RNN	E	0,002677	0,001571	0,838667
Mô hình đề xuất 1D CNN	F	0,002310	0,001414	0,879782
So sánh 1D CNN với LinearRegression	(F-A)/A	-13,1%	-8,9%	7,8%
So sánh 1D CNN với XGBRegressor	(F-B)/B	-28,1%	-13,4%	14,7%
So sánh 1D CNN với LGBMRegressor	(F-C)/C	-20,2%	-9,5%	8,3%
So sánh 1D CNN với MLP	(F-D)/D	-15,0%	-5,6%	5,5%
So sánh 1D CNN với RNN	(F-E)/E	-13,7%	-10,0%	4,9%

Kết quả cho thấy, cả hai mô hình đều có thể xấp xỉ hợp lý tín hiệu đo được. Tuy nhiên, mô hình đề xuất 1D CNN có tăng cường dữ liệu thể hiện sự phù hợp vượt trội với tín hiệu thực so với mô hình không có tăng cường dữ liệu. Cụ thể, mô hình này khôi phục chính xác hơn cả biên độ lẫn dạng sóng của tín hiệu dao động.

Bảng 3 trình bày kết quả đánh giá hiệu suất của mô hình 1D CNN đề xuất so với các mô hình hồi quy và học sâu, gồm: Linear Regression (hồi quy tuyến tính), XGBRegressor (thuật toán hồi quy XGBoost - Tăng cường độ dốc cực đại), LGBMRegressor (thuật toán hồi quy LightGBM - Tăng cường độ dốc nhẹ), MLP (Mạng nơ-ron truyền thẳng nhiều lớp) và RNN (Mạng nơ-ron hồi tiếp) trên tập kiểm tra. Kết quả cho thấy, mô hình đề xuất 1D CNN đạt giá trị RMSE, MAE thấp nhất và hệ số xác định R<sup>2</sup> cao nhất (RMSE=0,002310, MAE=0,001414, R<sup>2</sup>=0,879782), cho thấy độ chính xác và khả năng tổng quát vượt trội. Cụ thể, so với Linear Regression, 1D CNN giúp giảm RMSE và MAE lần lượt 13,1 và 8,9%, đồng thời cải thiện R<sup>2</sup> thêm 7,8%. Mô hình cũng cho thấy, mức cải thiện đáng kể so với các thuật toán học máy như XGBRegressor và LGBMRegressor, cũng như các mô hình học sâu như MLP và RNN. Đặc biệt, khi so với RNN - một mô hình phổ biến trong xử lý chuỗi thời gian - 1D CNN vẫn cho kết quả tốt hơn với RMSE giảm 13,7% và R<sup>2</sup> tăng 4,9%. Những kết quả này khẳng định tính hiệu quả của mô hình đề xuất 1D CNN và tăng cường dữ liệu trong bài toán khôi phục dữ liệu dao động trong hệ thống SHM.

#### 4. Kết luận

Nghiên cứu này đã chứng minh rằng việc áp dụng mạng nơ-ron tích chập một chiều là một hướng tiếp cận hiệu quả và phù hợp cho bài toán khôi phục dữ liệu dao động theo chuỗi thời gian trong các hệ thống giám sát sức khỏe kết cấu. Mô hình 1D CNN cho thấy, khả năng trích xuất đặc trưng cục bộ vượt trội từ tín hiệu đầu vào, đồng thời có tốc độ huấn luyện nhanh, độ ổn định cao và kiến trúc gọn nhẹ - rất phù hợp với các ứng dụng trong môi trường thực tế, nơi dữ liệu thường bị gián đoạn hoặc nhiễu loạn.

Về mặt học thuật, nghiên cứu đã đóng góp một quy trình xây dựng mô hình học sâu chuyên biệt cho bài toán khôi phục dữ liệu mất mát trong SHM, đồng thời làm rõ hiệu quả của việc tăng cường dữ liệu bằng nhiễu Gaussian. Cụ thể, kết quả cho thấy, việc bổ sung nhiễu với mức hợp lý có thể cải thiện đáng kể hiệu suất dự đoán và khả năng khái quát hóa của mô hình, từ đó nâng cao độ tin cậy trong môi trường dữ liệu thực.

Về mặt hạn chế, nghiên cứu này mới chỉ được thực hiện trên dữ liệu dao động thu thập từ mô hình cầu trong phòng thí nghiệm và chưa xem xét trường hợp sử dụng thông tin từ nhiều cảm biến khác nhau để hỗ trợ khôi phục dữ liệu bị thiếu của một cảm biến cụ thể.

Trong tương lai, các hướng nghiên cứu mở rộng có thể bao gồm:

(1) Triển khai và đánh giá mô hình trên dữ liệu thực địa từ các công trình ngoài thực tế;

(2) Mở rộng sang các loại công trình khác như đập thủy điện, nhà cao tầng hoặc công trình công nghiệp;

(3) Tích hợp thông tin từ nhiều loại cảm biến khác nhau để cải thiện độ chính xác và khả năng thích ứng của mô hình trong điều kiện giám sát đa chiều.

Ngoài ra, việc kết hợp 1D CNN với các kiến trúc tiên tiến khác như encoder-decoder hoặc attention mechanism cũng là một hướng nghiên cứu hứa hẹn nhằm nâng cao hiệu quả khôi phục dữ liệu trong các hệ thống SHM phức tạp.

## LỜI CẢM ƠN

Nghiên cứu này được tài trợ bởi Trường Đại học Giao thông Vận tải trong đề tài mã số T2025-CT-018. Các tác giả xin trân trọng cảm ơn.

## TÀI LIỆU THAM KHẢO

[1] V.G.M. Annamdas, S. Bhalla, C.K. Soh (2017), “Applications of structural health monitoring technology in Asia”, *Structural Health Monitoring*, **16**(3), pp.324-346, DOI: 10.1177/1475921716653278.

[2] C.R. Farrar, K. Worden (2007), “An introduction to structural health monitoring”, *Philosophical Transactions of The Royal Society A: Mathematical, Physical and Engineering Sciences*, **365**(1851), pp.303-315, DOI: 10.1098/rsta.2006.1928.

[3] J.P. Lynch, K.J. Loh (2006), “A summary review of wireless sensors and sensor networks for structural health monitoring”, *Shock and Vibration Digest*, **38**(2), pp.91-128, DOI: 10.1177/0583102406061499.

[4] H. Li, J. Ou (2016), “The state of the art in structural health monitoring of cable-stayed bridges”, *J. Civil Struct. Health Monit.*, **6**, pp.43-67, DOI: 10.1007/s13349-015-0115-x.

[5] Y. Bao, H. Li, X. Sun, et al. (2013), “Compressive sampling-based data loss recovery for wireless sensor networks used in civil structural health monitoring”, *Struct. Health Monit.*, **12**(1), pp.78-95, DOI: 10.1177/1475921712462936.

[6] V.S.G. Thadikemalla, A.S. Gandhi (2018), “A data loss recovery technique using compressive sensing for structural health monitoring applications”, *KSCE J. Civ. Eng.*, **22**, pp.5084-5093, DOI: 10.1007/s12205-017-2070-z.

[7] R.M.C. Bastos, M.A.T. Figueiredo (2017), “Reconstruction of missing data in structural health monitoring using Kalman filters and EM algorithms”, *Mechanical Systems and Signal Processing*, **85**, pp.829-845, DOI: 10.1016/j.ymssp.2016.09.025.

[8] Y. LeCun, L. Bottou, Y. Bengio, et al. (1998), “Gradient-based learning applied to document recognition”, *Proceedings of The IEEE*, **86**(11), pp.2278-2324, DOI: 10.1109/5.726791.

[9] B.K. Oh, B. Glisic, Y. Kim, et al. (2020), “Convolutional neural network-based data recovery method for structural health monitoring”, *Struct. Health. Monit.*, **19**(6), pp.1821-1838, DOI: 10.1177/1475921719897571.

[10] P. Moeinifard, M.S. Rajabi, M. Bitaraf (2021), “Lost vibration test data recovery using convolutional neural network: A case study”, *AUT Journal of Civil Engineering*, **5**(4), pp.701-714, DOI: 10.22060/ajce.2022.20641.5773.

[11] P. Ni, Y. Li, L. Sun, et al. (2022), “Traffic-induced bridge displacement reconstruction using a physics-informed convolutional neural network”, *Comput. Struct.*, **271**, DOI: 10.1016/j.compstruc.2022.106863.

[12] Y. Li, P. Ni, L. Sun, et al. (2022), “A convolutional neural network-based full-field response reconstruction framework with multitype inputs and outputs”, *Struct. Control. Health Monit.*, **29**(7), DOI: 10.1002/stc.2961.

[13] G. Fan, J. Li, H. Hao (2021a), “Dynamic response reconstruction for structural health monitoring using densely connected convolutional networks”, *Struct. Health. Monit.*, **20**(4), pp.1373-1391, DOI: 10.1177/1475921720916881.

[14] G. Fan, J. Li, H. Hao (2021b), “Using deep learning technique for recovering the lost measurement data”, *EASEC16: Proceedings of The 16th East Asian-Pacific Conference on Structural Engineering and Construction*, pp.229-237, DOI: 10.1007/978-981-15-8079-6\_22.

[15] N.T.C. Nhung, T.Q. Minh (2024), “Recovery of sensor data in supervising of structure strength using integrated neuron networks combined with regressive neuron networks”, *Journal of Transport Technology*, **9**, pp.39-42 (in Vietnamese).

[16] L.V. Vu, N.D. Luong, T.T. Hiep, et al. (2024), “Data recovery in bridge structural health monitoring systems using a hybrid graph convolutional network and long short-term memory model”, *Transport and Communications Science Journal*, **75**(9), pp.2385-2399, DOI: 10.47869/tcsj.75.9.12 (in Vietnamese).