



DATA RECOVERY IN BRIDGE STRUCTURAL HEALTH MONITORING SYSTEMS USING A HYBRID GRAPH CONVOLUTIONAL NETWORK AND LONG SHORT-TERM MEMORY MODEL

Le Van Vu, Nguyen Duc Luong, Tran The Hiep , Bui Tien Thanh,
Nguyen Thi Cam Nhung*

University of Transport and Communications, No 3 Cau Giay Street, Hanoi, Vietnam

ARTICLE INFO

TYPE: Research Article

Received: 14/09/2024

Revised: 05/12/2024

Accepted: 12/12/2024

Published online: 15/12/2024

<https://doi.org/10.47869/tcsj.75.9.12>

* *Corresponding author*

Email: ncnhung@utc.edu.vn ; Tel: +84947610939

Abstract. Structural Health Monitoring (SHM) systems often face the issue of data loss, which reduces the effectiveness and accuracy of the analysis and assessment of the condition of structures. This paper proposes a model combining Graph Convolutional Networks (GCN) and Long Short-Term Memory (LSTM) networks to address this issue. The model leverages the capability of Graph Convolutional Networks (GCN) to capture spatial relationships between sensors and the ability of Long Short-Term Memory (LSTM) networks to process time-series data, enabling the model to accurately predict missing values based on historical data and sensor locations. The model is tested on acceleration data collected from 8 sensors attached to a cable-stayed bridge in a laboratory setting. Experimental results demonstrate that the model achieves good prediction performance, with a mean squared error (MSE) of 0,0003 and a mean absolute error (MAE) of 0,007 after 500 iterations. Comparison charts between real and reconstructed data show similar fluctuations between the two data sets, indicating the model's ability to capture the trends of real-world data.

Keywords: Graph Convolutional Network (GCN), Long Short-Term Memory (LSTM), Structural Health Monitoring (SHM)

@ 2024 University of Transport and Communications



KHÔI PHỤC DỮ LIỆU CHO HỆ THỐNG GIÁM SÁT SỨC KHOẺ CÔNG TRÌNH CẦU SỬ DỤNG MÔ HÌNH MẠNG TÍCH CHẬP ĐỒ THỊ VÀ MẠNG BỘ NHỚ NGẮN DÀI HẠN

Lê Văn Vũ, Nguyễn Đức Lương, Trần Thế Hiệp, Bùi Tiến Thành,
Nguyễn Thị Cẩm Nhung*

Trường Đại học Giao thông vận tải, Số 3 Cầu Giấy, Hà Nội, Việt Nam

THÔNG TIN BÀI BÁO

CHUYÊN MỤC: Công trình khoa học

Ngày nhận bài: 14/09/2024

Ngày nhận bài sửa: 05/12/2024

Ngày chấp nhận đăng: 12/12/2024

Ngày xuất bản Online: 15/12/2024

<https://doi.org/10.47869/tcsj.75.9.12>

* Tác giả liên hệ

Email: ncnhung@utc.edu.vn; Tel: +84947610939

Tóm tắt. Hệ thống giám sát sức khỏe kết cấu (SHM) thường phải đối mặt với vấn đề mất mát dữ liệu, điều này làm giảm hiệu quả và độ chính xác trong quá trình phân tích, đánh giá tình trạng của các công trình. Bài báo đề xuất một mô hình kết hợp giữa mạng nơ-ron tích chập đồ thị (GCN) và mạng bộ nhớ ngắn dài hạn (LSTM) để giải quyết vấn đề này. Mô hình này tận dụng khả năng của GCN trong việc nắm bắt các mối quan hệ không gian giữa các cảm biến và khả năng của LSTM trong việc xử lý dữ liệu chuỗi thời gian, giúp mô hình dự đoán chính xác các giá trị bị thiếu dựa trên dữ liệu lịch sử và vị trí của các cảm biến. Mô hình được thử nghiệm trên dữ liệu gia tốc thu thập từ 8 cảm biến gắn trên cầu dây văng trong phòng thí nghiệm. Kết quả thực nghiệm cho thấy mô hình đạt được hiệu suất dự đoán tốt với sai số toàn phương trung bình (MSE) là 0,0003 và sai số tuyệt đối trung bình (MAE) là 0,007 sau 500 bước lặp. Các biểu đồ so sánh dữ liệu thực tế và dữ liệu được khôi phục cũng cho thấy các biến động của hai chuỗi dữ liệu là khá tương đồng, chứng tỏ mô hình có khả năng nắm bắt xu hướng của dữ liệu thực tế.

Từ khóa: Mạng đồ thị tích chập (GCN), mạng bộ nhớ ngắn dài hạn (LSTM), hệ thống giám sát sức khỏe công trình (SHM)

@ 2024 Trường Đại học Giao thông vận tải

1. GIỚI THIỆU

Hệ thống cơ sở hạ tầng, đặc biệt là các công trình giao thông tại Việt Nam, đang trong giai đoạn hoàn thiện và phát triển mạnh mẽ. Tuy nhiên, chất lượng của các công trình giảm dần

theo thời gian do điều kiện sử dụng và vận hành, đồng thời cũng có nguy cơ gặp phải các mối nguy hiểm không lường trước được như các sự kiện động đất, lũ lụt,... Để tránh thiệt hại về kinh tế và đảm bảo sự an toàn cho tính mạng con người các kỹ thuật và tiêu chuẩn kiểm tra kết cấu đã được đưa ra, chẳng hạn như kiểm tra trực quan và các kỹ thuật đánh giá không phá hủy. Tuy nhiên, các kỹ thuật kiểm tra kết cấu truyền thống này thường tốn kém, mất thời gian và không an toàn cho công nhân. Nhận thấy điều đó, các hệ thống giám sát sức khỏe kết cấu (Structural health monitoring - SHM) đánh giá tình trạng kết cấu theo thời gian thực thông qua những tiến bộ trong công nghệ cảm biến và thiết bị đo lường đã thu hút sự chú ý của các nhà quản lý và nhà nghiên cứu trong những năm gần đây. Việc đưa vào sử dụng các hệ thống SHM cho công trình giao thông không những khắc phục những nhược điểm của các kỹ thuật truyền thống mà còn giúp phát hiện sớm các hư hỏng đang xảy ra, từ đó có thể bảo trì và sửa chữa kịp thời, đảm bảo sự an toàn và độ tin cậy của kết cấu với chi phí tối thiểu.

Trong SHM, các phản ứng của kết cấu được đo lường bằng cách sử dụng nhiều loại cảm biến khác nhau, bao gồm cảm biến gia tốc, cảm biến chuyển vị và cảm biến biến dạng. Các cảm biến này được lắp đặt trong các bộ phận kết cấu chính để đo lường các thông số của kết cấu. Từ đó tính toán và đánh giá an toàn cũng như hiệu suất của kết cấu một cách chính xác an toàn và hiệu suất của kết cấu dựa trên các phản ứng này trong các điều kiện thực tế [1].

Trong các hệ thống SHM hiện tại, xuất hiện những trường hợp mất mát dữ liệu từ đo đạc của kết cấu vì các cảm biến đã gặp sự cố hoặc hỏng hóc. Có thể là sự cố tạm thời như ví dụ do mất điện hoặc là các thiệt hại ko thể khắc phục như do tuổi thọ của các thành phần cảm biến [2]. Bên cạnh đó, trong trường hợp hệ thống cảm biến không dây, việc mất dữ liệu có thể xảy ra trong quá trình truyền dữ liệu giữa các cảm biến và các máy thu từ xa [3]. Những trường hợp này dẫn đến các bộ dữ liệu không đầy đủ, khó phân tích do thiếu dữ liệu. Ví dụ, chuyển vị trong một mặt cắt ngang dầm có thể được đánh giá bằng cách sử dụng hai cảm biến biến dạng song song, tuy nhiên nếu một cảm biến gặp sự cố hoặc hỏng hóc thì chuyển vị này không thể được đánh giá.

Do đó, để giải quyết các vấn đề liên quan đến việc mất dữ liệu đo lường này, nhiều phương pháp để khôi phục và ước tính các phép đo bị mất đã được phát triển. Trong một nghiên cứu về việc khôi phục dữ liệu bị mất trong hệ thống cảm biến không dây, một thuật toán cải tiến để khắc phục khó khăn phụ thuộc vào bộ vi điều khiển giới thiệu bởi Yu và các cộng sự [4]. Công nghệ này khôi phục các tín hiệu bằng cách sử dụng ít dữ liệu đo lường hơn so với số lượng dữ liệu đo lường được cung cấp bởi SHM. Thuật toán này cũng được sử dụng để giám sát dài hạn các cây cầu bằng hệ thống cảm biến không dây, giúp khôi phục các phản ứng động và ước tính các tham số từ dữ liệu chuỗi thời gian. Các tham số này sau đó được dùng để xây dựng mô hình phần tử hữu hạn (Finite Element - FE) [5]. Một nghiên cứu khác đề xuất phương pháp giám sát dựa trên sự phụ thuộc của các cảm biến ở các vị trí khác nhau, sử dụng phương pháp phi tham số để mô hình hóa dữ liệu giám sát biến dạng. Dựa trên phân tích tương quan, dữ liệu bị mất được khôi phục thông qua sự nội suy của các đặc điểm giữa các phản ứng của các cảm biến [6].

Trong những năm gần đây, nhiều phương pháp đã được phát triển để áp dụng vào bài toán giám sát sức khỏe kết cấu. Trong đó, học máy (ML - Machine Learning) và học sâu (DL - Deep Learning) cùng với sự phát triển nhanh chóng của công nghệ cảm biến đã mang lại những tiến bộ đáng kể trong nhiều lĩnh vực này. Các hệ thống SHM dựa trên DL không chỉ tăng cường khả năng dự đoán và phát hiện sớm các vấn đề kết cấu mà còn tối ưu hóa quy trình bảo trì và rủi ro cho các công trình quan trọng. Những tiến bộ này đã cải thiện đáng kể độ chính xác và hiệu quả trong việc theo dõi và đánh giá tình trạng kết cấu, mở ra những khả năng mới cho việc bảo trì và đảm bảo an toàn công trình. Trong một nghiên cứu, một mạng nơ-ron sâu (Deep

Neural Network - DNN) đã được sử dụng để tự động xác định dữ liệu bị mất từ các phản ứng động đo được. Do đó DNN, được huấn luyện với các biểu đồ thời gian của các dao động kết cấu, đã phân loại thành công dữ liệu bình thường và dữ liệu bị mất từ các gia tốc động đo được từ SHM dài hạn [7]. Một trong những kiểu DNN phổ biến nhất là mạng CNN (Convolutional Neural Network), được sử dụng rộng rãi trong nhận dạng hình ảnh và thị giác máy tính [8]. Trong một nghiên cứu lĩnh vực SHM, các CNN có hiệu suất vượt trội trong việc xử lý dữ liệu hình ảnh dựa trên pixel đã được sử dụng để giải quyết vấn đề phát hiện vết nứt dựa trên hình ảnh, phát hiện ăn mòn và xác định thiệt hại dựa trên hình ảnh. Sau khi được huấn luyện mạng CNN có thể tự động nhận dạng các vết nứt từ các hình ảnh mới về bề mặt của các dầm cầu [9].

Mạng nơ-ron đồ thị tích chập (Graph Convolutional Network - GCN) là một phiên bản mở rộng của mạng nơ-ron tích chập (CNN), trong đó kết nối giữa các nút được xác định trước (hoặc học được) thông qua ma trận kề toàn cục thay vì các kết nối cục bộ tiêu chuẩn [10]. Trong lĩnh vực giao thông, GCN khai thác cấu trúc của mạng lưới giao thông dưới dạng đồ thị giúp mô hình hóa mối quan hệ không gian giữa các nút (điểm giao thông) và cải thiện độ chính xác trong việc dự báo lưu lượng, tốc độ và kẹt xe, giúp cải thiện hệ thống giao thông và đưa ra cảnh báo sớm [11,12]. Thế nhưng khi đồ thị lớn mạng GCN dễ gặp vấn đề về tổng quát hóa dữ liệu và khó xử lý các mối quan hệ động trong dữ liệu thời gian.

Mạng nơ-ron hồi quy (Recurrent Neural Network - RNN) được biết đến như một loại mạng nơ-ron đặc biệt có khả năng xử lý dữ liệu tuần tự và nắm bắt các mối quan hệ trong dữ liệu thời gian dài. LSTM (Long Short-Term Memory) là một loại mạng nơ-ron hồi quy RNN được thiết kế để khắc phục một số hạn chế của các RNN truyền thống. Đặc trưng LSTM nằm ở khả năng duy trì thông tin cần thiết và loại bỏ các thông tin không cần thiết thông qua cơ chế cổng, đặc biệt là cổng quên (forget). Điều này giúp cho LSTM học và mô hình hóa các mối quan hệ giữa các sự kiện cách nhau nhiều bước thời gian, giúp cải thiện hiệu suất trong các bài toán chuỗi thời gian phức tạp. Trong nghiên cứu của mình, Yi và các cộng sự đã sử dụng phương pháp dự đoán tính toán để khôi phục dữ liệu dịch chuyển do nhiệt trên cầu dây văng [13]. LSTM được áp dụng để tái tạo dữ liệu bị thiếu, cải thiện độ chính xác của hệ thống giám sát sức khỏe cầu. Tuy nhiên LSTM có một số nhược điểm bao gồm yêu cầu nhiều tài nguyên tính toán dẫn đến thời gian huấn luyện dài, dễ bị overfitting với dữ liệu huấn luyện không đa dạng, khó xử lý dữ liệu dài hạn và hiệu suất giảm khi dữ liệu không đồng nhất hoặc biến đổi lớn.

Trong nghiên cứu này, GCN và LSTM được kết hợp để khôi phục dữ liệu thu thập từ các cảm biến gia tốc của một mô hình cầu trong phòng thí nghiệm. Bộ dữ liệu thu thập được sẽ được chia thành 2 tập, bao gồm tập huấn luyện và tập kiểm tra. Tập kiểm tra được tạo bằng cách giả định một số vị trí bị mất mát dữ liệu. Mô hình sau khi được huấn luyện sẽ được sử dụng để khôi phục dữ liệu bị mất trong tập kiểm tra. Hiệu suất mô hình được đánh giá bằng các chỉ số MSE (Root Mean Square Error), MAE (Mean Absolute Error) và biểu đồ trực quan so sánh dữ liệu gốc và dữ liệu được khôi phục.

Kết cấu cầu sẽ được mô hình hoá như một đồ thị. Cụ thể, mỗi cảm biến gia tốc được lắp đặt trên cầu được xem như một "nút" trong đồ thị, chứa đựng thông tin về gia tốc tại vị trí đó. Các nút này không hoạt động độc lập mà được liên kết với nhau thông qua các "cạnh", thể hiện mối quan hệ không gian giữa chúng. Đó có thể là khoảng cách vật lý hoặc đặc trưng kết cấu giữa các "nút" trong đồ thị. GCN-LSTM sẽ nhận vào một chuỗi các đồ thị, mỗi đồ thị tương ứng với một thời điểm đo đạc. Dữ liệu gia tốc từ các cảm biến sẽ được cập nhật liên tục vào các nút của đồ thị. GCN-LSTM sẽ học cách phân tích sự thay đổi của gia tốc theo thời gian và không gian trên toàn bộ cầu. Khi một cảm biến bị lỗi hoặc mất kết nối, GCN-LSTM có thể sử

dụng thông tin từ các cảm biến xung quanh và các thời điểm trước đó để dự đoán giá trị gia tốc tại vị trí của cảm biến bị lỗi.

Dữ liệu gia tốc được sử dụng làm đầu vào cho bài toán khôi phục dữ liệu trong nghiên cứu vì đây là loại dữ liệu quan trọng trong các ứng dụng giám sát sức khỏe kết cấu, đặc biệt trong lĩnh vực cầu đường và các công trình hạ tầng lớn. Từ các giá trị gia tốc, các kỹ sư có thể phân tích động lực học và xác định tần số riêng của kết cấu, giúp phát hiện ra các biến đổi về đặc tính động lực học. Thông qua việc so sánh các đặc tính gia tốc của công trình qua thời gian cho phép phát hiện và xác định sự suy giảm chất lượng hoặc vị trí hư hỏng. Ngoài ra, dựa vào xu hướng của dữ liệu gia tốc còn có thể dự báo tuổi thọ còn lại của công trình, từ đó hỗ trợ trong việc lập kế hoạch bảo trì và sửa chữa một cách hợp lý.

2. PHƯƠNG PHÁP ĐỀ XUẤT

2.1. Mạng bộ nhớ ngắn dài hạn (Long Sort Term Memory - LSTM)

Kiến trúc của LSTM (Long Short-Term Memory), được đề xuất bởi Hochreiter và Schmidhuber vào năm 1997 [14]. LSTM là một loại mạng nơ-ron RNN được thiết kế để xử lý và dự đoán chuỗi dữ liệu có độ dài biến đổi và mối quan hệ phụ thuộc dài hạn. Thành phần chính của mạng LSTM là khối nhớ, không chỉ giúp ghi nhớ các trạng thái ẩn của các bước thời gian trước thông qua một tế bào nhớ (memory cell), mà còn cung cấp ba cổng điều chỉnh quan trọng để quyết định giữ lại hay xóa thông tin thời gian.

Sự phát triển của ba cổng, cụ thể là cổng đầu vào (input gate), cổng quên (forget gate) và cổng đầu ra (output gate), là một trong những đóng góp lớn nhất của LSTM, giúp giải quyết hai thách thức mà RNN truyền thống phải đối mặt. Thách thức đầu tiên là khả năng ghi nhớ thông tin trong khoảng thời gian dài, và thách thức thứ hai là hiện tượng biến mất độ dốc (vanishing gradient) của RNN. Cổng vào i_t xác định những thông tin nào nên được thêm vào trạng thái hiện tại. Cổng quên f_t xác định thông tin nào từ các trạng thái trước đó sẽ được xóa, do đó duy trì kích thước phù hợp của trạng thái cell hiện tại. Cuối cùng, cổng ra o_t xác định phần nào sẽ được xuất ra bằng cách lọc đầu vào và trạng thái ẩn trước đó. Giả sử chuỗi thời gian đầu vào là $x = (x_1, \dots, x_n)$ và giá trị dự đoán là y . Mô hình LSTM được minh họa trong Hình 1.

Ở bước t của mô hình LSTM:

a. Input và Output:

C_{t-1} : Trạng thái cell từ thời điểm trước đó.

h_{t-1} : Trạng thái ẩn từ thời điểm trước đó.

x_t : Đầu vào hiện tại.

C_t : Trạng thái cell hiện tại.

h_t : Trạng thái ẩn hiện tại.

b. Các cổng:

Cổng vào (i_t) để xác định thông tin đầu vào nào sẽ cập nhật bộ nhớ, với hàm Sigmoid lọc thông tin (cho qua 0 hoặc 1) và hàm tanh định trọng số từ -1 đến 1.

$$i_t = \sigma(x_t \cdot W_i + h_{t-1} \cdot W_i + b_i) \quad (1)$$

$$\tilde{C}_t = \tanh(x_t \cdot W_c + h_{t-1} \cdot W_c + b_c) \quad (2)$$

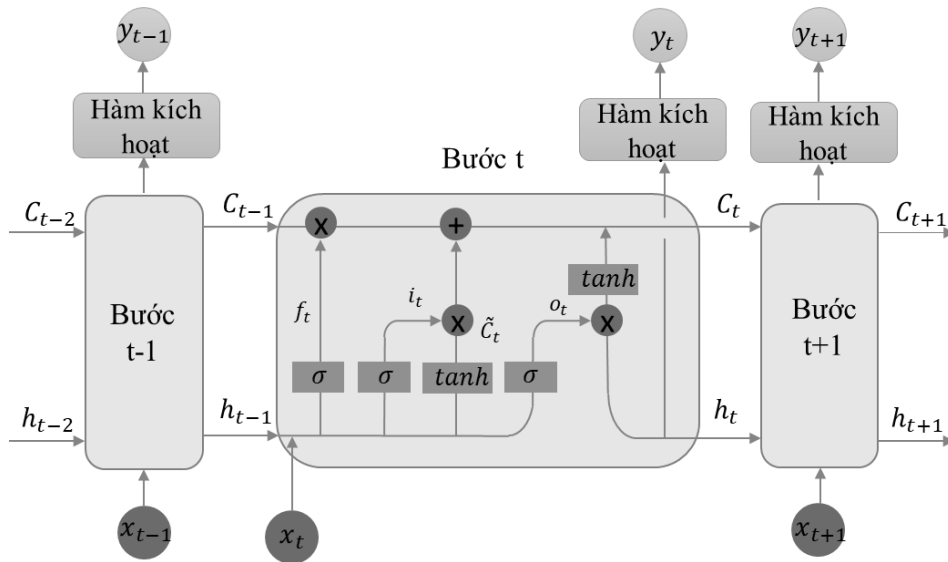
Cổng quên (f_t) quyết định phần thông tin nào từ bộ nhớ cũ được loại bỏ, dựa vào đầu vào và trạng thái trước đó, với giá trị từ 0 (loại bỏ) đến 1 (giữ lại).

$$f_t = \sigma(x_t \cdot W_f + h_{t-1} \cdot W_f + b_f) \quad (3)$$

Cổng đầu ra (o_t) xác định thông tin nào từ bộ nhớ được sử dụng làm đầu ra, thông qua hàm Sigmoid và tanh, quyết định trọng số thông tin từ -1 đến 1, tạo ra đầu ra cuối cùng.

$$o_t = \sigma(x_t \cdot W_o + h_{t-1} \cdot W_o + b_o) \quad (4)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (5)$$



Hình 1. Kiến trúc của LSTM.

2.2. Mạng đồ thị tích chập GCN (Graph Convolutional Network - GCN)

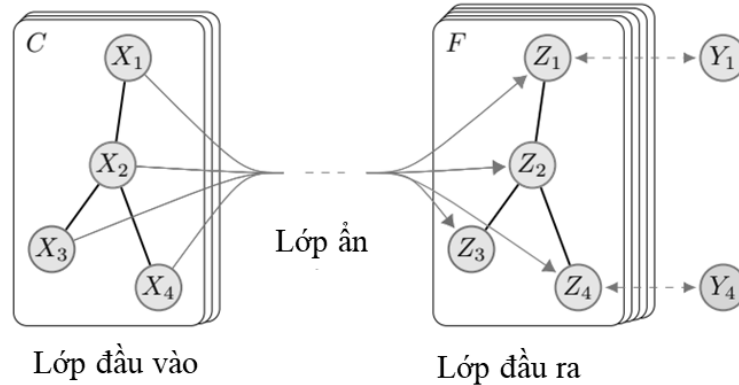
GCN là một loại mạng nơ-ron sâu được thiết kế để làm việc với dữ liệu có cấu trúc đồ thị. GCN mở rộng khái niệm tích chập từ không gian hình ảnh sang không gian đồ thị, cho phép mạng học các đặc trưng từ các nút và cạnh trong đồ thị. Quá trình học của GCN bao gồm việc thu thập thông tin từ các nút lân cận, tổng hợp thông tin này và cập nhật đặc trưng của mỗi nút dựa trên thông tin từ các nút xung quanh.

GCN sử dụng ma trận kề của đồ thị để xác định mối quan hệ giữa các nút và áp dụng các phép tích chập để tổng hợp thông tin từ các nút liên kết. Mỗi lớp trong GCN cập nhật đặc trưng của nút bằng cách sử dụng các trọng số học được và thông tin từ các nút kết nối. Điều này giúp mạng có thể học được các mẫu và mối quan hệ phức tạp trong dữ liệu đồ thị, từ đó cải thiện hiệu suất trong các tác vụ như phân loại nút, dự đoán liên kết và phân loại đồ thị.

Trong nghiên cứu này, chúng tôi sử dụng kiến trúc GCN (Hình 2) được đề cập trong nghiên cứu của Bruna và các cộng sự [15]. Mô hình GCN 2 lớp có thể được biểu diễn dưới dạng:

$$Z = f(X, A) = \sigma(\hat{A}ReLU(\hat{A}XW_0)W_1) \quad (6)$$

Trong đó: X đại diện cho ma trận đặc trưng, A đại diện cho ma trận kề, \hat{A} biểu thị cho bước tiền xử lí, Z là ma trận trọng số từ ẩn đến đầu ra, W_0 và W_1 đại diện cho ma trận trọng số ở lớp thứ nhất và lớp thứ hai, và $\sigma(\cdot)$, $Relu()$ đại diện cho hàm kích hoạt.



Hình 2. Mạng đồ thị tích chập [16].

2.3. Mô hình mạng đề xuất GCN – LSTM

Trong bài báo này, mục tiêu của việc khôi phục dữ liệu là dự đoán giá trị gia tốc trong một khoảng thời gian nhất định dựa trên về giá trị gia tốc lịch sử đo đạc.

Định nghĩa 1: Mạng lưới cảm biến G . Chúng tôi sử dụng mạng không trọng số đồ thị $G = (V, E)$ để mô tả cấu trúc đồ thị của mạng lưới cảm biến và chúng tôi coi mỗi cảm biến là một nút. Trong đó: V là tập hợp các nút, $V = \{v_1, v_2, \dots, v_N\}$, N là số nút hay là số cảm biến và E là tập hợp các cạnh. Sự liên kết ma trận A được dùng để thể hiện sự kết nối giữa các cảm biến, $A \in R^{N \times N}$. Ma trận kề chỉ chứa các phân tử của 0 và 1. Phần tử là 0 nếu không có liên kết giữa các cảm biến và 1 biểu thị có một liên kết.

Định nghĩa 2: Ma trận đặc trưng $X^{N \times P}$. Chúng tôi coi dữ liệu cảm biến gia tốc là đặc điểm thuộc tính của nút trong mạng, được biểu thị bằng $X \in R^{N \times P}$. Trong đó: P đại diện cho số lượng thuộc tính nút (độ dài của chuỗi thời gian lịch sử) và $X_t \in R^{N \times i}$ được sử dụng để biểu thị gia tốc tại mỗi cảm biến tại thời điểm thứ i . Vì vậy, vấn đề khôi phục dữ liệu theo không gian-thời gian có thể được coi là học hàm ánh xạ f trên tiền đề của cấu trúc liên kết mạng lưới cảm biến G và ma trận đặc trưng X rồi tính toán thông tin các cảm biến trong T như thể hiện trong phương trình:

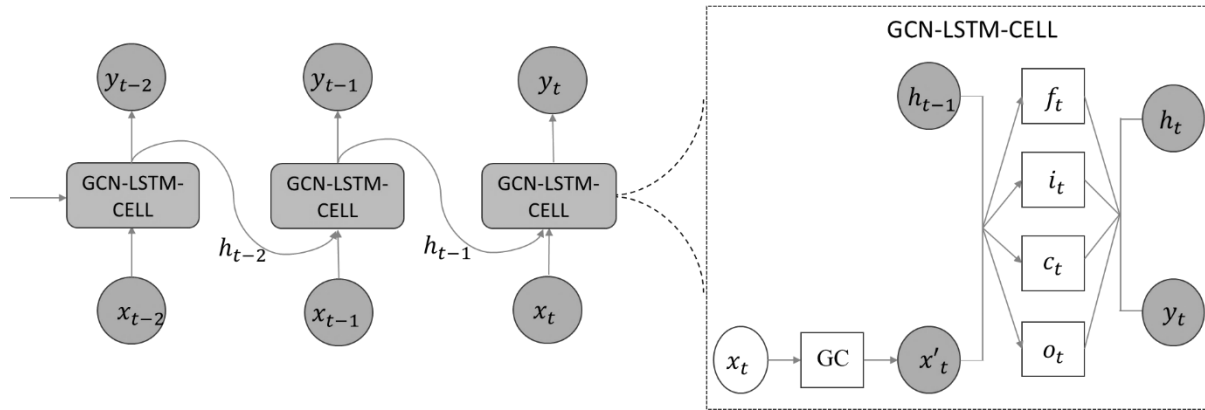
$$[X_{t+1}, \dots, X_{t+T}] = f(G; (X_{t-n}, \dots, X_{t-1}, X_t)) \tag{7}$$

Trong đó: n là độ dài của chuỗi thời gian lịch sử và T là độ dài của chuỗi thời gian cần dự đoán.

Đạt được sự phụ thuộc không gian phức tạp là một vấn đề chính của khôi phục dữ liệu. Mạng nơ-ron tích chập truyền thống CNN có thể thu được các đặc điểm không gian cục bộ, nhưng nó chỉ có thể được sử dụng trong không gian Euclide, chẳng hạn như hình ảnh, lưới thông thường, v.v.. Gần đây, việc khái quát hóa CNN thành mạng tích chập đồ thị GCN, có thể xử lý dữ liệu có cấu trúc đồ thị tùy ý, đã nhận được sự chú ý rộng rãi. Tìm hiểu sự phụ thuộc theo thời gian là một vấn đề quan trọng khác trong khôi phục dữ liệu. Hiện nay, mô hình mạng nơ-ron được sử dụng rộng rãi nhất để xử lý dữ liệu chuỗi là mạng nơ-ron hồi quy RNN. Tuy nhiên, do các khiếm khuyết như biến mất độ dốc và bùng nổ độ dốc, mạng nơ-ron hồi quy

truyền thống có những hạn chế trong việc dự đoán dài hạn. Mô hình LSTM là biến thể của mạng nơ-ron hồi quy và đã được chứng minh là có thể giải quyết các vấn đề trên.

Nghiên cứu này đề xuất một phương pháp kết hợp sử dụng cả GCN và LSTM. Việc kết hợp này khai thác điểm mạnh của từng phương pháp, tạo ra một hệ thống có khả năng hiểu sâu sắc hơn về các mối quan hệ không gian và thời gian trong dữ liệu, từ đó nâng cao hiệu quả và độ chính xác trong giám sát và dự đoán sự cố trong kết cấu công trình. Kiến trúc mạng GCN-LSTM đc miêu tả như Hình 3.



Hình 3. Kiến trúc của mô hình GCN-LSTM.

Như được hiển thị trong Hình 3, h_{t-1} biểu thị trạng thái ẩn tại thời điểm $t-1$; x_t biểu thị dữ liệu đầu vào tại thời điểm t ; f_t là cổng quên, được sử dụng để kiểm soát mức độ bỏ qua thông tin trạng thái tại thời điểm trước đó; i_t là cổng đầu vào, được sử dụng để kiểm soát mức độ đưa thông tin trạng thái tại thời điểm trước đó vào trạng thái hiện tại; c_t là nội dung bộ nhớ được lưu tại thời điểm t ; và h_t là trạng thái đầu ra tại thời điểm t .

Kiến trúc GCN-LSTM hoạt động như sau: các lớp tích chập đồ thị (Graph Convolution –GC) xử lý dữ liệu đầu vào x_t để trích xuất các đặc trưng không gian, sau đó đưa các đặc trưng này vào GCN-LSTM để xử lý thông tin theo chiều thời gian. Quá trình này cho phép mô hình không chỉ hiểu được các mối quan hệ không gian mà còn nắm bắt được sự thay đổi theo thời gian của dữ liệu.


Các tế bào GCN-LSTM liên kết với nhau, với mỗi tế bào xử lý trạng thái ẩn từ tế bào trước đó và đầu vào hiện tại để dự đoán trạng thái đầu ra y_t . Mô hình này có khả năng duy trì xu hướng thay đổi của dữ liệu lịch sử và nắm bắt sự phụ thuộc theo thời gian, giúp cải thiện độ chính xác trong dự đoán và phát hiện sự cố.

Mạng kết hợp GCN-LSTM có nhiều ưu điểm nổi bật nhờ vào sự phối hợp giữa hai mô hình là GCN và LSTM. Với LSTM nắm bắt ngữ cảnh thông qua việc ghi nhớ và xử lý các chuỗi thời gian dài hạn và phức tạp. Điều này giúp mô hình duy trì và sử dụng các thông tin quan trọng từ quá khứ để khôi phục dữ liệu bị mất mát. Còn GCN bổ sung vào khả năng này bằng cách trích xuất và hiểu các mối quan hệ không gian giữa các điểm dữ liệu cảm biến trong mạng đồ thị. Sự kết hợp của GCN cho phép mô hình nhận biết sự phụ thuộc không gian phức tạp giữa các nút cảm biến, trong khi LSTM đảm bảo rằng thông tin thời gian được duy trì và sử dụng hiệu quả. Nhờ sự phối hợp này, mô hình GCN-LSTM có khả năng xử lý dữ liệu phức tạp từ cả hai khía cạnh không gian và thời gian.


3. ÁP DỤNG

3.1. Giới thiệu mô hình

Để đánh giá hiệu quả của phương pháp đề xuất, nghiên cứu này xem xét một mô hình cầu dây văng trong phòng thí nghiệm A3-Lab-DX của Trường đại học Giao thông Vận tải. Mô hình cầu được chế tạo bằng thép, lấy cảm hứng từ các mô hình cầu dây văng trong thực tế nhưng được điều chỉnh để phù hợp với điều kiện phòng thí nghiệm. Mô hình có thiết kế mặt phẳng dây thẳng đứng theo tim cầu, tổng chiều dài 3,50m. Nhịp chính là dầm thép hình chữ nhật kích thước 3,50m x 0,12m x 0,005m. Trụ tháp cao 1,60m, gồm 2 thanh thép hình U65 hàn vào nhau tại đỉnh Hình 4. Một số bộ phận của cầu được thể hiện qua Hình 5, Hình 6 và Hình 7.



Hình 4. Cầu dây văng phòng thí nghiệm.



Hình 5. Neo dây cáp được hàn cố định trên bản mặt cầu.



Hình 6. Hệ thống điều chỉnh lực căng dây văng tại đỉnh tháp.




Hình 7. Vị trí gối cầu.


3.1.Thiết bị, sơ đồ đo và bộ dữ liệu thu thập

Thiết bị:

- Đầu đo để nhận dạng dao động được sử dụng là cảm biến của hãng PCB PIEZOTRONICS (Hình 8).
- Thiết bị thu nhận dữ liệu dao động là bộ NI cDAQ-9178 (NI-CompactDAQ) (Hình 9) của hãng National Instruments (Product of Hungary) trong đó có 2 Module NI9234 trên mỗi module có 4 cổng thu thập dữ liệu đo gia tốc từ 4 cảm biến.



Hình 8. Đầu đo nhận dạng dao động và cáp truyền tín hiệu.




Hình 9. Cáp truyền tín hiệu.



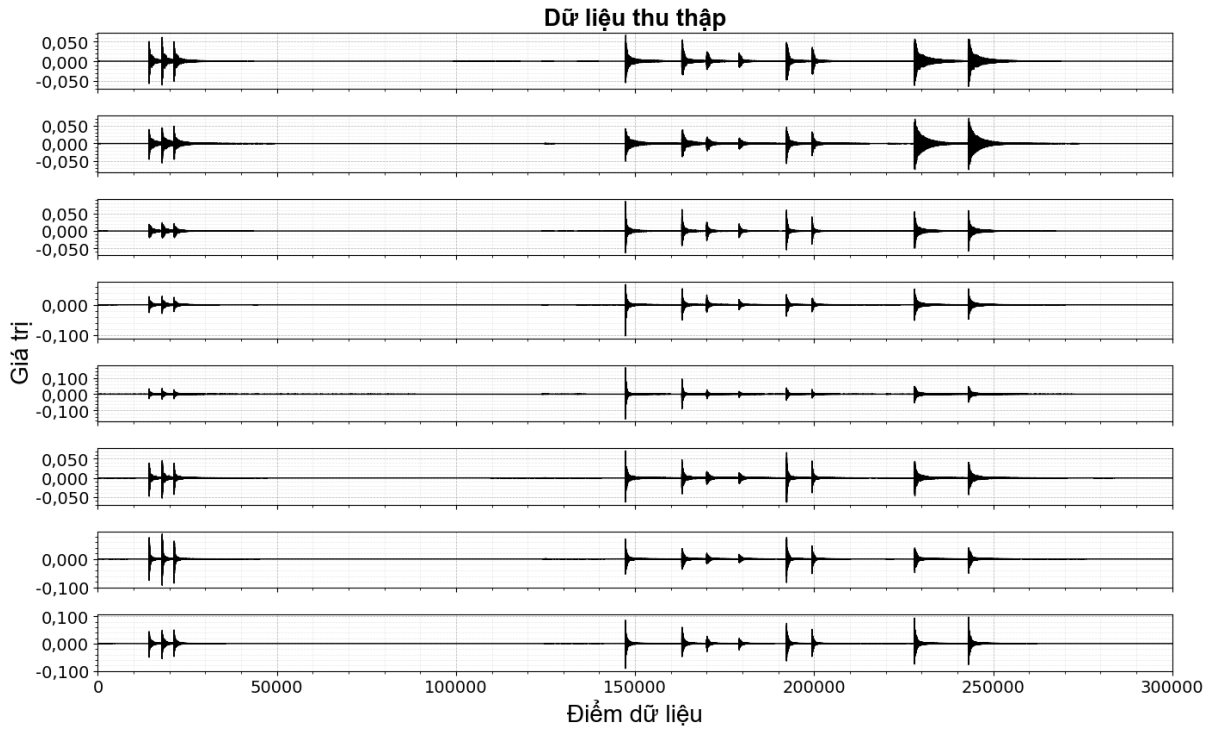
Hình 10. Quá trình thu thập dữ liệu.

Bố trí lắp đặt thiết bị được thể hiện ở Hình 10. Sơ đồ đo được thể hiện ở Hình 11




Hình 11. Sơ đồ bố trí điểm đo.

Bộ dữ liệu thu thập được gồm 100000 điểm dữ liệu với tần số lấy mẫu 100Hz thể hiện qua Hình 12. Từ trên xuống lần lượt là dữ liệu của các cảm biến từ 101 đến 204.



Hình 12. Bộ dữ liệu thu thập được từ mô hình cầu thí nghiệm.

Trích xuất 1700 điểm dữ liệu để tạo ra bộ dữ liệu cho bài toán khôi phục dữ liệu (Hình 13)



Hình 13. Bộ dữ liệu được trích xuất.

Bộ dữ liệu thu thập được sẽ được chia thành 2 tập gồm tập huấn luyện, tập kiểm tra với tỉ lệ 70:30. Tập kiểm tra được giả sử là vị trí dữ liệu bị mất mát. Mô hình sau khi được huấn luyện

sẽ được sử dụng để khôi phục dữ liệu bị mất trong tập kiểm tra. Sau đó kết quả dữ liệu khôi phục dữ liệu và dữ liệu ban đầu được trực quan hoá thông qua biểu đồ.

3.2. Kết quả đạt được

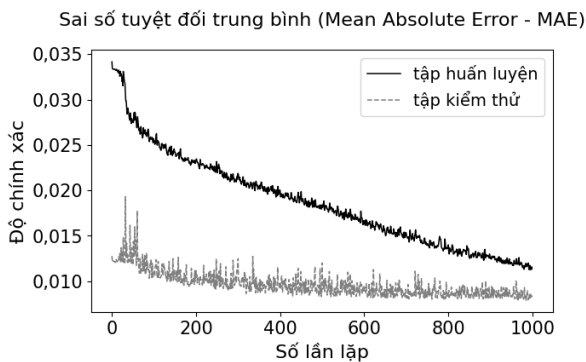
Để đánh giá hiệu suất dự đoán của mô hình GCN - LSTM, chúng tôi sử dụng 2 chỉ số để đánh giá sự khác biệt giữa dữ liệu thực tế Y_t , bao gồm:

(1) Sai số toàn phương trung bình (Mean Squared Error - MSE):

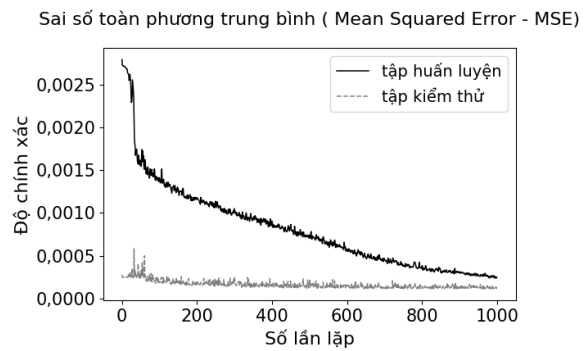
$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_t - \hat{Y}_t)^2 \quad (8)$$

(2) Sai số tuyệt đối trung bình (Mean Absolute Error - MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_t - \hat{Y}_t| \quad (9)$$





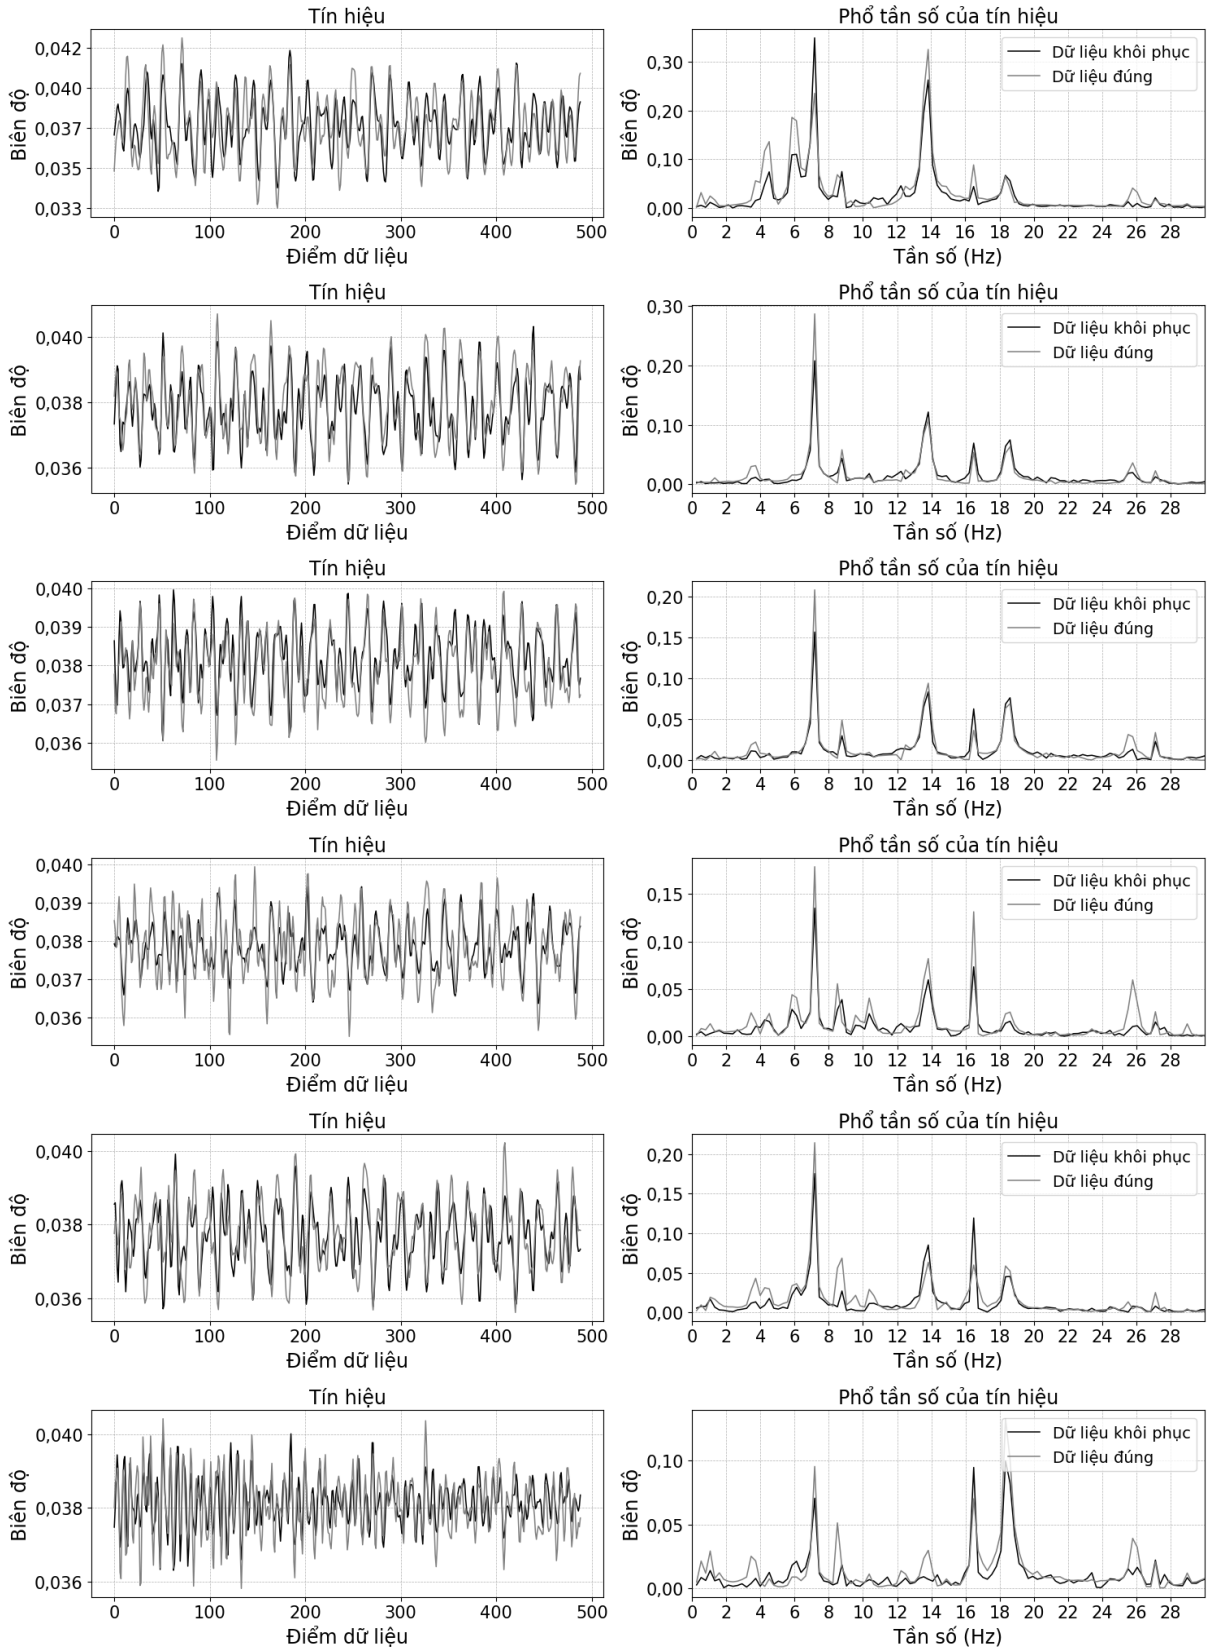
Hình 14. Sai số toàn phương trung bình trên tập huấn luyện và tập kiểm tra.




Hình 15. Sai số toàn tuyệt đối trung bình trên tập huấn luyện và tập kiểm tra.

Hai biểu đồ trên cho thấy hiệu suất dự đoán của mô hình GCN-LSTM thông qua các chỉ số MAE và MSE. Cả hai biểu đồ đều thể hiện rằng sai số trên tập huấn luyện (train) và tập kiểm định (validation) đều giảm dần theo số lần lặp. Cụ thể, đường cong sai số của tập huấn luyện bắt đầu từ khoảng 0,034 (MAE) và 0,0029 (MSE), sau đó giảm dần xuống khoảng 0,012 và 0,00035 sau 1000 lần lặp. đường cong sai số của tập đánh giá dao động nhiều hơn, nhưng cũng giảm từ khoảng 0,020 (MAE) và 0,0006 (MSE) xuống còn khoảng 0,007 và 0,0002 sau 1000 lần lặp. Điều này cho thấy mô hình GCN-LSTM có khả năng tổng quát hóa tốt và cải thiện hiệu suất dự đoán một cách hiệu quả sau mỗi lần mà không gặp phải vấn đề quá khớp (overfitting). Các chỉ số MAE và MSE đều cho thấy mô hình có khả năng dự đoán chính xác và cải thiện qua các lần lặp, thể hiện mô hình có hiệu suất tốt và đáng tin cậy.







Hình 16. So sánh kết quả dữ liệu khôi phục và dữ liệu gốc (từ trên xuống lần lượt là dữ liệu từ các cảm biến 101-204).

Hình 16 cho thấy các biểu đồ trên so sánh dữ liệu thực tế (đường màu xám) và dữ liệu dự đoán (đường màu đen) qua thời gian, thể hiện kết quả dự đoán của mô hình. Nhìn chung, các đường dữ liệu khôi phục rất gần với đường dữ liệu thực tế, cho thấy độ chính xác dự đoán cao của mô hình. Các xu hướng và biến động của hai chuỗi dữ liệu này khá tương đồng, với các đỉnh và đáy xuất hiện đồng thời, chứng tỏ mô hình có khả năng nắm bắt xu hướng của dữ liệu thực tế. Mặc dù có một số biến động nhỏ trong dữ liệu dự đoán, nhưng chúng không quá lớn và không ảnh hưởng nhiều đến độ chính xác tổng thể. Hơn nữa, các đường dữ liệu đều duy trì một mức độ ổn định nhất định qua thời gian, cho thấy mô hình duy trì hiệu suất dự đoán ổn định trong suốt thời gian dài. Ngoài ra, khi xem xét phổ tần số của dữ liệu, các kết quả cho thấy sự tương đồng cao giữa dữ liệu thực tế và dữ liệu dự đoán tại các tần số chính với tần số đầu tiên $f_1 \approx 7Hz$. Các đỉnh phổ của dữ liệu dự đoán hầu như trùng khớp với các đỉnh của dữ liệu thực tế, đặc biệt ở các tần số thấp, nơi mà các đặc tính cơ bản của kết cấu thường được thể hiện rõ ràng. Điều này chứng tỏ mô hình không chỉ có khả năng dự đoán giá trị thời gian mà còn nắm bắt tốt đặc tính tần số của tín hiệu. Tuy nhiên, cũng có một số khác biệt nhỏ về biên độ ở các tần số cao hơn, tuy nhiên khác biệt này có thể được cải thiện thông qua việc tối ưu hóa mô hình. Một lần nữa, thông qua các biểu đồ so sánh dữ liệu được khôi phục và dữ liệu thực tế có thể thấy mô hình dự đoán có hiệu suất tốt, khả năng nắm bắt xu hướng và biến động của dữ liệu thực tế, và duy trì độ chính xác cao qua thời gian.

4. KẾT LUẬN

Trong bài báo này chúng tôi đã đề xuất sử dụng một mô hình kết hợp giữa GCN và LSTM để khôi phục dữ liệu theo thời gian cho một mô hình cầu trong phòng thí nghiệm. GCN nắm bắt và trích xuất và hiểu các mối quan hệ không gian giữa các điểm dữ liệu cảm biến trong mạng đồ thị. LSTM nắm bắt ngữ cảnh thông qua việc ghi nhớ và xử lý các chuỗi thời gian dài hạn và phức tạp. Điều này giúp mô hình duy trì và sử dụng các thông tin quan trọng từ quá khứ để khôi phục dữ liệu bị mất mát. Mô hình cũng đã chứng minh được sự hiệu quả thông qua bộ dữ liệu thu thập được từ mô hình cầu trong phòng thí nghiệm. Biểu đồ sai số và biểu đồ kết quả so sánh dữ liệu gốc so với dữ liệu dự đoán đều cho thấy kết quả tốt chứng minh tính hiệu quả của mô hình GCN-LSTM trong việc khôi phục dữ liệu bị mất trong SHM. Nghiên cứu này mở ra hướng đi mới trong việc ứng dụng các kỹ thuật học sâu vào lĩnh vực SHM, đặc biệt là trong việc giải quyết các vấn đề liên quan đến mất dữ liệu tại Việt Nam. Khôi phục dữ liệu đóng vai trò quan trọng trong việc tối ưu hóa hiệu quả và độ chính xác của hệ thống SHM, góp phần đảm bảo sự an toàn và bền vững của các công trình hạ tầng.

LỜI CẢM ƠN

Nghiên cứu này được tài trợ bởi Bộ Giáo Dục và Đào Tạo trong đề tài mã số B2024-GHA-09.

TÀI LIỆU THAM KHẢO

- [1]. H. Tran-Ngoc, S. Khatir, T. Le-Xuan, G. De Roeck, T. Bui-Tien, M. Abdel Wahab, Finite element model updating of a multispan bridge with a hybrid metaheuristic search algorithm using experimental data from wireless triaxial sensors, *Eng. Comput*, (2021) 1–19. <https://doi.org/10.1007/s00366-021-01307-9>
- [2]. T. Bui Tien, T. Vu Quang, L. Nguyen Ngoc, H. Tran Ngoc, Time series data recovery in SHM of large-scale bridges: Leveraging GAN and Bi-LSTM networks, *Structures* 63 (2024). <https://doi.org/10.1016/j.istruc.2024.106368>
- [3]. H.M. Lee, J.M. Kim, K. Sho, H.S. Park, A wireless vibrating wire sensor node for continuous structural health monitoring, *Smart Mater. Struct*, 19 (2010). <https://doi.org/10.1088/0964-1726/19/5/055004>
- [4]. Y. Yu, F. Han, Y. Bao, J. Ou, A study on data loss compensation of WiFi-based wireless sensor networks for structural health monitoring, *IEEE Sens. J*, 16 (2015) 3811–3818. <https://doi.org/10.1109/JSEN.2015.2512846>
- [5]. S.M. O’Connor, J.P. Lynch, A.C. Gilbert, Compressed sensing embedded in an operational wireless sensor network to achieve energy efficiency in long-term monitoring applications, *Smart Mater. Struct*, 23 (2014). <https://doi.org/10.1088/0964-1726/23/8/085014>
- [6]. Z. Chen, H. Li, Y. Bao, Analyzing and modeling inter-sensor relationships for strain monitoring data and missing data imputation: a copula and functional data-analytic approach, *Struct. Health Monit.*, 18 (2019) 1168–1188. <https://doi.org/10.1177/1475921718788703>
- [7]. Y. Bao, Z. Tang, H. Li, Y. Zhang, Computer vision and deep learning–based data anomaly detection method for structural health monitoring, *Struct. Health Monit.*, 18 (2019) 401–421. <https://doi.org/10.1177/1475921718757405>
- [8]. B.K. Oh, B. Glisic, Y. Kim, H.S. Park, Convolutional neural network–based data recovery method for structural health monitoring, *Struct. Health Monit*, 19 (2020) 1821–1838. <https://doi.org/10.1177/1475921719897571>
- [9]. G. Fan, J. Li, H. Hao, Lost data recovery for structural health monitoring based on convolutional neural networks, *Struct. Control Health Monit*, 26 (2019). <https://doi.org/10.1002/stc.2433>
- [10]. X. Xu, X. Zhao, M. Wei, Z. Li, X. Xu, X. Zhao, M. Wei, Z. Li, A comprehensive review of graph convolutional networks: approaches and applications, *Electron. Res. Arch.*, 31 (2023) 4185–4215. <https://doi.org/10.3934/era.2023213>
- [11]. B. Yu, H. Yin, Z. Zhu, Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting, in: *Proc. Twenty-Seventh Int. Jt. Conf. Artif. Intell.*, (2018) 3634–3640. <https://doi.org/10.24963/ijcai.2018/50>
- [12]. L. Zhao, Y. Song, C. Zhang, Y. Liu, P. Wang, T. Lin, M. Deng, H. Li, T-gcn: A temporal graph convolutional network for traffic prediction, *IEEE Trans. Intell. Transp. Syst*, 21 (2019) 3848–3858. <https://doi.org/10.1109/TITS.2019.2935152>
- [13]. S. Sun, Z. Wang, Z. Xia, L. Yi, Z. Yue, Y. Ding, The Temperature-Induced Deflection Data Missing Recovery of a Cable-Stayed Bridge Based on Bayesian Robust Tensor Learning, *Symmetry*, 15 (2023). <https://doi.org/10.3390/sym15061234>
- [14]. S. Hochreiter, J. Schmidhuber, Long short-term memory, *Neural Comput*, 9 (1997) 1735–1780.
- [15]. J. Bruna, W. Zaremba, A. Szlam, Y. LeCun, Spectral Networks and Locally Connected Networks on Graphs, 2014. <http://arxiv.org/abs/1312.6203>
- [16]. T.N. Kipf, M. Welling, Semi-Supervised Classification with Graph Convolutional Networks, 2017. <http://arxiv.org/abs/1609.02907>