

Damage detection for cable-stayed bridge structure using hybrid deep learning network and time-series data obtained from fiber optic sensors

Hong Quan Pham^{1*}, Anh Duc Mai², Thanh Nguyen Chi³, Ngoc Bich Thi Nguyen¹

¹University of Transport Technology, 54 Trieu Khuc, Ha Noi, Viet Nam

²The University of Transportation and Communications, 3 Cau Giay, Ha Noi, Viet Nam

³The University of Transportation and Communications Limited Company, Hanoi, Vietnam

Article info

Type of article:

Original research paper

DOI:

<https://doi.org/10.58845/jstt.utt.2024.vn.4.2.30-39>

*Corresponding author:

E-mail address:

quanph22@utt.edu.vn

Received: 6/4/2024

Accepted: 22/5/2024

Published: 24/5/2024

Abstract: In Structural Health Monitoring (SHM), the use of time-series data obtained from sensors has garnered interest from the research community worldwide. With the advancement of sensor technologies, this data is becoming increasingly abundant and complex. However, traditional Machine Learning (ML) methods, such as Artificial Neural Networks, are no longer efficient enough to accurately process and diagnose structural damages based on time-dependent data. To address this issue, this study proposes a novel deep learning approach integrating a 1-dimensional Convolutional Neural Network (1DCNN) and Long Short-Term Memory (LSTM) network to enhance the effectiveness of structural damage detection based on time-series data collected from fiber optic sensors. The efficacy of the proposed method is assessed through a dataset from a cable-stayed bridge in a laboratory setting, constructed at the University of Transportation. Accordingly, the results have demonstrated that the proposed method significantly outperforms traditional deep learning approaches, with accuracy rates on the validation and test sets of 77.5% and 74.1%, respectively.

Keywords: Long short-term memory; 1D Convolutional Neural Network; Time-series data; Damage detection; fiber optic sensors; Deep Learning.

Nghiên cứu chẩn đoán hư hỏng cho kết cấu cầu dây sử dụng mạng học sâu tiên tiến cho dữ liệu thu được từ cảm biến quang

Phạm Hồng Quân^{1*}, Mai Anh Đức², Nguyễn Chí Thanh³, Nguyễn Thị Ngọc Bích³

¹Trường Đại học Công nghệ Giao thông vận tải, 54 Triều Khúc, Hà Nội, Việt Nam

² Trường Đại học Giao thông vận tải, 3 Cầu Giấy, Hà Nội, Việt Nam

³Phòng Chuyển đổi số, Công ty TNHH Giao thông vận tải, Hà Nội, Việt Nam

Thông tin bài viết

Dạng bài viết:

Bài báo nghiên cứu

DOI:

<https://doi.org/10.58845/jstt.utt.2024.vn.4.2.30-39>

*Tác giả liên hệ:

Địa chỉ E-mail:

quanph22@utt.edu.vn

Ngày nộp bài: 6/4/2024

Ngày chấp nhận: 22/5/2024

Ngày đăng bài: 24/5/2024

Tóm tắt: Trong Giám sát sức khỏe kết cấu (Structural Health Monitoring - SHM), việc sử dụng dữ liệu dạng chuỗi thời gian thu được từ các cảm biến được sự quan tâm của cộng đồng nghiên cứu trên thế giới. Với sự phát triển của các công nghệ cảm biến, các dữ liệu này ngày càng nhiều và phức tạp. Tuy nhiên, các phương pháp Học máy (Machine learning - ML) truyền thống, chẳng hạn như Mạng thần kinh nhân tạo, không còn đủ hiệu quả để xử lý và chẩn đoán chính xác các hư hỏng cấu trúc dựa trên dữ liệu phụ thuộc vào thời gian. Để giải quyết vấn đề này, nghiên cứu này đề xuất một phương pháp học sâu mới tích hợp mạng thần kinh tích chập 1 chiều (1D Convolutional Neural Network-1DCNN) và mạng bộ nhớ ngắn hạn dài (Long Short-Term Memory - LSTM) để nâng cao hiệu quả phát hiện hư hỏng kết cấu dựa trên dữ liệu dạng chuỗi thời gian được thu thập từ cảm biến quang. Hiệu quả của phương pháp đề xuất được đánh giá thông qua bộ dữ liệu cầu dây văng trong phòng thí nghiệm, được xây dựng tại Trường Đại học Giao thông Vận tải. Theo đó, kết quả đã chứng minh thấy phương pháp đề xuất hoàn toàn vượt trội so với phương pháp học sâu truyền thống với kết quả lần lượt trên tập kiểm thử và kiểm tra là 77.5 và 74.1%.

Từ khóa: Mạng bộ nhớ ngắn hạn; Mạng thần kinh tích chập 1 chiều; Dữ liệu theo thời gian; Chẩn đoán hư hỏng; Cảm biến sợi quang; Mạng học sâu.

1. Giới thiệu

Trong kỷ nguyên 4.0, sự phát triển của các công nghệ cảm biến đã cho phép thu thập một lượng lớn dữ liệu dạng chuỗi thời gian từ kết cấu, đặc biệt là các cảm biến sợi quang (Fiber Bragg Grating - FBG), loại cảm biến này đã trải qua sự phát triển nhanh chóng trong những năm gần đây sau khi quan sát thấy sự phản xạ dải rất hẹp trong vùng lõi nhạy sáng của sợi quang silica pha tạp Ge [1]. Việc thành công chế tạo FBG trên lõi sợi quang bằng cách tiếp xúc với mẫu giao thoa UV hai chùm

tia vào năm 1989 [2] đã mở ra cánh cửa cho ứng dụng rộng rãi của chúng. FBG có nhiều ưu điểm, bao gồm khả năng miễn nhiễm với nhiễu điện từ (EMI) trên mặt đất, cũng như khối lượng nhẹ và kích thước vật lý nhỏ, thích hợp để nhúng hoặc gắn vào các kết cấu. Cảm biến FBG cũng không đòi hỏi dây kết nối đến hệ thống điều khiển vì chúng đồng thời là bộ phận cảm biến và ống dẫn tín hiệu. Điều này giúp giảm thiểu rủi ro và chi phí liên quan đến việc kết nối và lắp đặt. Khác biệt rõ rệt của FBG so với các công nghệ cảm biến khác là khả năng cung

cấp thông tin về bước sóng, một tham số tuyệt đối, từ đó tạo ra một sơ đồ đo lường tuyệt đối, tự tham chiếu. Cảm biến quang đã chứng minh được tính ưu việt của nó so với các cảm biến truyền thống khác trong lĩnh vực SHM [3],[4]. Cảm biến FBG có độ nhạy cao từ đó dễ dàng nắm bắt các dao động dù là rất nhỏ trong kết cấu. Do đó, dữ liệu thu được từ cảm biến quang trở nên chính xác và hiệu quả hơn so với các cảm biến thông thường. Để xử lý các dữ liệu thu thập được từ cảm biến này, các nghiên cứu ứng dụng học máy (Machine Learning - ML) đã được phát triển và chứng minh trong nhiều nghiên cứu [5],[6],[7],[8]. Tuy nhiên, ML điển hình là mạng nơ ron nhân tạo chỉ xử lý được dữ liệu với kích thước nhỏ, không phù hợp cho các dữ liệu lớn. Chính vì vậy, mô hình học sâu được phát triển và thay thế cho ML để xử lý vấn đề này.

Mạng học sâu thông qua việc sử dụng các mô hình mạng lưới thần kinh nhiều lớp, không chỉ giúp phát hiện các mẫu trong bộ dữ liệu lớn mà còn sở hữu khả năng tự động trích xuất các tính năng từ dữ liệu đầu vào mà không cần sự can thiệp của con người. Điều này tối ưu hóa việc xác định các điểm bất thường trong dữ liệu chuỗi thời gian của SHM, từ đó chẩn đoán hư hỏng trở nên nhanh hơn và chính xác hơn. Các mô hình học sâu nổi bật để xử lý dữ liệu chuỗi thời gian nhằm phát hiện hư hỏng bao gồm 1DCNN và LSTM. Cụ thể, 1DCNN là một kiến trúc mạng nơ-ron được thiết kế đặc biệt cho việc trích xuất đặc trưng từ dữ liệu chuỗi thông qua các tầng tích chập. 1DCNN có khả năng tự động học và phát hiện các đặc trưng cục bộ và toàn cục từ dữ liệu chuỗi, giúp mô hình hiểu rõ hơn về cấu trúc và đặc điểm của dữ liệu, từ đó cải thiện khả năng dự đoán và phân loại. Những ví dụ đáng chú ý bao gồm, Youqi Zhang và cộng sự [9] Nghiên cứu này đề xuất một 1DCNN đơn giản giúp phát hiện những thay đổi cục bộ nhỏ về độ cứng và khối lượng cấu kiện, đồng thời kiểm chứng hiệu quả của nó trên các cấu trúc thực tế thông qua việc áp dụng dữ liệu gia tốc thô mà không yêu cầu bất kỳ quy trình xử lý trước nào. Mô hình CNN được đề xuất đã thể hiện khả năng phản ứng cao đối với

những thay đổi nhỏ về trọng lượng và độ cứng trong các kết cấu thép thực tế qua ba bộ dữ liệu khác nhau. Osama Abdeljaber và cộng sự [10] đề xuất mô hình Mạng CNN đồng thời tối ưu hóa việc trích xuất và phân loại tính năng, nâng cao hiệu quả và khả năng tổng quát hóa để phát hiện hư hỏng dựa trên dao động. 1DCNN được áp dụng để ước tính chính xác hư hỏng chỉ từ hai bộ đo lường trên kết cấu chuẩn, khắc phục các hạn chế về dữ liệu và chứng minh khả năng học hỏi hiệu quả từ dữ liệu dao động thô.

LSTM, một dạng Mạng thần kinh hồi quy (RNN) chuyên biệt, được thiết kế để ghi nhớ và xử lý thông tin trong khoảng thời gian dài [11]. Với khả năng ghi nhớ thông tin trong quá khứ và truyền thông tin qua các thời điểm, LSTM rất hiệu quả trong việc nhận biết các mẫu dữ liệu có tính tuần tự và phụ thuộc vào ngữ cảnh, giúp mô hình có khả năng dự đoán và phát hiện các xu hướng và biến đổi dài hạn từ dữ liệu chuỗi. Ví dụ, Sharma và Sen [12] đề xuất một cách tiếp cận thời gian thực dựa trên LSTM bằng cách sử dụng các mạng phân loại được giám sát và dự đoán không giám sát để cho phép phát hiện và định vị kịp thời dưới các biến đổi nhiệt. Đã được thử nghiệm trên một cây cầu thực, phương pháp này đưa ra các cảnh báo bất thường nhanh chóng trong các điều kiện vận hành một cách đáng tin cậy, khắc phục những hạn chế của các kỹ thuật truyền thống. Việc theo dõi tình trạng hệ thống treo ô tô là rất quan trọng nhưng đầy thách thức do động lực học phi tuyến tính và thiếu kiến thức chuyên môn về dữ liệu cảm quan, từ thách thức đó Haoju Hu và cộng sự [13] đã phát triển hệ thống dựa trên mạng LSTM sử dụng dữ liệu cảm biến chuỗi thời gian để ước tính tải trọng hệ thống treo và tuổi thọ còn lại mà không cần biết trước.

LSTM được phát triển với mục đích bổ sung thêm vấn đề mất thông tin theo chuỗi dài. Đặc điểm nổi bật của LSTM là khả năng lưu giữ thông tin trong thời gian dài mà không cần củng cố thêm trong quá trình đào tạo. Theo thiết kế, nó vốn đã lưu giữ những thông tin quan trọng mà không cần

sự can thiệp từ bên ngoài. Tuy nhiên, một thách thức nảy sinh khi dữ liệu tuần tự không chỉ phụ thuộc vào thời gian mà còn phụ thuộc vào không gian, một tình huống hiển nhiên trong các tình huống SHM trong đó dữ liệu từ các cảm biến được kết nối với nhau có liên quan. LSTM chủ yếu vượt trội với dữ liệu theo thời gian. Do đó, nghiên cứu này đề xuất sự kết hợp giữa 1DCNN và LSTM. Trong khi 1DCNN lọc và kết nối thông tin không gian từ dữ liệu, đồng thời LSTM tối ưu hóa việc học dữ liệu tuần tự. Sự kết hợp của 1DCNN, trích xuất các mẫu và mối quan hệ cục bộ, sự hiệu quả của LSTM trong việc học dữ liệu tuần tự tạo ra một kiến trúc mạnh mẽ, tối ưu để phân tích và phân loại dữ liệu chuỗi thời gian phức tạp. Trong nghiên cứu này, các mạng học sâu được sử dụng để chẩn đoán các trạng thái làm việc của kết cấu, bằng cách thay đổi tải trọng tại một số vị trí trên cầu, tương ứng với việc thay đổi ma trận khối lượng, từ đó sẽ thay đổi ứng xử động của kết cấu. Các cảm biến quang được sử dụng ở đây để thu thập các dữ liệu theo thời gian, các dữ liệu này sẽ khác nhau ứng với các ứng xử động khác nhau của kết cấu, sau đó sử dụng các dữ liệu này để huấn luyện mạng.

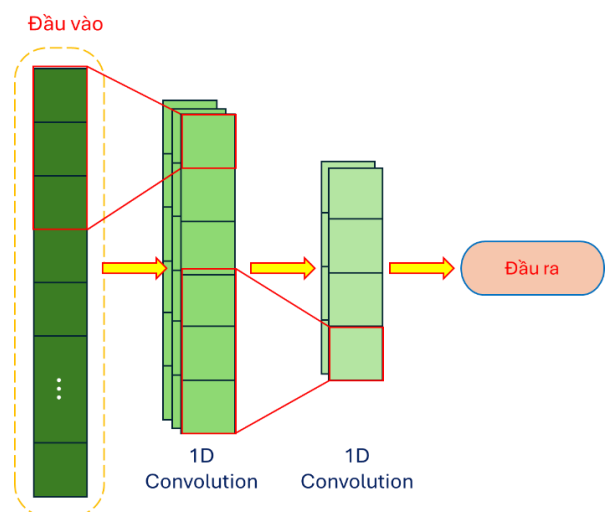
Bài báo này được cấu trúc thành ba phần chính. Phần 2 về các phương pháp ứng dụng trong nghiên cứu này bao gồm 1DCNN, LSTM và Phương pháp được đề xuất 1DCNN-LSTM. Hiệu quả của phương pháp đề xuất được đánh giá bằng cách sử dụng dữ liệu thu thập được từ cảm biến quang áp dụng cho mô hình phòng thí nghiệm cầu dây văng của trường Đại học Giao thông vận tải. Phần 3 mô tả chi tiết thí nghiệm thu thập dữ liệu bằng cảm biến cáp quang và bộ dữ liệu đó. Phần 4 là kết quả ứng dụng phương pháp đề xuất cho bộ dữ liệu. Cuối cùng, bài viết kết thúc với phần tóm tắt những phát hiện chính.

2. Phương pháp

2.1. Mạng tích chập một chiều (1DCNN)

1DCNN đã được công nhận trong lĩnh vực học sâu, đặc biệt là về khả năng xử lý dữ liệu tuần tự và chuỗi thời gian hiệu quả. Không giống như

2DCNN, 1DCNN tập trung vào một chiều duy nhất, từ đó giúp chúng tăng khả năng nắm bắt các mẫu thời gian theo trình tự. Về cơ bản bắt nguồn từ cơ chế tích chập, 1DCNN trượt bộ lọc (còn gọi là “kernel”) theo chiều thời gian của chuỗi đầu vào (Hình 1). Hành động này dẫn đến các bản đồ đặc trưng thể hiện các biểu diễn trừu tượng và sắc thái của đầu vào khi độ sâu của mạng tăng lên. Bằng cách nhấn mạnh các tập hợp con dữ liệu cục bộ, 1DCNN, thông qua các trường tiếp nhận hạn chế của chúng, mang lại độ chính xác. Hơn nữa, cấu trúc sử dụng trọng số chia sẻ trong quá trình tích chập bảo đảm khả năng nhận dạng các mẫu ở mọi vị trí trong chuỗi, qua đó cung cấp tính năng bất biến về vị trí. Hơn nữa, các lớp tổng hợp chung cho 2DCNN cũng có liên quan trong 1DCNN, giúp giảm trình tự mẫu và nhấn mạnh các tính năng nổi bật. Tuy nhiên, giống như bất kỳ mô hình nào, 1DCNN có những thách thức riêng. Mặc dù chúng có thể xác định các mẫu cục bộ một cách hiệu quả, nhưng việc nắm bắt các phần phụ thuộc dài hơn hoặc bối cảnh toàn cầu theo trình tự có thể không tối ưu, đặc biệt là khi kích thước hạt nhân không đủ lớn. Điều này khiến chúng kém lý tưởng hơn cho các nhiệm vụ trong đó sự phụ thuộc lâu dài là rất quan trọng, một thách thức mà các kiến trúc định kỳ như LSTM được thiết kế để giải quyết. Ngoài ra, 1DCNN nếu không được thiết kế hoặc điều chỉnh cẩn thận có thể dễ bị trang bị quá mức, đặc biệt khi dữ liệu huấn luyện còn rời rạc.



Hình 1. Mô hình 1DCNN đơn giản

2.2. Mạng bộ nhớ ngắn dài hạn (LSTM)

Ý tưởng thiết kế chính của LSTM nhằm đối phó với vấn đề gradient biến mất và bùng nổ, những thách thức thường gặp trong các mạng RNN truyền thống [14], LSTM đã được Hochreiter và Schmidhuber giới thiệu vào năm 1997 như một sự cải tiến so với Mạng thần kinh hồi quy truyền thống (RNN) để nắm bắt sự phụ thuộc lâu dài [15].


Trọng tâm của kiến trúc LSTM là “ô trạng thái” của nó, được bổ sung bởi ba cổng: cổng đầu vào (in_t), cổng quên (g_t) và cổng đầu ra (out_t). Các cổng này được biểu diễn về mặt toán học như sau.

$$in_t = \sigma(M_{ij}x_t + \omega_{ij} + M_{hi}h_{t-1} + \omega_{hi}) \tag{1}$$

$$g_t = \sigma(M_{if}x_t + \omega_{if} + M_{hf}h_{t-1} + \omega_{hf}) \tag{2}$$

$$out_t = \sigma(M_{io}x_t + \omega_{io} + M_{ho}h_{t-1} + \omega_{ho}) \tag{3}$$

Trong đó M đại diện cho ma trận trọng số, x_t là đầu vào, h_{t-1} là trạng thái ẩn trước đó và ω là độ lệch. σ đại diện cho hàm kích hoạt “sigmoid”. Sơ đồ minh họa (Hình 2) có thể cung cấp cái nhìn trực quan hơn về phương thức hoạt động của LSTM.




Hình 2. Cấu trúc điển hình của tế bào LSTM

Mặc dù có khả năng tuyệt vời nhưng mạng LSTM không tránh khỏi những hạn chế. Điều đáng chú ý là chúng thường yêu cầu thời gian đào tạo dài hơn do tính chất thường xuyên của chúng. Kiến trúc phức tạp, trong khi cho phép các biểu diễn phức tạp, đôi khi có thể dẫn đến tình trạng khớp quá mức (overfitting), đặc biệt là khi dữ liệu khan hiếm [16]. Hơn nữa, tính chất tính toán tuần tự của chúng đặt ra những thách thức trong việc song song hóa, điều này có thể cản trở hiệu suất tối ưu trên GPU. Ngoài ra, trong khi LSTM thực sự đã giảm thiểu vấn đề biến mất độ dốc một cách thành

thạo hơn RNN, một số điều kiện nhất định vẫn có thể gây ra bão hòa độ dốc [17].

2.3. Phương pháp đề xuất 1DCNN-LSTM

Trong nghiên cứu này, chúng tôi đề xuất một phương pháp tiếp cận sáng tạo kết hợp giữa 1DCNN và LSTM. Về bản chất, mỗi mạng này đều có những thế mạnh riêng. Tuy nhiên, bằng cách kết hợp các khả năng của chúng, mô hình không chỉ đơn thuần là tổng hợp các phương pháp mà còn là một mạng thống nhất có khả năng giải quyết các thách thức mà mỗi mạng truyền thống gặp phải khi hoạt động độc lập. Kiến trúc mạng của 1DCNN-LSTM được minh họa trong Hình 3.



Hình 3. Kiến trúc mạng 1DCNN-LSTM

Đầu tiên, mô hình bắt đầu với tensor đầu vào $O \in \mathbb{R}^{N \times F \times T}$, với N là số lượng mẫu, F là số lượng thiết lập và T là dữ liệu chuỗi thời gian. Bằng cách chuyển tensor đầu vào qua lớp tích chập ban đầu, lớp này sẽ trích xuất các tính năng ban đầu từ đầu vào và chuẩn bị cho quá trình xử lý sâu hơn.

$$O_{conv 1} = L(BN(M_{conv 1} * O + \omega_{conv 1})) \tag{4}$$

Trong đó L là hàm kích hoạt ReLU, BN biểu thị lớp chuẩn hoá Batch Normalization, $M_{conv 1}$ là ma trận trọng số của lớp chập và $\omega_{conv 1}$ là độ lệch tương ứng.

Sau đó, tensor được hợp nhất sẽ được xử lý thông qua lớp LSTM. LSTM lấy dữ liệu trình tự và nắm bắt các phụ thuộc theo thời gian. LSTM tính toán trạng thái ẩn λ_t và trạng thái ô C_t bằng cách sử dụng các cổng và tương tác như chi tiết của LSTM trong các phương trình (1)-(3). Trong phương pháp đề xuất này, việc xây dựng hàm có thể trình bày như sau:

$$\lambda_t = LSTM(O_{conv 1}) \tag{5}$$

Cuối cùng, các lớp sử dụng hàm kích hoạt Softmax và Sigmoid tạo ra những dự đoán cuối cùng:

$$O_d = \sigma(M_{d1} \cdot \lambda_t + b_{d1}) \tag{6}$$

$$O_{out} = \text{Softmax}(M_{d2} \cdot O_d + b_{d2}) \quad (7)$$

Trong đó M_{d1}, M_{d2} là ma trận trọng số của các lớp dày đặc. ω_{d1}, ω_{d2} là các độ lệch tương ứng.


3. Thí nghiệm và bộ dữ liệu

3.1. Mô hình thí nghiệm

Để đánh giá hiệu quả của phương đề xuất, một mô hình cầu dây văng được thiết kế và xây dựng tại phòng thí nghiệm tại nhà A3 của Trường đại học Giao thông Vận tải. Cáp quang được sử dụng của hãng FBGS với tên DTG@-LB150-FG, với dải đo từ 1530nm đến 1566nm Hình 4a, cáp được gắn cố định vào kết cấu bởi bộ kẹp Hình 4b.



(a)



(b)

Hình 4. Cảm biến quang và kẹp cảm biến quang

Mô hình cầu dây văng trong phòng thí nghiệm được xây dựng tham khảo các mô hình thí nghiệm trong phòng cho bài toán dao động [18], [19] cũng như dựa trên mô hình số được mô phỏng trên các chương trình phần tử hữu hạn. Cầu có sơ đồ một mặt phẳng dây, dây là kết cấu chịu lực chính từ đó có thể xây dựng thí nghiệm trên cầu

mô hình. Mô hình được làm bằng vật liệu thép, có tổng chiều dài 3,50 m, với nhịp chính là dầm thép hình chữ nhật có kích thước 3,50m x 0,12m x 0.005m. Trụ tháp của mô hình có tổng chiều cao 1,60 m, gồm 2 thanh thép hình U65 được hàn với nhau tại đỉnh trụ. Trụ tháp được neo vào mặt sàn bê tông bằng 08 bu lông neo cường độ cao có đường kính 0.01 m giúp hạn chế rung cho trụ trong các thí nghiệm dao động trên mô hình cầu. Tại hai phía đầu cầu, dầm được đỡ bằng gối lò xo và được cố định xuống nền bê tông bằng 04 bu lông neo cường độ cao có đường kính 0.01 m. Hình ảnh cầu thí nghiệm được minh họa trong Hình 5.



Hình 5. Mô hình cầu dây văng

Cảm biến quang FBG được bố trí theo dọc dầm của cầu với 14 cảm biến cách đều nhau 25cm (Hình 4a). Gắn các cảm biến với kết cấu thông qua các bộ kẹp.

3.2. Bộ dữ liệu

Một loạt các kịch bản về các tình huống hư hỏng trong kết cấu được thiết lập và đo đạc. Các hư hỏng được thực hiện bằng cách đặt tải trọng tập trung tại những vị trí được coi là hư hỏng trong kết cấu. Mục đích của việc đặt các tải trọng tập trung là thay đổi ma trận khối lượng, từ đó thay đổi ứng xử động của kết cấu. Sau đó các thuật toán sẽ được sử dụng để xác định các thay đổi này.


Các trường hợp hư hỏng được tổng hợp trong Bảng 1, ví dụ bố trí trường hợp hư hỏng số 2 mô tả trong Hình 6 và dữ liệu gia tốc theo thời gian thu được sau xử lý và tăng cường cho 1 thiết lập. Cầu được thiết lập với 6 trường hợp hư hỏng, và được bố trí 14 cách tử, mỗi cách tử đóng vai trò

thu thập dữ liệu như một cảm biến, tổng số điểm dữ liệu đo được cho mỗi trường hợp là 10000 điểm. Như vậy, bộ dữ liệu gốc thu thập được có kích thước là (6,14,10000).

Sau đó để gia tăng dữ liệu cho mạng học sâu học tập, một loạt những kỹ thuật như thêm nhiễu, trượt, cắt, co, kéo giãn dữ liệu được áp dụng để tăng cường dữ liệu. Trong bài báo này, các phương pháp tăng cường dữ liệu như (thêm nhiễu, trượt, cắt, co, kéo giãn dữ liệu) được áp dụng để cải thiện số lượng dữ liệu. Trong thực tế, trong quá trình đo đạc, số lượng dữ liệu thu được có thể bị hạn chế vì vậy khi sử dụng cho bài toán đánh giá hư hỏng của kết cấu, độ chính xác sẽ bị ảnh hưởng. Vì vậy các phương pháp này có hiệu quả thiết thực để cải thiện các dữ liệu thu được từ thực tế. Bộ dữ liệu cuối cùng được dùng cho mạng có kích thước (5500,14,1000). Tiếp theo bộ dữ liệu này sẽ được chia thành 3 tập, tập huấn luyện với 60%, tập kiểm thử 20% và tập kiểm tra chiếm 20%.

Bảng 1. Khối lượng (kg) tương ứng với 06 vị trí trong từng trường hợp

TH	Vị trí					
	01	02	03	04	05	06
01	10	10	10	10	10	10
02	20	10	10	10	10	10
03	10	30	10	10	10	10
04	20	10	20	10	20	10
05	20	10	20	10	10	10
06	10	20	10	10	20	20



Hình 6. Trường hợp hư hỏng trên mô hình cầu dây văng (trường hợp 02)

4. Kết quả và thảo luận

Để xác thực tính hiệu quả của mạng học sâu

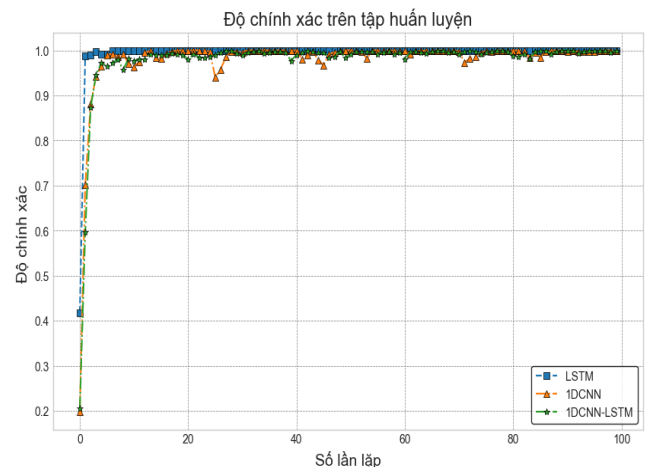
đề xuất 1DCNN-LSTM, mạng RNN và 1DCNN truyền thống được dùng để so sánh. Đầu tiên, kết quả định tính của cả hai mạng sẽ được ghi lại bằng biểu đồ hội tụ trong Hình 7. Theo đó có thể dễ dàng nhận thấy rằng biểu thuật toán đề xuất đã hoàn toàn vượt trội so với các thuật toán truyền thống khi độ chính xác của thuật toán đạt vị trí cao nhất, tách biệt so với thuật toán 1DCNN và LSTM. Ngoài ra, biểu đồ còn cho thấy sự ổn định của thuật toán khi liên tục thay đổi độ dốc để tìm được giá trị tối ưu mới tốt hơn giá trị trước đó.

Kết quả đã cho thấy sự vượt trội của mạng học sâu đề xuất cho với mạng truyền thống về mặt định tính. Dẫu vậy, vẫn chưa thể khẳng định mạng có thực sự phân biệt và tìm ra được hư hỏng hay không. Vì vậy, kết quả định lượng cần được tiến hành. Theo đó trong nghiên cứu này, độ chính xác được tính toán dựa trên công thức sau:

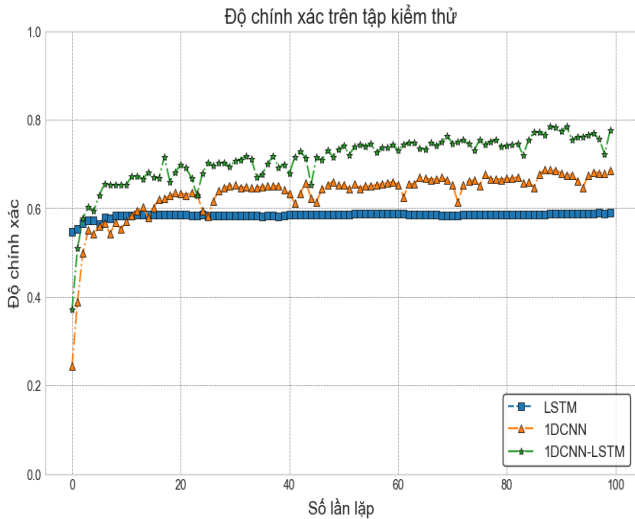
$$f1score = \frac{2 * Recall * Precision}{Recall + Precision} \tag{8}$$

Trong đó $recall = \frac{TP}{TP + FN}$ và $Precision = \frac{TP}{TP + FP}$

Kết quả định lượng được trình bày trong Bảng 2 cho tập kiểm thử và Bảng 3 cho tập kiểm tra. Trong đó có thể dễ dàng nhận thấy rằng, mạng học sâu đề xuất thực sự đã làm tốt hơn so với mạng học sâu truyền thống khi đạt giá trị độ chính xác trên tập kiểm thử và kiểm tra lần lượt là 77.5% và 74.1%. Kết quả này cao hơn rất nhiều so với 1DCNN lần lượt là 68.5% và 67.0%. Thuật toán LSTM chỉ đạt được 58.9% và 58.1%.



(a)



(b)

Hình 7. Biểu đồ hội tụ của mạng 1DCNN-LSTM so với mạng học sâu truyền thống trên tập huấn luyện (a) và kiểm tra (b)

5. Kết luận

Bảng 2. Bảng kết quả mạng 1DCNN-LSTM và các mạng học sâu truyền thống trên tập kiểm thử

Nhãn	LSTM			1DCNN			1DCNN-LSTM		
	precision	recall	f1-score	precision	recall	f1-score	precision	recall	f1-score
0	0.662	0.522	0.584	0.696	0.647	0.670	0.758	0.663	0.707
1	0.480	0.551	0.513	0.634	0.58	0.605	0.701	0.625	0.661
2	0.639	0.636	0.638	0.593	0.69	0.638	0.903	0.712	0.796
3	0.544	0.581	0.562	0.654	0.644	0.649	0.695	0.859	0.768
4	0.564	0.661	0.609	0.785	0.789	0.787	0.813	0.944	0.874
5	0.697	0.584	0.635	0.757	0.757	0.757	0.812	0.843	0.828
Độ chính xác			0.589			0.685			0.775

Bảng 3. Bảng kết quả mạng 1DCNN-LSTM và các mạng học sâu truyền thống trên tập kiểm tra

Nhãn	LSTM			1DCNN			1DCNN-LSTM		
	precision	recall	f1-score	precision	recall	f1-score	precision	recall	f1-score
0	0.652	0.518	0.577	0.716	0.633	0.672	0.729	0.623	0.672
1	0.511	0.468	0.488	0.677	0.517	0.587	0.706	0.567	0.628
2	0.651	0.621	0.636	0.694	0.677	0.685	0.876	0.712	0.786
3	0.472	0.654	0.548	0.556	0.699	0.619	0.594	0.788	0.678
4	0.577	0.686	0.626	0.748	0.767	0.758	0.772	0.918	0.839
5	0.660	0.578	0.617	0.650	0.762	0.701	0.790	0.897	0.841
Độ chính xác		0.581			0.67			0.741	

Các phương pháp 1DCNN, LSTM và 1DCNN-LSTM đều có thể xác định, chẩn đoán hư hỏng trên tập dữ liệu theo thời gian cho kết cấu cầu.

Phương pháp đề xuất có độ chính xác cao

Bài viết đề xuất ứng dụng một phương pháp học sâu bằng sự kết hợp giữa mạng 1DCNN và LSTM, được sử dụng để chẩn đoán hư hỏng kết cấu dựa trên dữ liệu chuỗi thời gian thu thập bằng cáp quang của cầu dây văng thí nghiệm trong trường Đại học Giao thông vận tải. Kết quả đã chứng minh rằng phương pháp đề xuất hoàn toàn vượt trội so với các phương pháp 1DCNN và LSTM truyền thống được thiết kế cho dữ liệu chuỗi thời gian.

Cụ thể, với cùng bộ dữ liệu huấn luyện, kiểm thử và kiểm tra, phương pháp 1DCNN-LSTM đã đạt kết quả 77.5 và 74.1% lần lượt trên tập kiểm tra (Bảng 2) và kiểm thử (Bảng 3). Theo sau đó là 1DCNN với 68.5% và 67.0%. Cuối cùng là thuật toán LSTM đạt được 58.9% và 58.1%. Dựa trên những kết quả này, một số kết luận quan trọng có thể được rút ra như sau:

nhất trong việc xác định hư hỏng kết cấu từ dữ liệu chuỗi thời gian thu thập được từ cảm biến cáp quang.

Kết quả thực nghiệm chứng minh ưu việt của phương pháp đề xuất so với các phương pháp

truyền thống.

Tiềm năng của phương pháp đề xuất có thể ứng dụng cho các công trình thực tế trong lĩnh vực SHM, đặc biệt là khi xử lý các dữ liệu dạng chuỗi theo thời gian.

Lời cảm ơn

Chúng tôi xin cảm ơn Trường Đại học Công nghệ GTVT đã tạo điều kiện để chúng tôi thực hiện các nghiên cứu này. Bài báo được tài trợ bởi Trường Đại học Công nghệ Giao thông vận tải, 54 Triều Khúc, Thanh Xuân, Hà Nội, Việt Nam (UTT), mã đề tài ĐTTĐ2023-07.

Tài liệu tham khảo

- [1] B. S. Kawasaki, K. O. Hill, D. C. Johnson, and Y. Fujii. (1978). Narrow-band Bragg reflectors in optical fibers. *Opt. Lett., OL*, vol. 3, no. 2, pp. 66–68, Aug. 1978, doi: 10.1364/OL.3.000066.
- [2] G. Meltz, W. W. Morey, and W. H. Glenn. (1989). Formation of Bragg gratings in optical fibers by a transverse holographic method. *Opt. Lett., OL*, vol. 14, no. 15, pp. 823–825, Aug. 1989, doi: 10.1364/OL.14.000823.
- [3] M. Rao, R. Bhat, M. Cri, K. Madhav, and S. Asokan. (2006). Structural Health Monitoring (SHM) Using Strain Gauges, PVDF Film and Fiber Bragg Grating (FBG) Sensors: A Comparative Study. Jan. 2006.
- [4] D. Kinet, P. Mégret, K. W. Goossen, L. Qiu, D. Heider, and C. Caucheteur. (2014). Fiber Bragg Grating Sensors toward Structural Health Monitoring in Composite Materials: Challenges and Solutions. *Sensors*, vol. 14, no. 4, Art. no. 4, Apr. 2014, doi: 10.3390/s140407394.
- [5] S. Sarkar, D. Inupakutika, M. Banerjee, M. Tarhani, and M. Shadaram. (2021). Machine Learning Methods for Discriminating Strain and Temperature Effects on FBG-Based Sensors. *IEEE Photonics Technology Letters*, vol. 33, no. 16, pp. 876–879, Aug. 2021, doi: 10.1109/LPT.2021.3055216.
- [6] K. P. Nascimento, A. Frizzera-Neto, C. Marques, and A. G. Leal-Junior. (2021). Machine learning techniques for liquid level estimation using FBG temperature sensor array. *Optical Fiber Technology*, vol. 65, p. 102612, Sep. 2021, doi: 10.1016/j.yofte.2021.102612.
- [7] K. Dey, N. Vangety, and S. Roy. (2021). Machine learning approach for simultaneous measurement of strain and temperature using FBG sensor. *Sensors and Actuators A: Physical*, vol. 333, p. 113254, Jan. 2022, doi: 10.1016/j.sna.2021.113254.
- [8] D. Pal, A. Kumar, A. Gautam, and J. Thangaraj. (2022). FBG Based Optical Weight Measurement System and Its Performance Enhancement Using Machine Learning. *IEEE Sensors Journal*, vol. 22, no. 5, pp. 4113–4121, Mar. 2022, doi: 10.1109/JSEN.2022.3144173.
- [9] Y. Zhang, Y. Miyamori, S. Mikami, and T. Saito. (2019). Vibration-based structural state identification by a 1-dimensional convolutional neural network. *Computer-Aided Civil and Infrastructure Engineering*, vol. 34, no. 9, pp. 822–839, 2019, doi: 10.1111/mice.12447.
- [10] O. Abdeljaber, O. Avci, M. S. Kiranyaz, B. Boashash, H. Sodano, and D. J. Inman. (2017). 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data. *Neurocomputing*, vol. 275, pp. 1308–1317, Jan. 2018, doi: 10.1016/j.neucom.2017.09.069.
- [11] S. Hochreiter and J. Schmidhuber. (1997). Long Short-Term Memory. *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [12] S. Sharma and S. Sen. (2023). Real-time structural damage assessment using LSTM networks: regression and classification approaches. *Neural Comput & Applic*, vol. 35, no. 1, pp. 557–572, Jan. 2023, doi: 10.1007/s00521-022-07773-6.
- [13] H. Hu, H. Luo, and X. Deng. (2021). Health Monitoring of Automotive Suspensions: A LSTM Network Approach. *Shock and Vibration*, vol. 2021, p. e6626024, Apr. 2021, doi: 10.1155/2021/6626024.
- [14] Y. Bengio, P. Simard, and P. Frasconi.

- (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, vol. 5, no. 2, pp. 157–166, Mar. 1994, doi: 10.1109/72.279181.
- [15] W. Zaremba, I. Sutskever, and O. Vinyals. (2015). Recurrent Neural Network Regularization. *arXiv*, Feb. 19, 2015. doi: 10.48550/arXiv.1409.2329.
- [16] Z. C. Lipton, J. Berkowitz, and C. Elkan. (2015). A Critical Review of Recurrent Neural Networks for Sequence Learning. *arXiv*, Oct. 17, 2015. doi: 10.48550/arXiv.1506.00019.
- [17] R. Pascanu, T. Mikolov, and Y. Bengio. (2013). On the difficulty of training recurrent neural networks. in *Proceedings of the 30th International Conference on Machine Learning*, PMLR, May 2013, pp. 1310–1318. Accessed: May 16, 2024. [Online]. Available: <https://proceedings.mlr.press/v28/pascanu13.html>
- [18] X. Su, H. Kang, J. Chen, T. Guo, C. Sun, and Y. Zhao. (2019). Experimental study on in-plane nonlinear vibrations of the cable-stayed bridge. *Nonlinear Dyn*, vol. 98, no. 2, pp. 1247–1266, Oct. 2019, doi: 10.1007/s11071-019-05259-0.
- [19] W. Pakos, Z. Wójcicki, J. Grosel, K. Majcher, and W. Sawicki. (2016). Experimental research of cable tension tuning of a scaled model of cable stayed bridge. *Archiv.Civ.Mech.Eng*, vol. 16, no. 1, pp. 41–52, Mar. 2016, doi: 10.1016/j.acme.2015.09.001.