

Nghiên cứu chẩn đoán hư hỏng kết cấu cầu giàn thép sử dụng mạng kết hợp 1DCNN-LSTM

Research on damage diagnosis of steel truss bridge structures using a hybrid 1DCNN-LSTM Network

> TS TRẦN VIỆT HƯNG

Trường Đại học Giao thông vận tải

Email: hungtv@utc.edu.vn

TÓM TẮT

Bài báo trình bày một phương pháp tiếp cận mới để chẩn đoán hư hỏng trong kết cấu thông qua việc áp dụng mô hình học sâu (Deep Learning - DL) kết hợp giữa khả năng trích xuất các đặc trưng của mạng nơ-ron tích chập một chiều (One Dimensional Convolutional Neural Network - 1DCNN) và khả năng xử lý dữ liệu chuỗi thời gian mạng bộ nhớ dài ngắn hạn (Long Short-Term Memory - LSTM). Mặc dù 1DCNN có ưu thế trong việc trích xuất các đặc trưng từ dữ liệu nhưng gặp hạn chế khi xử lý các mối quan hệ dài hạn trong chuỗi thời gian. LSTM lại thể hiện khả năng phân tích, học các quan hệ dài hạn, nhưng gặp khó khăn trong việc cân bằng các trọng số tính toán và tốc độ xử lý còn chậm. Để kiểm chứng hiệu quả của phương pháp đề xuất, nghiên cứu được thực hiện bằng cách sử dụng dữ liệu theo thời gian thu được từ hệ thống cảm biến gia tốc trên cầu giàn thép Chương Dương. Kết quả cho thấy hiệu quả của phương pháp đề xuất vượt trội hơn hai mô hình học sâu riêng lẻ - 1DCNN và LSTM, đạt độ chính xác lần lượt là 91,6%, 84,5% và 81,4% trên tập dữ liệu kiểm tra.

Từ khóa: Chẩn đoán hư hỏng, mạng nơ-ron tích chập một chiều, mạng bộ nhớ dài ngắn hạn, dữ liệu chuỗi thời gian, cầu giàn thép.

ABSTRACT

This paper presents a novel approach for structural damage diagnosis by applying a deep learning (DL) model that combines the feature extraction capabilities of a One-Dimensional Convolutional Neural Network (1DCNN) with the time-series data processing strength of a Long Short-Term Memory (LSTM) network. While 1DCNN excels at extracting features from data, it struggles with capturing long-term dependencies in time-series sequences. On the other hand, LSTM is effective at learning and analyzing long-term relationships but faces challenges in balancing computational weights and has slower processing speeds. To validate the effectiveness of the proposed method, the study utilizes time-series data collected from an accelerometer sensor system on the Chuong Duong steel truss bridge. The results demonstrate that the proposed hybrid model outperforms the standalone deep learning models-1DCNN and LSTM-achieving accuracies of 91.6%, 84.5% and 81.4%, respectively, on the test dataset.

Keywords: Damage diagnosis, one-dimensional convolutional neural network, long short-term memory network, time-series data, steel truss bridge.

1. ĐẶT VẤN ĐỀ

Trong những thập kỷ gần đây, Giám sát sức khỏe kết cấu (SHM) là chủ đề được các nhà khoa học trên thế giới đặc biệt quan tâm. Nhờ vào sự tiến bộ vượt bậc của công nghệ, SHM đã và đang được triển khai rộng rãi để đảm bảo an toàn, tính toàn vẹn và sự phát triển bền vững của các công trình giao thông. Những nghiên cứu cho thấy, SHM không chỉ giúp phát hiện sớm các hư hỏng mà còn tối ưu hóa chi phí bảo trì và quản lý hệ thống kết cấu [1, 2, 3].

Trong SHM, học máy truyền thống bị hạn chế khi phải xử lý lượng dữ liệu lớn nên việc áp dụng các mô hình học sâu (Deep Learning - DL) không chỉ có khả năng học và phát hiện các mẫu dữ

liệu phức tạp một cách hiệu quả mà còn tự học cách trích xuất và tận dụng các đặc điểm quan trọng từ dữ liệu đầu vào. 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 có thể phân tích xử lý dữ liệu dạng chuỗi phù hợp với nhiều loại dữ liệu và phát hiện các đặc trưng quan trọng từ dữ liệu đầu vào làm cho quá trình mô hình hóa trở nên nhanh chóng, hiệu quả. Một ví dụ cụ thể, Youqi Zhang và cộng sự [4]. Nghiên cứu này đề xuất 1DCNN đơn giản giúp phát hiện những thay đổi cục bộ nhỏ về độ cứng và khối lượng cấu kiện, đồng thời xác nhận nó trên các cấu trúc thực bằng cách sử dụng dữ liệu gia tốc thô mà không cần xử lý trước. Hay Sharma và cộng sự

[5] để xuất sử dụng mạng 1DCNN để tự động trích xuất đặc trưng từ tín hiệu gia tốc và xác định vị trí các điểm liên kết yếu. Phương pháp này được xây dựng thí nghiệm và kiểm chứng số liệu trên các khung thép và cũng được thử nghiệm trên một cấu trúc khung thép thực tế.

LSTM, một dạng mạng nơ-ron hồi quy (Recurrent Neural Network-RNN) chuyên biệt, được thiết kế để ghi nhớ và xử lý thông tin trong khoảng thời gian dài. LSTM có khả năng lưu giữ thông tin giúp mô hình học được mối quan hệ giữa các sự kiện cách nhau nhiều bước. Ví dụ, Sony và cộng sự [6] đã chứng minh phương pháp dựa trên LSTM để xuất có hiệu suất tương đương với mạng 1DCNN trên tập dữ liệu QUGS và vượt trội hơn 1DCNN trên tập dữ liệu cầu Z24. Hay Xu và cộng sự [7] đã đề xuất một framework dựa trên kiến trúc mạng nơ-ron LSTM giải quyết những hạn chế của các phương pháp hiện có để đánh giá thiệt hại sau động đất. Nó cung cấp một đánh giá nhanh chóng và chính xác về hư hại do động đất gây ra và thể hiện tính hiệu quả và tiềm năng cho các ứng dụng thực tế.

Mặc dù Mạng 1DCNN và LSTM đều đem lại những lợi ích đáng kể trong quá trình xử lý dữ liệu, chúng không tránh khỏi những hạn chế. 1DCNN thường gặp phải trở ngại trong việc học các mối quan hệ dài hạn và bộc lộ khó khăn trong việc tổng quát hóa khi đối mặt với dữ liệu mới mang tính chất khác biệt. Ngược lại, dù LSTM thể hiện sự ưu việt trong việc xử lý dữ liệu chuỗi thời gian, nó lại không hiệu quả trong việc xử lý các phụ thuộc không gian. Đối với việc giải quyết những hạn chế này, nghiên cứu đề xuất sử dụng một sự kết hợp giữa 1DCNN và LSTM. Bằng cách này, trong khi 1DCNN có khả năng lọc và kết nối thông tin không gian từ dữ liệu, LSTM cùng lúc tối ưu hóa việc học các mẫu dữ liệu tuần tự, tạo nên một kiến trúc mạnh mẽ, được tối ưu để phân tích và phân loại dữ liệu chuỗi thời gian phức tạp.


Bài báo được cấu trúc thành 5 phần chính, như sau: Ngoài phần giới thiệu ban đầu, phần thứ hai đưa ra cách hoạt động của mạng 1DCNN, LSTM và mô hình kết hợp 1DCNN-LSTM. Phần thứ ba cung cấp thông tin về cấu trúc Chương Dương cùng với bộ dữ liệu được sử dụng trong nghiên cứu. Phần thứ tư trình bày kết quả thu được từ nghiên cứu. Cuối cùng, phần kết luận tổng kết những phát hiện và kết quả chính của bài báo.

2. PHƯƠNG PHÁP

2.1. Mạng tích chập một chiều (1DCNN)

Mạng 1DCNN là một loại mạng nơ-ron sâu được thiết kế để xử lý dữ liệu tuần tự hoặc chuỗi thời gian. Khác với các mạng 2DCNN thông thường được sử dụng chủ yếu cho dữ liệu hình ảnh, 1D-CNN tập trung vào việc xử lý các đặc trưng từ dữ liệu một chiều. Đây là một công cụ mạnh mẽ trong nhiều ứng dụng như xử lý ngôn ngữ tự nhiên, phân tích chuỗi thời gian và đặc biệt là trong SHM. Cách thức hoạt động của 1DCNN biểu diễn ở Hình 1 được xây dựng dựa trên các lớp tích chập, lớp gộp, lớp làm phẳng và lớp kết nối hoàn toàn để trích xuất và học các đặc trưng từ dữ liệu đầu vào. Quá trình huấn luyện 1DCNN bao gồm việc tối ưu hóa các tham số của các bộ lọc và trọng số trong các lớp fully connected thông qua các kỹ thuật tối ưu hóa như gradient descent. Mục tiêu là giảm thiểu hàm mất mát, phản ánh sự chênh lệch giữa dự đoán của mô hình và giá trị thực tế. Qua nhiều vòng lặp huấn luyện, mạng học cách trích xuất các đặc trưng quan trọng từ dữ liệu chuỗi thời gian, từ

đó cải thiện độ chính xác việc phát hiện những đặc điểm hư hỏng trên kết cấu.




Hình 1. Mô hình 1DCNN đơn giản

2.2. Mạng bộ nhớ ngắn dài hạn (LSTM)

Mô hình LSTM là một dạng của mạng RNN được giới thiệu lần đầu bởi Hochreiter và Schmidhuber [8] vào năm 1997. Mạng được thiết kế để khắc phục vấn đề mất dần gradient (vanishing gradient) trong quá trình huấn luyện. Nhờ vào kiến trúc đặc biệt của mình, LSTM có khả năng học và ghi nhớ thông tin dài hạn, giúp nó trở thành một công cụ mạnh mẽ trong phân tích dữ liệu chuỗi thời gian.

Việc triển khai LSTM trong các ứng dụng thực tế gặp nhiều thách thức do tính toán phức tạp và yêu cầu tài nguyên cao. Với số lượng lớn tham số và các phép toán ma trận, mô hình này đòi hỏi bộ nhớ lớn và thời gian xử lý lâu, đặc biệt khi áp dụng trên các hệ thống nhúng hoặc thiết bị có tài nguyên hạn chế. Ngoài ra, việc điều chỉnh siêu tham số như số lượng đơn vị LSTM, tốc độ học và kích thước batch là một quá trình phức tạp, đòi hỏi thử nghiệm nhiều lần để tìm ra cấu hình tối ưu.



Hình 2. Cấu trúc điển hình bên trong LSTM

Cách thức hoạt động của kiến trúc LSTM (Hình 2) là trạng thái tế bào của nó, với ba cổng: Cổng đầu vào (i_t), cổng quên (f_t) và cổng đầu ra (o_t). Các cổng này được biểu diễn về mặt toán học như sau:

Cổng đầu vào 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.

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

$$\tilde{c}_t = \tanh(x_t \cdot W_c + h_{t-1} \cdot U_c + b_c)$$

Cổng quên 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).

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

Cổng đầu ra 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.

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

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

Trong đó: Các giá trị W và b đại diện cho ma trận trọng số và độ lệch; x_t là đầu vào, h_{t-1} là trạng thái ẩn trước đó và σ đại diện cho hàm kích hoạt sigmoid.

2.3. Phương pháp đề xuất 1DCNN - LSTM

Trong nghiên cứu này, chúng tôi đề xuất sử dụng một phương pháp tiếp cận kết hợp giữa 1DCNN và LSTM. Bằng cách kết hợp khả năng của hai mô hình không chỉ đơn thuần là tổng hợp 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

Ưu điểm của mô hình kết hợp 1DCNN-LSTM được thể hiện rõ rệt, đặc biệt ở khả năng kết hợp cả đặc trưng cục bộ và quan hệ dài hạn. Mạng 1DCNN đảm nhận vai trò trích xuất các đặc trưng cục bộ từ dữ liệu chuỗi, trong khi LSTM giúp mô hình hóa các mối quan hệ dài hạn trong dữ liệu. Nhờ sự kết hợp này, mô hình có thể học được các mẫu dữ liệu phức tạp và xác định sự tương tác giữa các đặc trưng, đồng thời nắm bắt hiệu quả xu hướng theo thời gian. Điều này giúp tăng cường độ chính xác trong dự báo và phân loại các bài toán liên quan đến chuỗi thời gian, nâng cao hiệu suất so với các mô hình đơn lẻ.


3. THÔNG TIN VÀ BỘ DỮ LIỆU CỦA CẦU

3.1. Giới thiệu cầu Chương Dương



Hình 4. Một số hình ảnh cầu Chương Dương [9, 10]


Cầu Chương Dương - một công trình cầu giàn thép nhịp lớn tại Hà Nội, nối quận Hoàn Kiếm với quận Long Biên. Với tổng chiều dài 1.230 m và chiều rộng 20 m, cầu Chương Dương được thiết kế gồm 4 làn xe cơ giới và hai làn xe thô sơ. Cầu bao gồm 21 nhịp, trong đó nhịp chính bắc qua sông dài 180 m, còn các nhịp khác có chiều dài từ 47 đến 90 m [11]. Một số thông tin của cầu được thể hiện trong Hình 4 và Hình 5.



Hình 5. Kích thước của nhịp thứ 10 cầu Chương Dương [11]

3.2. Mô hình phần tử hữu hạn (Finite element model - FEM)

Trong phần này, mô hình phần tử hữu hạn của cầu giàn thép Chương Dương được xây dựng bằng phần mềm Matlab. Mô hình này sẽ sử dụng các phần tử dầm với mỗi nút có sáu bậc tự do. Nhịp cầu giàn đơn dài 89,28 m được mô phỏng bằng 318 nút và 799 phần tử. Các gối cầu được mô phỏng bằng cách sử dụng cả gối cố định và gối di động. Thành phần chính của cầu được làm bằng thép nên vật liệu của các phần tử là như nhau, với mô-đun Young = $2,1 \times 10^{11}$ Pa, tỷ số Poisson = 0,3 và khối lượng riêng thể tích = 7.850 kg/m^3 . Mô hình FEM của cầu được thể hiện như trong Hình 6.



Hình 6. Mô hình phần tử hữu hạn của cầu Chương Dương

3.3. Thu thập và xử lý dữ liệu

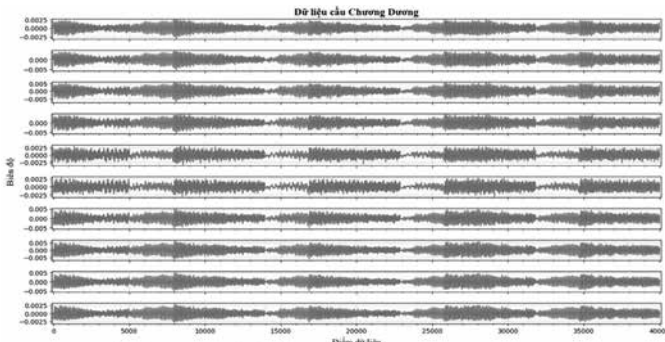
Nghiên cứu này sẽ giả định 11 trường hợp hư hỏng bằng cách giảm độ cứng ở một phần tử kết cấu của cầu. Ví dụ, nếu độ cứng còn lại là 70% thì mức độ hư hỏng sẽ là 20%. Các trường hợp sẽ được dán nhãn từ 0 đến 11 với mỗi nhãn là một mức độ hư hỏng tương ứng như trong Bảng 1.

Bảng 1. Các trường hợp hư hỏng

Nhãn	Phần tử	Phần trăm hư hỏng (%)	Trạng thái
0	1	0	Nguyên vẹn
1	2	10	
2	3	20	
3	4	30	
4	5	40	
5	10	10	Hư hỏng
6	11	20	
7	12	30	
8	13	10	
9	16	20	
10	25	30	

Tải trọng được dùng để kích thích dao động là hoạt tải xe tải 3 trục theo HL93, với vận tốc chạy trên cầu là 60 km/h và chạy 10 lần trên cầu. Số lần xe chạy trên cầu là 20 lần, khoảng cách giữa các lần chạy là 2s.


Bằng cách sử dụng 40 cảm biến ảo ở tần số lấy mẫu 500 Hz đã được thu thập với điểm thời gian là 40.000, tạo ra một tập dữ liệu có kích thước (11, 40, 40.000). Một đoạn dữ liệu mẫu được minh họa trong Hình 7.



Hình 7. Dữ liệu ban đầu thu được từ cảm biến

4. KẾT QUẢ VÀ ĐÁNH GIÁ


Trong nghiên cứu này, phương pháp đề xuất sẽ được sử dụng để phát hiện hư hỏng trên cầu Chương Dương. Nghiên cứu này sử dụng ngôn ngữ Python phiên bản 3.11.9 và thư viện TensorFlow, một thư viện học sâu nguồn mở với khả năng hỗ trợ mạnh mẽ cho nhiều mô hình học sâu. Các phương pháp truyền thống như LSTM, 1DCNN cũng được áp dụng để so sánh với mạng kết hợp để thấy rõ hiện quả. Các kết quả được biểu diễn trong Hình 8, Hình 9 và Hình 10.



Hình 8. Biểu đồ hội tụ: a) - Tập huấn luyện; b) - Tập kiểm tra

Dựa trên Hình 8, có thể nhận thấy rằng trên tập huấn luyện, mô hình kết hợp 1DCNN-LSTM hội tụ nhanh hơn và đạt được độ chính xác cao hơn so với các mô hình còn lại. Khi áp dụng trên tập kiểm tra, mô hình này tiếp tục thể hiện khả năng tổng quát hóa vượt trội. Cụ thể hơn, từ Hình 9, mô hình 1DCNN-LSTM dự đoán khá

chính xác đối với hầu hết các lớp khi số dự đoán đúng trên đường chéo khá cao và một số nhân chỉ nhầm lẫn 1 - 2 lần với tần số ít. So với các mô hình khác, 1DCNN và LSTM nhầm lẫn ở nhiều nhân, lên đến 7 lần.



Hình 9. Ma trận nhầm lẫn của 3 mô hình

5. KẾT LUẬN VÀ KIẾN NGHỊ

Nghiên cứu này áp dụng mô hình kết hợp 1DCNN-LSTM, trong xử lý dữ liệu chuỗi thời gian trong lĩnh vực SHM. Các kết quả cho thấy mô hình này có hiệu suất cao hơn so với việc sử dụng riêng lẻ 1DCNN hoặc LSTM trong việc chẩn đoán hư hỏng kết cấu. Mô hình 1DCNN-LSTM đạt tỷ lệ độ chính xác cao nhất là 91,6% trên tập kiểm tra, cao hơn so với 1DCNN ở mức 84,5% và LSTM với 81,4%. Sự vượt trội này mở ra khả năng ứng dụng mô hình trong nhiều lĩnh vực khác, từ y tế đến dự báo thời tiết, nhờ vào khả năng linh hoạt và hiệu quả trong xử lý dữ liệu phức tạp. Tuy nhiên, để tối ưu hóa hiệu suất, cần tiếp tục nghiên cứu về tinh chỉnh tham số, tăng cường dữ liệu và phát triển kỹ thuật mới.

TÀI LIỆU THAM KHẢO

- [1]. J. P. Lynch and K. J. Loh (2006), A summary review of wireless sensors and sensor networks for structural health monitoring, Shock and vibration digest, vol.38, no.2, pp.91-130.
- [2]. B. F. Spencer, M. E. (Oct. 2004), Ruiz-Sandoval and N. Kurata, Smart sensing technology: opportunities and challenges, Struct. Control Health Monit., vol.11, no.4, pp.349-368, doi: 10.1002/stc.48.
- [3]. H. Sohn et al. (2003), A review of structural health monitoring literature: 1996-2001, Los Alamos National Laboratory, USA, vol.1, no.16, pp.10-12989.
- [4]. Y. Zhang, Y. Miyamori, S. Mikami and T. Saito (Sep., 2019), Vibration-based structural state identification by a 1-dimensional convolutional neural network, Computer aided Civil Eng, vol.34, no.9, pp.822-839, doi: 10.1111/mice.12447.
- [5]. S. Sharma and S. Sen (Nov., 2020), One-dimensional convolutional neural network-based damage detection in structural joints, J Civil Struct Health Monit, vol.10, no.5, pp.1057-1072, doi: 10.1007/s13349-020-00434-z.
- [6]. S. Sony, S. Gamage, A. Sadhu and J. Samarabandu (2022), Vibration-based multiclass damage detection and localization using long short-term memory networks, in Structures, Elsevier, pp.436-451, Accessed: Mar. 23, 2025; [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2352012421010493>.
- [7]. Y. Xu, X. Lu, B. Cetiner and E. Taciroglu (Apr., 2021), Real-time regional seismic damage assessment framework based on long short-term memory neural network, Computer aided Civil Eng, vol.36, no.4, pp.504-521, doi: 10.1111/mice.12628.
- [8]. Hai D. M., "[RNN] LSTM là gì?", Hai's Blog. Accessed: Mar. 23, 2025. [Online]. Available: <https://dominhhai.github.io/vi/2017/10/what-is-lstm/>.
- [9]. Quang Phong và Tiến Dũng, Hà Nội cấm nhiều loại xe qua cầu Chương Dương,
- [10]. Dương Châu, Hà Nội: Lập dự án sửa chữa cầu Chương Dương.
- [11]. L. Nguyen-Ngoc, Q. Nguyen-Huu, G. De Roeck (2024), T. Bui-Tien and M. Abdel-Wahab, Deep neural network and evolved optimization algorithm for damage assessment in a truss bridge, Mathematics, vol.12, no.15, p.2300.