

Phát hiện hư hỏng cho cầu giàn thép sử dụng mô hình 1DCNN-LSTM

■ TS. TRẦN NGỌC HÒA^(*); BÙI PHÚC LỘC; NGUYỄN ĐỨC LƯƠNG
TỔNG ĐỨC MẠNH; VŨ MẠNH TRUNG
Trường Đại học Giao thông vận tải
Email: ^(*)ngochoa@utc.edu.vn

TÓM TẮT: Trong lĩnh vực giám sát sức khỏe kết cấu (Structural Health Monitoring - SHM), đánh giá hư hỏng đóng vai trò trung tâm và đang thu hút sự chú ý mạnh mẽ từ cộng đồng nghiên cứu quốc tế. Các phương pháp đánh giá này phụ thuộc vào dữ liệu và thông tin được thu thập thông qua quá trình kiểm tra cũng như các kỹ thuật được ứng dụng. Tính chính xác và độ tin cậy của những đánh giá này có thể biến đổi tùy thuộc vào nhiều điều kiện khác nhau. Để đối phó với thách thức này, nhiều mô hình học sâu đã được áp dụng, sử dụng dữ liệu chuỗi thời gian thu thập từ các kết cấu, bao gồm mạng nơ-ron tích chập một chiều (1DCNN) và mạng nơ-ron bộ nhớ ngắn dài hạn (Long Short-Term Memory - LSTM). Nghiên cứu này đề xuất một mô hình học sâu kết hợp 1DCNN và LSTM để cải thiện khả năng phát hiện hư hỏng trong kết cấu. Hiệu quả của phương pháp này được kiểm chứng trên bộ dữ liệu của một cầu giàn thép. Các kết quả đã chỉ ra rằng, phương pháp kết hợp đề xuất mang lại hiệu suất vượt trội so với LSTM truyền thống - với độ chính xác lần lượt trên tập kiểm tra là 94,3% và 90,04%.

TỪ KHÓA: Đánh giá hư hỏng, cầu giàn thép, mạng nơ-ron tích chập, bộ nhớ ngắn dài hạn, dữ liệu chuỗi thời gian.

ABSTRACT: In the realm of Structural Health Monitoring (SHM), damage assessment emerges as a pivotal issue, receiving special attention from the research community. The execution of this task relies on the analysis of information and data obtained through various inspection processes and methodologies. The reliability and accuracy of such assessments may fluctuate across different scenarios. To deal with this challenge, numerous deep learning architectures leveraging time-series data extracted from structural entities have been employed, notably including one-dimensional Convolutional Neural Networks (1DCNN) and Long Short-Term Memory (LSTM) networks. This study introduces a novel deep learning framework combining 1DCNN and LSTM (1DCNN-LSTM), aimed at amplifying the efficiency of damage identification

within structural frameworks. The performance of 1DCNN-LSTM is evaluated employing the dataset derived from a steel truss bridge. The results have demonstrated that the proposed combined method delivers superior performance compared to traditional LSTM - with respective accuracies on the test set of 94.3% and 90.04%.

KEYWORDS: Damage assessment, steel truss bridge, Convolutional Neural Network, Long Short-Term Memory, time-series data.

1. ĐẶT VẤN ĐỀ

Trong những thập kỷ gần đây, giám sát sức khỏe kết cấu công trình (SHM) là chủ đề được các nhà khoa học trên thế giới đặc biệt quan tâm. Việc bùng nổ cuộc cách mạng 4.0 đã tạo ra bước phát triển nhảy vọt cho kỹ thuật trí tuệ nhân tạo (Artificial Intelligence - AI), là nhân tố quan trọng ứng dụng vào đời sống xã hội và SHM không phải là ngoại lệ [1, 2, 3].

Trong giám sát sức khỏe kết cấu công trình, học máy truyền thống bị hạn chế với dữ liệu lớn nên việc áp dụng các mô hình mạng nơ-ron với nhiều lớp xử lý không chỉ nhận diện các xu hướng và 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 trong kết cấu 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 của Youqi Zhang và cộng sự [4], nghiên cứu này đề xuất sử dụng 1DCNN để phát hiện những thay đổi cục bộ về độ cứng của kết cấu, đồng thời kiểm tra trên các cấu trúc thực bằng cách sử dụng dữ liệu gia tốc thô mà không cần xử lý trước.

LSTM, một dạng mạng nơ-ron hồi quy (Recurrent Neural Network-RNN), được thiết kế để ghi nhớ và xử lý thông tin trong khoảng thời gian dài [5]. 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, Sharma và Sen [6] 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 phát hiện các hư hỏng trên một công trình cầu

thực tế. Haoju Hu và các cộng sự [7] đã phát triển một hệ thống tiên tiến dựa trên mạng LSTM, tận dụng dữ liệu cảm biến chuỗi thời gian để đưa ra ước lượng về tải trọng hoạt động và tuổi thọ còn lại của hệ thống treo của ô tô.

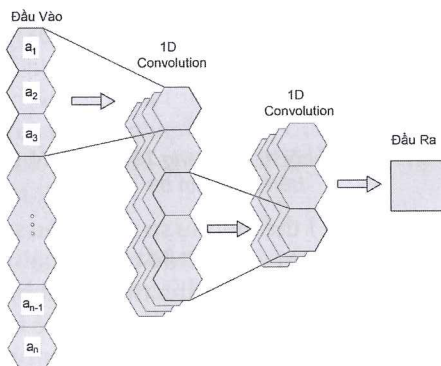
Mặc dù Mạng 1DCNN và LSTM đều đem lại những lợi ích đáng kể trong quá trình xử lý dữ liệu, chúng không tránh khỏi những hạn chế. 1DCNN thường gặp phải trở ngại trong việc học các mối quan hệ dài hạn và bộc lộ khó khăn trong việc tổng quát hóa khi đối mặt với dữ liệu mới mang tính chất khác biệt. Ngược 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 này 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 này được cấu trúc thành 5 phần chính: Ngoài phần giới thiệu ban đầu, phần thứ hai đưa ra mô tả về 1DCNN, LSTM và mô hình kết hợp 1DCNN-LSTM. Phần thứ ba cung cấp thông tin về cấu Nam Ô 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)

Mô hình 1DCNN (Hình 2.1) đang trở thành một công cụ mạnh mẽ trong lĩnh vực xử lý dữ liệu chuỗi và đã được áp dụng rộng rãi trong nhiều ứng dụng khác nhau. 1DCNN có khả năng học và trích xuất đặc trưng từ dữ liệu chuỗi một cách hiệu quả thông qua việc sử dụng lớp convolution và pooling, giúp nhận diện các mẫu phức tạp và đạt hiệu suất cao trong phân loại và dự đoán. Thay vì thực hiện các phép tính ma trận phức tạp, 1DCNN yêu cầu các phép toán đơn giản hơn, giảm đáng kể thời gian tính toán [8]. Tuy nhiên, để sử dụng 1DCNN hiệu quả, cần lưu ý rằng mô hình này đòi hỏi một lượng dữ liệu lớn để huấn luyện và việc tinh chỉnh tham số cũng rất quan trọng. Việc tinh chỉnh kích thước kernel, số lượng lớp convolution, hàm kích hoạt... cần được thực hiện cẩn thận để đạt được hiệu suất tốt nhất. Đồng thời, việc hiểu rõ về ưu điểm, hạn chế và cách sử dụng mô hình 1DCNN sẽ giúp tận dụng tối đa tiềm năng của nó trong các ứng dụng thực tế.

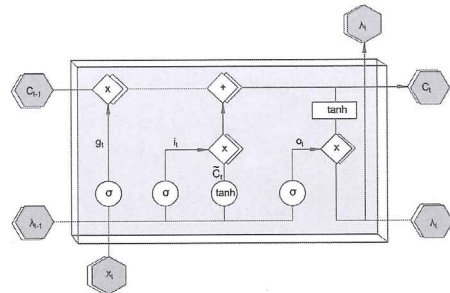


Hình 2.1: Mô hình 1DCNN đơn giản

2.2. Mạng bộ nhớ ngắn dài hạn (LSTM)

Mô hình LSTM, viết tắt của Long Short-Term Memory là một dạng của mạng RNN được giới thiệu lần đầu bởi Hochreiter và Schmidhuber vào năm 1997 [9]. LSTM đã trở thành một công cụ mạnh mẽ trong nhiều lĩnh vực. Một trong những ưu điểm nổi bật của LSTM là khả năng lưu trữ thông tin trong thời gian dài. Điều này làm cho mô hình trở nên đặc biệt phù hợp cho các ứng dụng yêu cầu xử lý thông tin dài hạn.

Với tính toán phức tạp và đòi hỏi nhiều tài nguyên, việc triển khai LSTM trong các ứng dụng thực tế có thể gặp phải những thách thức về hiệu suất và tài nguyên. Đồng thời, việc cấu hình và điều chỉnh các siêu tham số cũng đòi hỏi sự hiểu biết sâu về mô hình, điều này có thể làm tăng độ phức tạp của quá trình phát triển và triển khai.



Hình 2.2: Cấu trúc điển hình mô hình LSTM

Mô hình LSTM được triển khai như sau [9]:

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.

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

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

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).

$$g_t = \sigma(x_t \cdot W_g + \lambda_{t-1} \cdot U_g + b_g) \quad (3)$$


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.

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

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

2.3. 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 2.3.



Hình 2.3: Kiến trúc mạng 1DCNN-LSTM sử dụng

1DCNN được thiết kế để trích xuất đặc trưng cục bộ từ dữ liệu chuỗi, trong khi LSTM có khả năng mô hình hóa

mối quan hệ dài hạn trong dữ liệu. Vì vậy, mô hình có khả năng học được các mẫu phức tạp và tương tác giữa các đặc trưng, cũng như mô hình hóa được các mối quan hệ dài hạn trong dữ liệu chuỗi. Điều này giúp cải thiện khả năng dự đoán và phân loại của mô hình trong các bài toán liên quan đến dữ liệu chuỗi thời gian.

3. THÔNG TIN VÀ BỘ DỮ LIỆU CỦA CẦU

Cầu đường sắt Nam Ô là cây cầu giàn thép có quy mô lớn, nằm ở TP. Đà Nẵng, miền Trung Việt Nam. Cây cầu bao gồm 4 nhịp giản đơn có chiều dài bằng nhau (75 m). Đường ray được đặt trực tiếp trên dầm của mặt cầu. Mố phía Hải Vân được gọi là A-0, trong khi ba trụ cầu được đánh số là P-1, P-2 và P-3, bắt đầu từ phía A-0. Nhịp cuối cùng (thứ 4) đi từ P-3 đến mố A-1 phía TP. Đà Nẵng. Một số góc nhìn của cây cầu được đưa ra trong Hình 3.1.




a)




b)

Hình 3.1: Hướng nhìn cầu Nam Ô: a) - Phía thượng lưu; b) - Phía hạ lưu [10]

Các cấu kiện giàn được làm từ thép có nhiều loại tiết diện I, L, Box (Hình 3.2) và được liên kết với nhau bằng bu-lông.



Hình 3.2: Các thanh giàn trong mô hình [10]

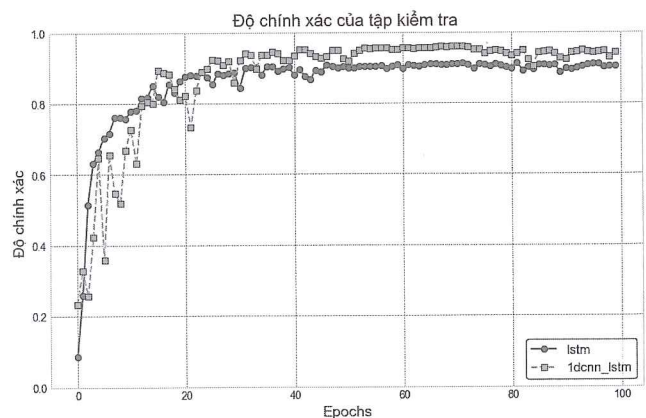


Hình 3.3: Dữ liệu theo thời gian tại một cảm biến ảo

4. KẾT QUẢ VÀ THẢO LUẬN

Để kiểm chứng sự hiệu quả của mô hình học sâu được đề xuất 1DCNN-LSTM, mạng LSTM cũng được xem xét. Dữ liệu được chia thành 11 lớp, bao gồm 1.980 bộ dữ liệu được chia thành tập huấn luyện và kiểm tra một cách ngẫu nhiên, với 70% dữ liệu dành cho huấn luyện và 30% dữ liệu dành cho kiểm tra.

Đầu tiên là một lớp 1DCNN sử dụng với mục đích trích xuất các tính năng quan trọng của mô hình, lớp CNN bao gồm các đặc điểm như sau: Số lượng Kernel là 128 và kích thước của kernel 3x3. Sau khi các dữ liệu đầu vào đã được trích xuất, mạng LSTM sẽ được sử dụng để học và phân loại. Mạng LSTM gồm 2 lớp, xen kẽ các lớp sử dụng các lớp Dropout để ngăn hiện tượng overfitting và các Maxpooling để trích xuất những đặc trưng quan trọng. Điều đó giúp giảm được các kích thước ma trận, giảm số phép tính và giảm thời gian tính toán. Kết quả so sánh dựa trên biểu đồ hội tụ được minh họa trong Hình 4.1.



Hình 4.1: Biểu đồ hội tụ của mạng 1DCNN-LSTM, LSTM trên tập kiểm tra

Nhận xét: Hình 4.1 thể hiện sự so sánh hiệu suất hội tụ giữa hai mô hình: LSTM và 1DCNN-LSTM qua số lần lặp. Mô hình kết hợp 1DCNN-LSTM cho thấy độ chính xác cao nhất và ổn định so với hai mô hình còn lại. Mô hình LSTM có độ chính xác ban đầu khá tốt nhưng nhanh chóng đạt đến hội tụ.

Bảng 4.1. Kết quả huấn luyện trên tập kiểm tra của mạng 1DCNN-LSTM, LSTM


Nhãn	LSTM			1DCNN-LSTM		
	precision	recall	f1-score	precision	recall	f1-score
0	0,930	0,957	0,943	0,829	0,986	0,901
1	0,855	0,922	0,888	0,974	0,987	0,981
2	1,000	0,909	0,952	0,988	0,943	0,965
3	0,959	0,910	0,934	0,986	0,910	0,947
4	0,902	0,949	0,925	0,846	0,987	0,911
5	0,895	0,895	0,895	0,986	0,908	0,945
6	0,881	0,925	0,902	0,974	0,925	0,949
7	0,963	0,814	0,883	0,913	0,969	0,940
8	0,787	0,914	0,846	0,986	0,901	0,942
9	0,902	0,914	0,908	0,950	0,938	0,944
10	0,895	0,865	0,880	0,976	0,921	0,948
Độ chính xác			0,904			0,943

Độ chính xác được tính với công thức sau:

$$f1 - score = \frac{2 * Recall * Precision}{Recall + Precision}$$

(6)

Với $Recall = \frac{TP}{TP+FN}$ và $Precision = \frac{TP}{TP+FP}$



Hình 4.2: Độ chính xác của mạng 1DCNN-LSTM, LSTM trên tập kiểm tra

Hình 4.2 và Bảng 4.1 cho thấy mô hình 1DCNN-LSTM vượt trội hơn hẳn so với cả LSTM. Mô hình này đạt tỷ lệ độ chính xác cao nhất là 94,3% trên tập kiểm tra, cao hơn so với LSTM với 90,04%.

5. KẾT LUẬN

Nghiên cứu này áp dụng mô hình kết hợp 1DCNN-LSTM, trong xử lý dữ liệu chuỗi thời gian cho giám sát sức khỏe kết cấu (SHM). Các kết quả cho thấy mô hình này có hiệu suất cao hơn so với việc sử dụng LSTM trong việc chẩn đoán hư hỏng kết cấu. Mô hình 1DCNN-LSTM đạt tỷ lệ độ chính xác cao nhất là 94,3% trên tập kiểm tra, cao hơn so với LSTM với 90,04%. Sự vượt trội này mở ra khả năng ứng dụng mô hình trong nhiều lĩnh vực khác, 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.

Lời cảm ơn: Nghiên cứu này được tài trợ bởi Bộ Giáo dục và Đào tạo trong Đề tài Khoa học và công nghệ cấp Bộ, mã số B2024-GHA-06.

Tài liệu tham khảo

[1]. H. Tran-Ngoc, S. Khatir, T. Le-Xuan, G. De Roeck, T. Bui-Tien and M. A. Wahab (2020), *A novel machine-learning based on the global search techniques using vectorized data for damage detection in structures*, Int. J. Eng. Sci., vol.157, p.103376.

[2]. H. Tran-Ngoc et al. (2022), *Damage assessment in structures using artificial neural network working and a hybrid stochastic optimization*, Sci. Rep., vol.12, no.1, p.4958.

[3]. T. Bui-Tien, D. Bui-Ngoc, H. Nguyen-Tran, L. Nguyen-Ngoc, H. Tran-Ngoc and H. Tran-Viet (2022), *Damage detection in structural health monitoring using hybrid convolution neural network and recurrent neural network*, Frat. Ed Integrità Strutt., vol.16, no.59, pp.461-470.

[4]. Y. Zhang, Y. Miyamori, S. Mikami and T. Saito (Sep., 2019), *Vibration-based structural state identification by a 1-dimensional convolutional neural network*, Comput.-Aided Civ. Infrastruct. Eng., vol.34, no.9, pp.822-839, doi: 10.1111/mice.12447.

[5]. S. Hochreiter and J. Schmidhuber (1997), *Long short-term memory*, Neural Comput., vol.9, no.8, pp.1735-1780.

[6]. S. Sharma and S. Sen (Jan., 2023), *Real-time structural damage assessment using LSTM networks: regression and classification approaches*, Neural Comput. Appl., vol.35, no.1, pp.557-572, doi: 10.1007/s00521-022-07773-6.

[7]. H. Hu, H. Luo and X. Deng (2021), *Health monitoring of automotive suspensions: a LSTM network approach*, Shock Vib., pp.1-11.

[8]. S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj and D. J. Inman (09, May, 2019), *1D Convolutional Neural Networks and Applications: A Survey*, arXiv, doi: 10.48550/arXiv.1905.03554.

[9]. Hai D. M. (29, Mar., 2024), *[RNN] LSTM là gì?*, Hai's Blog. Accessed, [Online]. Available: <https://dominhhai.github.io/vi/2017/10/what-is-LSTM/>.

[10]. H. Tran-Ngoc, S. Khatir, G. De Roeck, T. Bui-Tien, L. Nguyen-Ngoc and M. Abdel Wahab (Dec. 2018), *Model Updating for Nam O Bridge Using Particle Swarm Optimization Algorithm and Genetic Algorithm*, Sensors, vol.18, no.12, Art. no.12, doi: 10.3390/s18124131.

Ngày nhận bài: 25/3/2024
Ngày nhận bài sửa: 10/4/2024
Ngày chấp nhận đăng: 25/4/2024