



## DAMAGE CLASSIFICATION OF STEEL FRAME USING ONE-DIMENSIONAL CONVOLUTIONAL NEURAL NETWORK AND CHANNEL ATTENTION MECHANISM

Nguyen Huu Quyet<sup>1</sup>, Le Van Vu<sup>2</sup>, Tran Ngoc Hoa<sup>2\*</sup>

<sup>1</sup> The University of Transportation and Communications Limited Company (UCT., LTD), No 3 Cau Giay Street, Hanoi, Vietnam

<sup>2</sup> University of Transport and Communications, No 3 Cau Giay Street, Hanoi, Vietnam

### ARTICLE INFO

TYPE: Research Article

Received: 17/09/2024

Revised: 02/11/2024

Accepted: 10/12/2024

Published online: 15/12/2024

<https://doi.org/10.47869/tcsj.75.9.8>

\* *Corresponding author*

Email: ngochoa@utc.edu.vn; Tel: +84968933288

**Abstract.** In the field of structural health monitoring (SHM), the study of deep learning models such as one-dimensional convolutional neural networks (1DCNN) for processing and analyzing time-series datasets has garnered significant attention. However, 1DCNN models often do not achieve high accuracy when dealing with too long time-series data. Therefore, this research proposes an accurate classification of damage in steel frames by integrating 1DCNN with a channel attention (CA) mechanism. This combination enhances the model's performance by focusing on prominent features in time-series data, thereby improving classification accuracy. The study utilizes the Qatar University Grandstand Simulator (QUGS) dataset, a large-scale dataset developed to evaluate the effectiveness of models in the SHM field. Through the training process, the proposed 1DCNN-CA model outperforms the traditional 1DCNN model, achieving higher accuracy in both validation and test datasets, with 95.7% and 93.6%, respectively. The results demonstrate that the integration of the channel attention mechanism significantly improves the accuracy of deep learning models in damage classification tasks, offering great potential in SHM-related applications.

**Keywords:** damage classification, time-series data, one-dimensional convolutional neural network, channel attention mechanism.

@ 2024 University of Transport and Communications



# PHÂN LOẠI HƯ HỎNG KHUNG THÉP BẰNG MẠNG NƠ RON TÍCH CHẬP MỘT CHIỀU VÀ CƠ CHẾ CHÚ Ý KÊNH

Nguyễn Hữu Quyết<sup>1</sup>, Lê Văn Vũ<sup>2</sup>, Trần Ngọc Hoà<sup>2\*</sup>

<sup>1</sup> Công ty TNHH Giao thông vận tải, Số 3 Cầu Giấy, Hà Nội, Việt Nam

<sup>2</sup> 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: 17/09/2024

Ngày nhận bài sửa: 02/11/2024

Ngày chấp nhận đăng: 10/12/2024

Ngày xuất bản Online: 15/12/2024

<https://doi.org/10.47869/tcsj.75.9.8>

\* Tác giả liên hệ

Email: ngochoa@utc.edu.vn; Tel: +84968933288

**Tóm tắt.** Trong lĩnh vực giám sát sức khỏe kết cấu (SHM), việc nghiên cứu các mô hình học sâu như mạng nơ-ron tích chập một chiều (1DCNN) để xử lý, phân tích các bộ dữ liệu thời gian đã được đặc biệt quan tâm. Tuy nhiên, mô hình 1DCNN không đạt được độ chính xác cao với dữ liệu có chiều dài quá lớn. Do đó, nghiên cứu này đề xuất phân loại chính xác hư hỏng trong kết cấu khung thép bằng cách kết hợp 1DCNN với cơ chế chú ý kênh (CA). Sự kết hợp này cải thiện hiệu năng của mô hình trong việc tập trung vào các đặc trưng nổi bật trong dữ liệu chuỗi thời gian, từ đó nâng cao độ chính xác trong phân loại. Nghiên cứu áp dụng bộ dữ liệu Qatar University Grandstand Simulator (QUGS), một bộ dữ liệu quy mô lớn được xây dựng cho mục đích kiểm tra hiệu quả các mô hình trong lĩnh vực SHM. Thông qua quá trình huấn luyện, mô hình đề xuất 1DCNN-CA đạt hiệu suất vượt trội so với mô hình 1DCNN truyền thống, với độ chính xác cao hơn trong cả hai tập dữ liệu xác thực và kiểm tra lần lượt là 95,7% và 93,6%. Các kết quả thu được cho thấy việc tích hợp cơ chế chú ý kênh cải thiện đáng kể độ chính xác của các mô hình học sâu trong bài toán phân loại hư hỏng và có nhiều tiềm năng trong các vấn đề thuộc lĩnh vực SHM.

**Từ khóa:** phân loại hư hỏng, dữ liệu thời gian, mạng tích chập một chiều, cơ chế chú ý kênh.

@ 2024 Trường Đại học Giao thông vận tải

## 1. ĐẶT VẤN ĐỀ

Hệ thống SHM đã trở thành một công cụ quan trọng trong quản lý hạ tầng hiện đại. Việc thu thập và phân tích dữ liệu theo thời gian thực từ các cảm biến cung cấp những thông tin quan trọng về tình trạng kết cấu của công trình. Nhiều nghiên cứu đã xem xét việc sử dụng dữ liệu

từ các cảm biến gia tốc, cảm biến đo biến dạng và cảm biến chuyển vị để theo dõi dao động, tải trọng của công trình cầu trong điều kiện hoạt động bình thường và cả khi chịu tác động bất thường ảnh hưởng tới kết cấu công trình. Dữ liệu theo thời gian thu thập trong thời gian dài cho phép nhận diện các xu hướng dài hạn, sự thay đổi đột ngột và các bất thường trong quá trình vận hành và khai thác kết cấu, từ đó giúp đưa ra các dự đoán bảo trì và can thiệp kịp thời. Sự phát triển của học máy và trí tuệ nhân tạo đã nâng cao khả năng phân tích dữ liệu theo thời gian cho SHM. Việc tích hợp dữ liệu thời gian thực với phân tích dự đoán đã cho thấy tiềm năng cải thiện độ chính xác trong phát hiện hư hỏng, nâng cao an toàn và kéo dài tuổi thọ cho công trình cầu. Tuy nhiên, vẫn còn nhiều thách thức, đặc biệt là trong việc quản lý khối lượng dữ liệu lớn, đảm bảo độ tin cậy của cảm biến và diễn giải các mô hình dữ liệu phức tạp cho các loại cầu khác nhau [1–4].

1DCNN là mô hình được áp dụng rộng rãi, đặc biệt cho dữ liệu dạng chuỗi như thời gian. Với nguyên lý hoạt động phù hợp trong việc trích xuất các đặc trưng trên tập dữ liệu để học tập, điều này đặc biệt có hiệu quả trong việc xác định những sự bất thường trên kết cấu được phản ánh trên dữ liệu từ cảm biến. Tuy nhiên, việc huấn luyện theo nguyên lý này cũng xuất hiện một số nhược điểm dẫn tới suy giảm độ chính xác. Cụ thể, với bộ dữ liệu tuần tự có chiều dài lớn hơn khả năng làm việc hiệu quả sẽ dẫn tới các đặc trưng không thể được ghi nhớ và lưu trữ để huấn luyện mạng [5–8].

Nhiều nhà khoa học đã kết hợp mô hình 1DCNN với các mô hình có khả năng ghi nhớ để cải thiện kết quả. Hamed Fathnejat và cộng sự [9] đề xuất một mô hình bao gồm 1DCNN, mạng nơ ron hồi quy (recurrent neural network - RNN) để đánh giá hư hỏng dưới ảnh hưởng của môi trường dựa trên dữ liệu. Kết quả thu được từ hai bộ dữ liệu cho thấy mô hình kết hợp với biến thể của RNN là đơn vị hồi quy theo cổng (gated recurrent unit - GRU) hai chiều (BiGRU) đạt hiệu quả tốt nhất. Tran-Ngoc và cộng sự [10] sử dụng mô hình 1DCNN-BiLSTM-AUG cho việc phân loại 11 trường hợp hư hỏng từ bộ dữ liệu ảo của cầu Nam Ô. Trong đó, BiLSTM là mạng bộ nhớ dài ngắn-hạn hai chiều (bi-directional long short-term memory - BiLSTM) có cấu trúc phức tạp hơn GRU và AUG là phương pháp làm giàu dữ liệu. Với độ chính xác đạt 98,4%, mô hình đề xuất đã thu được hiệu quả vượt trội hơn các mô hình 1DCNN, LSTM và cả 1DCNN-LSTM. Trong nghiên cứu của Bui-Tien và cộng sự [11], các tác giả đã giới thiệu một cách tiếp cận tương tự với mức độ cao hơn. Các thông số trong mạng được tối ưu trong quá trình huấn luyện bằng thuật toán tối ưu và đạt độ chính xác tới 91,6% trong tập kiểm tra từ bộ dữ liệu từ cầu giàn thép Cửa Rào. Các phương pháp trên đều đã cải thiện được hiệu quả của 1DCNN, tuy nhiên có cấu trúc phức tạp và yêu cầu nguồn tài nguyên lớn để xử lý, do đó có thể không hiệu quả trong trường hợp công cụ tính toán không đủ mạnh hoặc thời gian hạn chế.

Những năm gần đây, cơ chế tập trung (attention mechanism – AM) đã được quan tâm để xử lý lượng dữ liệu, từ đó cải thiện kết quả huấn luyện [12]. Zhao và cộng sự [13] kết hợp mạng 1DCNN với AM trong việc dự đoán xác suất ngắn hạn của gió dựa trên nhiều tham số ảnh hưởng. Kết quả từ mô hình được giới thiệu hoàn toàn vượt trội hơn các mô hình truyền thống. Trong bài toán chẩn đoán lưu lượng giao thông, Wang và cộng sự [14] thử nghiệm mô hình 1DCNN-LSTM-Attention. Mô hình này kết hợp được cả hai ưu điểm của mạng nơ ron tích chập (convolutional neural network – CNN) là trích xuất dữ liệu và ghi nhớ của LSTM. Sau đó, AM được áp dụng để tập trung vào các thông tin nổi bật. Hu và cộng sự [15] xác định thành phần hóa học của kỹ tử bằng việc kết hợp công nghệ hình ảnh siêu phổ với 1DCNN. Quá trình được cải thiện bằng việc áp dụng thêm SA, cơ chế chú ý phổ (spectral attention) và kết hợp của hai cơ chế này.

Trong các bài toán chẩn đoán hư hỏng, việc triển khai AM sau các lớp tích chập đầu tiên cũng đã được nghiên cứu. Zhang và cộng sự [16] đã đề xuất mô hình BiGRU, AM và CNN để

xác định hư hỏng trong thiết bị quay cơ học. Kết quả thu được trong các trường hợp phức tạp đã cho thấy hiệu quả của phương pháp. Vo và cộng sự [17] nghiên cứu mô hình bao gồm CNN-RNN và AM. Phương pháp giúp đơn giản hóa quá trình chẩn đoán lỗi trực tiếp từ tín hiệu điện. Zhang và cộng sự [18] sử dụng 1DCNN-LSTM với AM và học chuyển tiếp (transfer learning) trong xác định hư hỏng trong hệ thống lái điện thủy lực bằng cáp (Electro-hydraulic Steer-by-Wire), đạt độ chính xác 94% cho lỗi cơ điện và 92% cho lỗi cơ thủy lực, cải thiện khả năng chẩn đoán trong các điều kiện khó khăn.

Trong nghiên cứu này, chúng tôi đề xuất kết hợp CA với 1DCNN cho bài toán phân loại các trường hợp hư hỏng từ dữ liệu gia tốc đo đặc theo thời gian. Mạng 1DCNN học được các đặc trưng cục bộ hữu ích, trong khi cơ chế CA cải thiện điều này bằng cách tập trung vào các kênh đặc trưng quan trọng nhất, từ đó nâng cao hiệu suất của mô hình. Bài báo gồm 4 phần chính: phần 1 trình bày tổng quan về việc áp dụng mô hình học sâu trong nhiều lĩnh vực cùng với ưu điểm của AM. Tiếp theo, phần 2 sẽ mô tả chi tiết mô hình đề xuất 1DCNN-CA. Đánh giá hiệu quả của mô hình đề xuất áp dụng với dữ liệu gia tốc trên khung thép trong phần 3. Cuối cùng là các kết luận về nội dung nghiên cứu.

## 2. MÔ HÌNH 1DCNN-CA

### 2.1. Mạng nơ ron tích chập một chiều

1DCNN là một phương pháp học sâu đặc biệt hiệu quả trong xử lý dữ liệu chuỗi hoặc tín hiệu một chiều trong nhiều lĩnh vực, như âm thanh, tài chính, y tế, và dữ liệu thu được từ các cảm biến trong hệ thống SHM. 1DCNN có khả năng trích xuất các đặc trưng quan trọng từ dữ liệu, giúp tăng cường hiệu suất phân tích và dự đoán. Lớp tích chập hoạt động bằng việc sử dụng một bộ lọc (filter) chạy dọc theo chiều của chuỗi dữ liệu (Hình 1). Ngoài ra, mô hình 1DCNN còn các thành phần khác bao gồm:


- Lớp gộp (pooling layer): có vai trò giảm chiều kích thước của dữ liệu để giảm số lượng tham số tính toán đồng thời giữ lại các đặc trưng quan trọng.
- Hàm kích hoạt: thêm tính phi tuyến vào quá trình huấn luyện sau mỗi lớp tích chập, bao gồm một số hàm phổ biến được biểu diễn qua các công thức (1), (2) và (3):

$$ReLU (Rectified Linear Unit): f(x) = \max(0, x) \quad (1)$$

$$Sigmoid: f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$Tanh: \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

- Lớp kết nối đầy đủ (dense hoặc fully connected layer): Tất cả các nơ-ron từ các lớp trước đó đều được kết nối với các nơ-ron trong lớp này, cho phép tổng hợp và trích xuất thông tin để đưa ra kết quả dự đoán cuối cùng.
- Hàm mất mát (loss function): Được sử dụng để đánh giá hiệu quả của mô hình bằng cách đo lường sự sai khác giữa dự đoán của mô hình và giá trị thực tế.
- Thuật toán tối ưu: thuật toán Adam được sử dụng để huấn luyện mạng nơ-ron học sâu có khả năng tự điều chỉnh tỷ lệ học tập (learning rate) cho mỗi tham số.



Hình 1. Cấu trúc mạng 1DCNN với 2 lớp tích chập cho dữ liệu thời gian.

## 2.2. Cơ chế chú ý kênh (CA)

CA là một thành phần quan trọng trong các mô hình mạng học sâu giúp làm nổi bật các đặc trưng quan trọng giữa các kênh dữ liệu đầu vào. Trong mô hình 1DCNN, CA tập trung vào các kênh quan trọng trong dữ liệu chuỗi thời gian, chẳng hạn như các đặc trưng đã được trích xuất từ các lớp tích chập. Nghiên cứu này triển khai mô-đun CA với tỷ lệ giảm chiều (compression ratio) là 8, nhằm giảm thiểu hiện tượng quá khớp (overfitting) và giảm bớt khối lượng tính toán. Sau đó, hai lớp dense được xây dựng để phân chia bộ dữ liệu gia tốc theo thời gian thành hai lớp, và quá trình gộp dữ liệu được thực hiện bằng hai phương pháp (trung bình và cực đại).

Ý tưởng cốt lõi nằm ở việc tính tổng đầu ra từ hai nhánh trên, sau đó áp dụng hàm kích hoạt sigmoid để tạo ra các trọng số cho từng đặc trưng. Các trọng số này được nhân với đầu vào nhằm tạo ra đầu ra đã được chú ý theo mức độ quan trọng của từng kênh trong chuỗi dữ liệu. Điều này giúp mô hình tập trung vào các đặc trưng quan trọng hơn, tối ưu hóa hiệu suất xử lý và phân tích dữ liệu.


## 2.3. Mô hình đề xuất 1DCNN-CA

Mô hình được khởi tạo với lớp tích chập 1 chiều (Conv1D) sử dụng 16 bộ lọc với kích thước 3 và hàm kích hoạt ReLU. Các đặc trưng trích xuất từ bộ dữ liệu gia tốc được tổng hợp qua cơ chế chú ý (attention), giúp mô hình tập trung vào các kênh dữ liệu quan trọng. Để hạn chế hiện tượng quá khớp, hệ số dropout 0,5 được thêm vào, ngẫu nhiên loại bỏ 50% số lượng nơ-ron trong quá trình huấn luyện. Lớp flatten chuyển đổi dữ liệu từ dạng 2 chiều thành dạng 1 chiều, chuẩn bị cho lớp dense kế tiếp. Trong lớp dense, số nơ-ron được chọn bằng số nhân và sử dụng hàm softmax để tính xác suất cho từng lớp. Thuật toán Adam được sử dụng để tối ưu hóa quá trình huấn luyện qua 100 vòng lặp.

## 3. ÁP DỤNG VÀ ĐÁNH GIÁ KẾT QUẢ

### 3.1. Giới thiệu chung về bộ dữ liệu

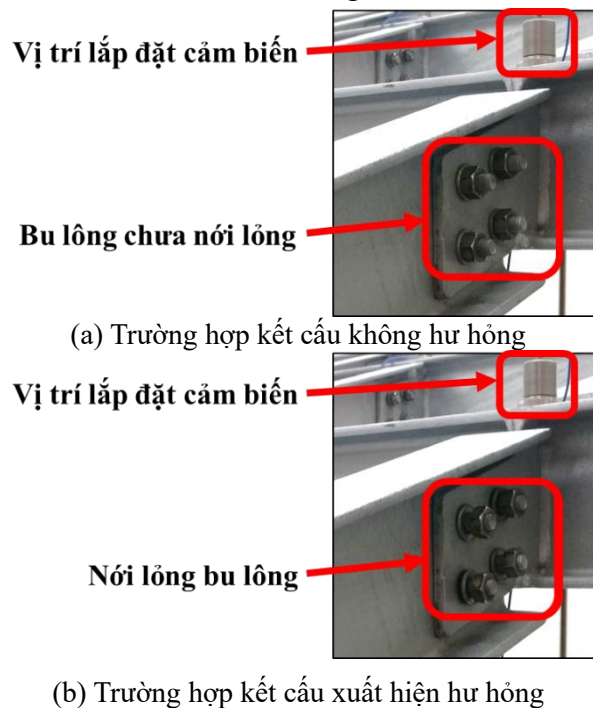
Nghiên cứu này sử dụng bộ dữ liệu gia tốc QUGS [19], một bộ dữ liệu quy mô lớn được phát triển nhằm mục đích nghiên cứu, phát triển và thử nghiệm các phương pháp SHM. Mô hình kết cấu trong QUGS trong Hình 2 [20] là một khung thép được thiết kế với kích thước là  $4,2m \times 4,2m$ . Kết cấu này bao gồm 8 dầm chính và 25 dầm ngang, được đỡ bởi 4 cột. Các dầm chính có chiều dài 4,6 m, 5 dầm ngang ở phần hẫng có chiều dài khoảng 1m và 20 dầm ngang còn lại có chiều dài 77 cm. Hai cột chính có chiều dài khoảng 1,65 m.



Hình 2. Kết cấu khung thép và tên điểm đo [20].

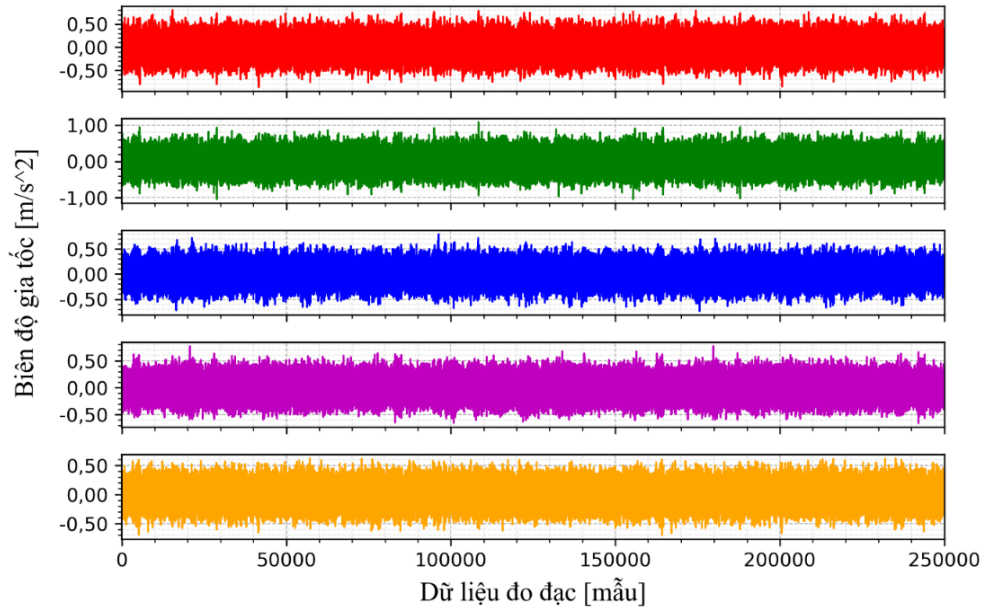
Kết cấu khung thép bao gồm 30 mối nối giữa các dầm chính và dầm phụ. Tương ứng với 30 vị trí đó cần sử dụng 30 cảm biến gia tốc, trong đó bao gồm 27 cảm biến PCB model 393B04 và 3 cảm biến B&K model 8344, được lắp đặt tại các mối nối trên dầm chính. Việc thu thập dữ liệu được thực hiện bằng hai thiết bị thu thập dữ liệu 16 kênh, đảm bảo khả năng thu thập tín hiệu đầu ra từ các cảm biến gia tốc. Hư hỏng kết cấu được mô phỏng bằng việc nối lỏng các bu lông tại các mối nối dầm với dầm trong Hình 2. Bộ dữ liệu được bao gồm 31 kịch bản:

- Kịch bản đầu tiên với trường hợp tham chiếu (không hư hỏng) có nhãn là “0”.
- Trong các kịch bản có nhãn từ “1” đến “30”, hư hỏng (Hình 3) lần lượt được đưa ra ở các vị trí mối nối có nhãn từ 1 đến 30 trong Hình 2.



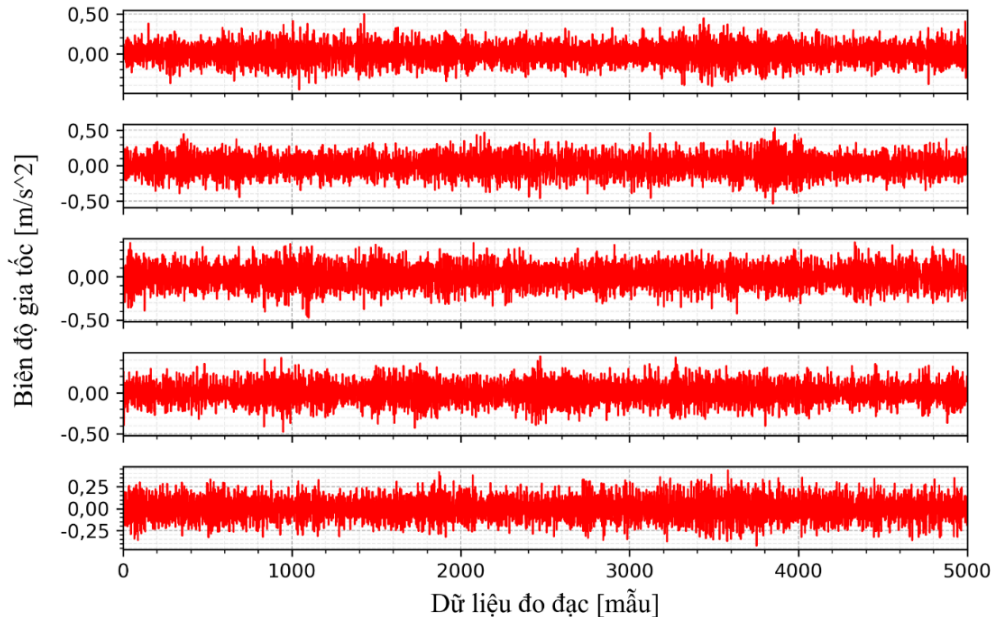
Hình 3. Hư hỏng giả định nối lỏng các bu lông [20].





Hình 4. Dữ liệu đo đạc gốc [20].

Trong từng kịch bản, các tín hiệu gia tốc được thu thập từ 30 cảm biến dưới tác động kích thích của bộ tạo dao động, với tần số lấy mẫu là 1024 Hz. Tín hiệu được thu thập trong khoảng thời gian 256 giây, do đó, mỗi tín hiệu bao gồm  $1024 \times 256 = 262144$  mẫu dữ liệu. Do đó, bộ dữ liệu sử dụng có dạng: 31 (trường hợp)  $\times$  30 (cảm biến)  $\times$  262144 (mẫu). Để cải thiện tốc độ cũng như hiệu quả trong quá trình huấn luyện, độ dài của từng đặc trưng chỉ lấy 250000 (mẫu) đảm bảo chia đều thành 50 đoạn nhỏ có độ dài ngắn hơn là 5000 (mẫu). Cuối cùng, bộ dữ liệu huấn luyện có cấu trúc: 930 (tập)  $\times$  50 (đặc trưng)  $\times$  5000 (mẫu). Hình 4 biểu diễn dữ liệu của 5 trong số 30 cảm biến thu thập cho 1 trường hợp. Dữ liệu sau đó được chia thành nhiều đoạn nhỏ có độ dài 5000 (mẫu) và thể hiện trong Hình 5.

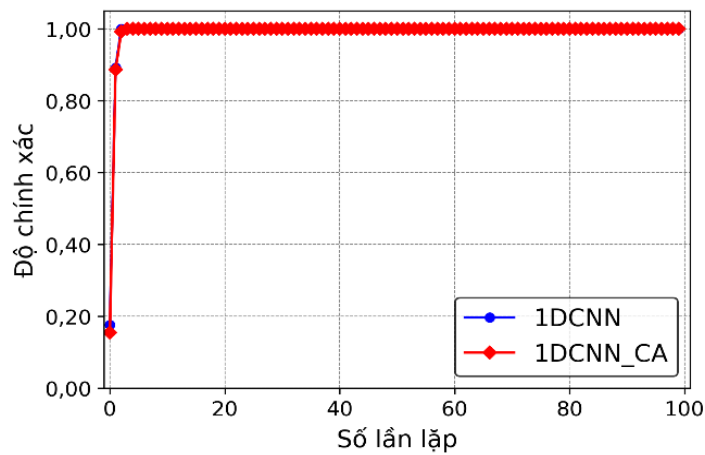


Hình 5. Dữ liệu đo đạc đã được chia thành các đoạn ngắn.

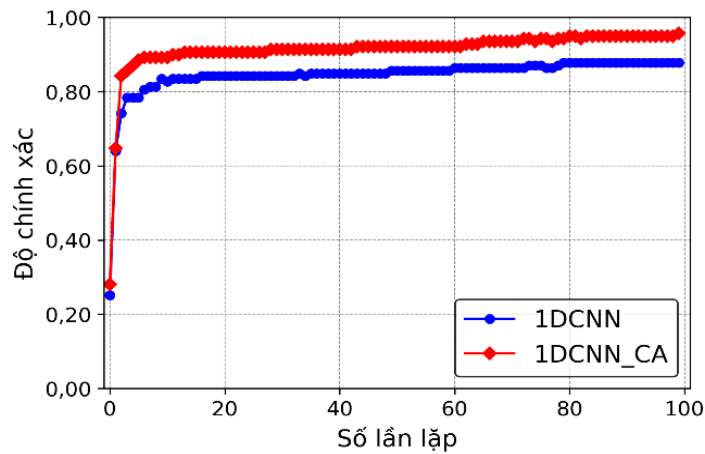
### 3.2. Huấn luyện và đánh giá kết quả

Quá trình huấn luyện dữ liệu được thực hiện trên máy trạm có bộ xử lý (central processing unit - CPU) loại Intel(R) Xeon(R) Gold 6138 với 40 lõi (Cores) có tốc độ xung nhịp là 2.00GHz. CPU Intel Xeon Gold 6138 là một trong những dòng CPU cao cấp của Intel, được thiết kế đặc biệt cho các máy chủ và máy trạm. Bộ nhớ (random access memory - RAM) tương đương 262144MB (262GB). Ngoài ra, máy còn được lắp đặt card màn hình NVIDIA GeForce RTX 4090 với 16354 nhân CUDA giúp tăng tốc độ tính toán của mô hình. Với hệ thống này có thể xử lý khối lượng dữ liệu lớn và chạy nhiều tác vụ đồng thời mà không gặp vấn đề về bộ nhớ.

Để đánh giá sự cải thiện của phương pháp đề xuất, kết quả của mô hình sử dụng cơ chế chú ý kênh (1DCNN-CA) được so sánh với mô hình 1DCNN với cùng bộ dữ liệu và các thông số như đề cập trong phần 2.3. Trong đó, tập huấn luyện chiếm 70% trong 930 mẫu (651 mẫu), 15% cho tập xác thực (139 mẫu) và còn lại 140 mẫu thuộc tập kiểm tra. Quá trình phân chia mẫu được thực hiện một cách ngẫu nhiên.



(a) Tập huấn luyện



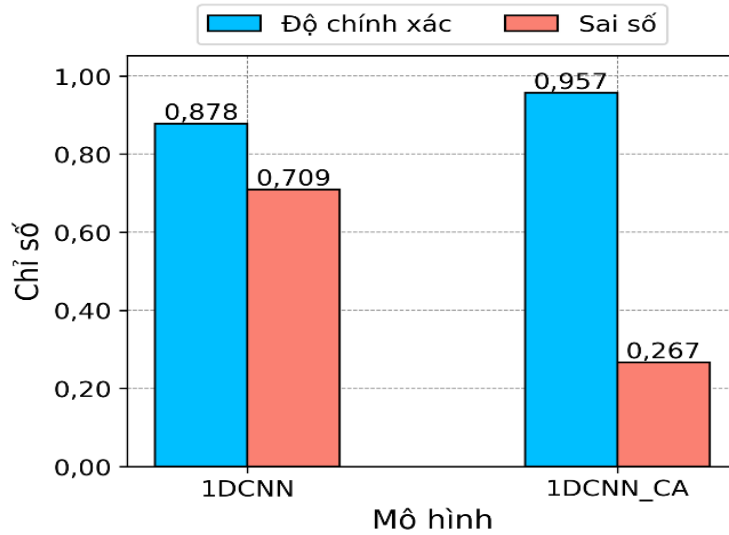
(b) Tập xác thực

Hình 6. Độ chính xác trong quá trình huấn luyện.


Hình 6 thể hiện độ chính xác của 2 mô hình 1DCNN và 1DCNN-CA trong quá trình huấn luyện sau 100 lần lặp. Cách tính toán chỉ số này có thể tham khảo thêm trong các tài liệu [3,10,11]. Với tập dữ liệu huấn luyện chiếm 70%, độ chính xác của cả 2 mô hình trong Hình 6a đạt độ chính xác gần như tuyệt đối 100% chỉ sau khoảng 5 lần lặp. Cho thấy với bộ dữ liệu sử dụng có chất lượng tốt và hiệu quả của 2 mô hình sử dụng các lớp tích chập. Hình 6b thể hiện mô hình 1DCNN-CA có hiệu suất tốt hơn mô hình 1DCNN trên tập xác thực trong toàn bộ quá



trình huấn luyện.



(a) Tập xác thực



(b) Tập kiểm tra

Hình 7. Kết quả đánh giá mô hình.

Độ chính xác và sai số mất mát (Loss) cuối cùng của các mô hình được tổng hợp trong Hình 7. Hình 7a là các kết quả tại vòng lặp thứ 100 trong quá trình huấn luyện khi đánh giá với tập xác thực. Cụ thể, mô hình 1DCNN đạt độ chính xác là 0,878 và sai số là 0,709, với kết quả này có thể phân loại tương đối tốt được các tập dữ liệu với các nhãn tương ứng. Với mô hình 1DCNN-CA có kết quả vượt trội khi đạt độ chính xác tới 95,7% (vượt khoảng 9% so với mô hình 1DCNN) và sai số chỉ là 0,267, giá trị này chỉ bằng khoảng 37% sai số từ mô hình 1DCNN. Từ những kết quả nêu trên có thể thấy trong quá trình huấn luyện, hiệu quả của mô hình đề xuất là tốt hơn đáng kể so với mô hình 1DCNN.

Đối với tập kiểm tra trong Hình 7b, mô hình đề xuất 1DCNN-CA vẫn cho thấy hiệu suất vượt trội hơn so với 1DCNN truyền thống. Cụ thể, độ chính xác của 1DCNN-CA là 0,936, và sai số là 0,269. Trong khi đó độ chính xác và sai số của 1DCNN là 0,893 và 0,586.



#### 4. KẾT LUẬN

Bài báo này đề xuất việc sử dụng cơ chế chú ý kênh vào mô hình 1DCNN truyền thống. Cơ chế chú ý kênh cho phép mô hình tập trung vào các đặc trưng quan trọng trong quá trình huấn luyện, từ đó cải thiện hiệu suất của mô hình. Bộ dữ liệu khung thép QUGS được sử dụng để đánh giá phương pháp này, với dữ liệu thu thập từ các cảm biến gia tốc lắp đặt trên kết cấu. Các cảm biến đo đặc trong cả tình huống kết cấu bình thường và khi giả định hư hỏng bằng cách nối lỏng bu lông liên kết tại các vị trí liên kết. Dựa trên kết quả thu được từ quá trình huấn luyện và kiểm tra, một số kết luận quan trọng đã được rút ra:

- Mô hình học sâu như 1DCNN có khả năng phân loại tốt các tập dữ liệu gia tốc theo thời gian. Cơ chế chú ý kênh cải thiện đáng kể hiệu năng của mô hình khi được thiết kế phù hợp và đặt sau các lớp tích chập.
- Mô hình đề xuất 1DCNN-CA có hiệu suất ổn định và vượt trội hơn với mô hình 1DCNN truyền thống trong quá trình huấn luyện về độ chính xác và sai số.
- Kết quả kiểm tra khẳng định phương pháp kết hợp 1DCNN với cơ chế chú ý kênh có độ chính xác cao với 0,936 và sai số chỉ là 0,269. Mô hình 1DCNN truyền thống chỉ đạt độ chính xác là 0,893.
- Kết quả từ bài báo này hứa hẹn là một phương pháp hiệu quả khi áp dụng các cơ chế chú ý trong các mô hình học sâu để cải thiện độ chính xác trong các bài toán nhận dạng, phân loại hư hỏng kết cấu từ dữ liệu theo thời gian thu được từ các cảm biến trong hệ thống giám sát sức khỏe kết cấu.

#### LỜI CẢM ƠN

Nghiên cứu này được tài trợ bởi Quỹ Phát triển khoa học và công nghệ Quốc gia (NAFOSTED) trong đề tài mã số NCUD.02-2022.18.

#### TÀI LIỆU THAM KHẢO

- [1]. Phạm Hồng Quân, Hồ Xuân Nam, Mai Đức Anh, Nguyễn Thị Cẩm Nhung, Chẩn đoán hư hỏng cầu giàn thép sử dụng mạng hồi quy cải tiến dựa trên mô hình số được cập nhật từ dữ liệu thu được từ cảm biến quang, Tạp chí Khoa học Giao thông vận tải, 75 (2024) 2000–2014. <https://doi.org/10.47869/tcsj.75.6.6>
- [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) 106368. <https://doi.org/10.1016/j.istruc.2024.106368>
- [3]. T. Le-Xuan, T. Bui-Tien, H. Tran-Ngoc, A novel approach model design for signal data using 1DCNN combing with LSTM and ResNet for damaged detection problem, Structures, 59 (2024) 105784. <https://doi.org/10.1016/j.istruc.2023.105784>
- [4]. O. Avci, O. Abdeljaber, S. Kiranyaz, M. Hussein, D.J. Inman, Wireless and real-time structural damage detection: A novel decentralized method for wireless sensor networks, Journal of Sound and Vibration, 424 (2018) 158–172. <https://doi.org/10.1016/j.jsv.2018.03.008>
- [5]. O. Avci, O. Abdeljaber, S. Kiranyaz, D. Inman, Structural Damage Detection in Real Time: Implementation of 1D Convolutional Neural Networks for SHM Applications, In Proceedings of the 35th IMAC, A Conference and Exposition on Structural Dynamics, 2017 (2017) 49-54. <https://doi.org/10.1007/978-3-319-54109-9>
- [6]. S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci, M. Gabbouj, 1-D Convolutional Neural Networks for Signal Processing Applications, ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 12-17 (2019) 8360-8364. <https://doi.org/10.1109/ICASSP.2019.8682194>

- [7]. O. Abdeljaber, O. Avci, M.S. Kiranyaz, B. Boashash, H. Sodano, D.J. Inman, 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data, *Neurocomputing*, 275 (2018) 1308–1317. <https://doi.org/10.1016/j.neucom.2017.09.069>
- [8]. O. Avci, O. Abdeljaber, S. Kiranyaz, D. Inman, Convolutional Neural Networks for Real-Time and Wireless Damage Detection, Shamim Pakzad, *Proceedings of the 37th IMAC, A Conference and Exposition on Structural Dynamics*, 2019 (2019) 129-136. [https://doi.org/10.1007/978-3-030-12115-0\\_17](https://doi.org/10.1007/978-3-030-12115-0_17)
- [9]. H. Fathnejat, B. Ahmadi-Nedushan, S. Hosseinijad, M. Noori, W.A. Altabey, A data-driven structural damage identification approach using deep convolutional-attention-recurrent neural architecture under temperature variations, *Engineering Structures*, 276 (2023) 115311. <https://doi.org/10.1016/j.engstruct.2022.115311>
- [10]. H. Tran-Ngoc, Q. Nguyen-Huu, T. Nguyen-Chi, T. Bui-Tien, Enhancing damage detection in truss bridges through structural stiffness reduction using 1DCNN, BiLSTM, and data augmentation techniques, *Structures* 68 (2024) 107035. <https://doi.org/10.1016/j.istruc.2024.107035>
- [11]. T. Bui-Tien, T. Nguyen-Chi, T. Le-Xuan, H. Tran-Ngoc, Enhancing bridge damage assessment: Adaptive cell and deep learning approaches in time-series analysis, *Construction and Building Materials*, 439 (2024) 137240. <https://doi.org/10.1016/j.conbuildmat.2024.137240>
- [12]. Z. Niu, G. Zhong, H. Yu, A review on the attention mechanism of deep learning, *Neurocomputing*, 452 (2021) 48–62. <https://doi.org/10.1016/j.neucom.2021.03.091>
- [13]. X. Zhao, M. Bai, X. Yang, J. Liu, D. Yu, J. Chang, Short-term probabilistic predictions of wind multi-parameter based on one-dimensional convolutional neural network with attention mechanism and multivariate copula distribution estimation, *Energy*, 234 (2021) 121306. <https://doi.org/10.1016/j.energy.2021.121306>
- [14]. K. Wang, C. Ma, Y. Qiao, X. Lu, W. Hao, S. Dong, A hybrid deep learning model with 1DCNN-LSTM-Attention networks for short-term traffic flow prediction, *Physica A: Statistical Mechanics and Its Applications*, 583 (2021) 126293. <https://doi.org/10.1016/j.physa.2021.126293>
- [15]. H. Hu, Y. Mei, Y. Wei, Z. Xu, Y. Zhao, H. Xu, X. Mao, L. Huang, Chemical composition prediction in goji (*Lycium barbarum*) using hyperspectral imaging and multi-task 1DCNN with attention mechanism, *LWT*, 204 (2024) 116436. <https://doi.org/10.1016/j.lwt.2024.116436>
- [16]. X. Zhang, C. He, Y. Lu, B. Chen, L. Zhu, L. Zhang, Fault diagnosis for small samples based on attention mechanism, *Measurement*, 187 (2022) 110242. <https://doi.org/10.1016/j.measurement.2021.110242>
- [17]. T.-T. Vo, M.-K. Liu, M.-Q. Tran, Harnessing attention mechanisms in a comprehensive deep learning approach for induction motor fault diagnosis using raw electrical signals, *Engineering Applications of Artificial Intelligence*, 129 (2024) 107643. <https://doi.org/10.1016/j.engappai.2023.107643>
- [18]. S. Zhang, W. Liang, W. Zhao, Z. Luan, C. Wang, K. Xu, Electro-hydraulic SBW fault diagnosis method based on novel 1DCNN-LSTM with attention mechanisms and transfer learning, *Mechanical Systems and Signal Processing*, 220 (2024) 111644. <https://doi.org/10.1016/j.ymsp.2024.111644>
- [19]. Structural Dynamics Team, A New Experimental Benchmark Problem for Vibration-Based Structural Health Monitoring (SHM). <https://www.structuralvibration.com/benchmark/>, 2018, truy cập ngày 20 tháng 08 năm 2024.
- [20]. O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, D.J. Inman, Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks, *Journal of Sound and Vibration*, 388 (2017) 154–170. <https://doi.org/10.1016/j.jsv.2016.10.043>