

CHẨN ĐOÁN HƯ HỎNG TRONG KẾT CẤU KHUNG KHÔNG GIAN SỬ DỤNG KẾT HỢP GIỮA DẠNG DAO ĐỘNG VÀ MẠNG NƠ-RON TÍCH CHẬP

Bạch Văn Sỹ^{a,b}, Lê Thanh Cao^b, Đỗ Huỳnh Như^b, Phạm Bá Linh^b, Hồ Đức Duy^{a,*}

^aKhoa Kỹ thuật Xây dựng, Trường Đại học Bách khoa, Đại học Quốc gia Thành phố Hồ Chí Minh,
268 Lý Thường Kiệt, Phường Diên Hồng, TP. Hồ Chí Minh, Việt Nam

^bKhoa Xây dựng, Trường Đại học Nha Trang, 2 Nguyễn Đình Chiểu,
phường Bắc Nha Trang, Khánh Hòa, Việt Nam

Nhận ngày 18/12/2025, Sửa xong 16/4/2026, Chấp nhận đăng 20/4/2026

Tóm tắt

Bài báo này đề xuất quy trình một bước để chẩn đoán vị trí và mức độ hư hỏng cho kết cấu khung không gian bằng cách sử dụng kết hợp dữ liệu dạng dao động và thuật toán học sâu. Đầu tiên, dữ liệu dạng dao động được thu thập qua phân tích dao động của kết cấu khung bằng phương pháp phần tử hữu hạn. Tiếp theo, mạng nơ-ron tích chập một chiều (1D-CNN) được xây dựng nhằm trích lọc, học đặc trưng dạng dao động và dự đoán đồng thời vị trí cũng như mức độ hư hỏng của các phần tử kết cấu. Để đánh giá hiệu quả quy trình đề xuất, ba dạng dao động của một kết cấu khung không gian gồm 52 phần tử và 30 nút được sử dụng làm dữ liệu đầu vào cho quá trình huấn luyện. Mạng 1D-CNN được huấn luyện với hai tập dữ liệu: (i) HL1 – dữ liệu dạng dao động với đầy đủ bậc tự do của mỗi nút, và (ii) HL2 – dữ liệu chỉ gồm các bậc tự do tịnh tiến. Kết quả huấn luyện cho thấy mô hình đạt hệ số R^2 từ 98-99% trên tập huấn luyện và 95-98% trên tập kiểm tra tương ứng với hai tập dữ liệu được khảo sát. Việc khảo sát 5 trường hợp hư hỏng khác nhau cho thấy dữ liệu HL2 cho kết quả tương đương với HL1 khi chẩn đoán chính xác vị trí hư hỏng và độ chính xác dự đoán mức độ hư hỏng từ 95-97%.

Từ khóa: chẩn đoán hư hỏng; dạng dao động; khung không gian; mạng nơ-ron tích chập; học sâu.

DAMAGE DETECTION IN SPATIAL FRAME STRUCTURES USING MODE SHAPES AND CONVOLUTIONAL NEURAL NETWORKS

Abstract

This paper proposes a one-step damage detection approach for spatial frame structures by integrating mode shape data with deep learning algorithms. Firstly, the mode shapes of the frame are obtained from vibration analysis using the finite element method. Secondly, a one-dimensional convolutional neural network (1D-CNN) is constructed to extract and learn the modal features and to simultaneously predict both the location and the severity of damage in structural elements. To evaluate the effectiveness of the proposed approach, the first three vibration modes of a spatial frame consisting of 52 elements and 30 nodes are used as input data for training. The 1D-CNN is trained with two datasets: (i) HL1 – modal data containing the full degrees of freedom at each node, and (ii) HL2 – modal data including only the translational degrees of freedom. The training results show that the model achieves R^2 values of 98-99% on the training set and 95-98% on the test set for the two datasets, respectively. Furthermore, an investigation of five damage scenarios indicates that HL2 yields performance comparable to HL1 in accurately identifying damage locations and predicting damage severity with an accuracy of 95-97%.

Keywords: damage detection; mode shape; spatial frame; convolutional neural network; deep learning.

[https://doi.org/10.31814/stce.huce2026-20\(2V\)-03](https://doi.org/10.31814/stce.huce2026-20(2V)-03) © 2026 Trường Đại học Xây dựng Hà Nội (ĐHXDHN)

1. Giới thiệu

Trong quá trình khai thác và sử dụng, kết cấu công trình luôn chịu tác động của các yếu tố bất lợi từ môi trường và hoạt động của con người như: vật liệu bị lão hóa theo thời gian, bị ăn mòn bởi các điều kiện môi trường hoặc tải trọng vượt quá giới hạn cho phép. Những tác động này làm suy giảm khả năng chịu lực và gây ra các dạng hư hỏng không mong muốn trên kết cấu. Do đó, việc theo dõi liên tục trạng thái làm việc của kết cấu là hết sức cần thiết nhằm kịp thời phát hiện các hư hỏng tiềm tàng. Để đáp ứng yêu cầu này, nhiều kỹ thuật đã được phát triển trong lĩnh vực theo dõi và chẩn đoán kết cấu (Structural Health Monitoring: SHM), bao gồm các phương pháp chẩn đoán phá hủy và không

*Tác giả đại diện. Địa chỉ e-mail: hoducduy@hcmut.edu.vn (Duy, H. Đ.)

phá hủy. Trong đó, các phương pháp không phá hủy nhận được nhiều sự quan tâm vì đảm bảo tính nguyên vẹn của kết cấu cần kiểm tra, giám sát. Một số kỹ thuật không phá hủy thông dụng có thể kể đến như: phương pháp siêu âm, phương pháp ảnh nhiệt và phương pháp dựa trên đặc trưng dao động. Nhờ khả năng nhanh chóng phát hiện vị trí hư hỏng của phương pháp không phá hủy, các phương pháp chẩn đoán truyền thống trước đây thường dựa vào sự thay đổi đặc trưng dao động trước và sau khi hư hỏng để khoanh vùng và định lượng mức độ hư hỏng của các phần tử. Điển hình là các nghiên cứu như: dựa vào sự thay đổi của tần số dao động, dạng dao động, độ cong dạng dao động và năng lượng biến dạng [1–5]. Hầu hết các nghiên cứu đều cho thấy rằng sự thay đổi đặc trưng dao động có thể khoanh vùng tốt vị trí hư hỏng nhưng gặp khó khăn trong việc định lượng chính xác mức độ hư hỏng. Do đó, một số nghiên cứu sau này đã đề xuất áp dụng kỹ thuật tối ưu hóa ngược trong quy trình chẩn đoán hai bước nhằm tăng cường khả năng phát hiện vị trí và định lượng mức độ hư hỏng [6–10]. Quy trình hai bước rất hữu ích khi loại bỏ nhiều vị trí chẩn đoán thông qua định lượng mức độ hư hỏng của các phần tử nằm trong vùng hư hỏng tiềm năng, với bước hai đóng vai trò xác nhận kết quả chẩn đoán của bước một. Tuy nhiên, phương pháp phân tích đòi hỏi chi phí tính toán lớn, dữ liệu dao động phải đủ cả hai trạng thái kết cấu: trước và sau khi hư hỏng xuất hiện.

Trong thời gian gần đây, sự phát triển mạnh mẽ của trí tuệ nhân tạo đã thúc đẩy việc ứng dụng các thuật toán học máy vào trong lĩnh vực chẩn đoán hư hỏng kết cấu. Avcı và cộng sự [11] đã cho rằng các thuật toán học máy có khả năng nhận dạng chính xác vị trí và mức độ hư hỏng của kết cấu với dữ liệu huấn luyện sử dụng tần số dao động và dạng dao động thu thập từ mô phỏng phần tử hữu hạn hoặc thu thập qua quan trắc trực tiếp. Các mô hình học máy thường sử dụng trong huấn luyện và chẩn đoán gồm SVM, ANN, và XGBoost với dữ liệu là các đặc trưng dao động [12–14]. Bên cạnh đó, nhờ khả năng trích lọc đặc trưng mạnh mẽ trực tiếp từ dữ liệu thô, mạng nơ-ron tích chập (CNN) đang được nhiều tác giả nghiên cứu đề xuất áp dụng với cách thức triển khai khác nhau. Như nghiên cứu của Zhong và cộng sự đã sử dụng mạng CNN để trích lọc đặc trưng của dạng dao động thực hiện chẩn đoán hư hỏng của kết cấu dàn thép [15]. Nguyen và Abdel đã sử dụng chỉ số hư hỏng dựa vào sự khác biệt của độ cong dạng dao động theo hai phương của kết cấu ở trạng thái ban đầu và khi hư hỏng để làm dữ liệu huấn luyện cho mạng R-CNN thực hiện chẩn đoán hư hỏng cho kết cấu tấm [16]. Gần đây, một số nghiên cứu về việc kết hợp đặc trưng năng lượng biến dạng của kết cấu với mạng CNN cũng được đề xuất áp dụng, kết quả cho thấy mô hình có độ tin cậy cao trong chẩn đoán hư hỏng kết cấu như: nghiên cứu của Bui và cộng sự áp dụng cho đối tượng kết cấu tấm [17], Tran và cộng sự phân tích chẩn đoán trên cầu kiện dầm với điều kiện biên khác nhau [18].

2. Phương pháp

2.1. Dao động tự do của kết cấu

Dạng dao động của kết cấu là dạng biến dạng riêng hoặc mô hình chuyển động đặc trưng của kết cấu khi nó dao động tự do tại một tần số riêng xác định. Các dạng dao động này là nghiệm riêng của phương trình dao động tự do không cản, được biểu diễn bởi phương trình trị riêng [19]:

$$[\mathbf{K} - \omega_i^2 \mathbf{M}] \phi_i = 0, \quad (i = 1, \dots, ndof) \quad (1)$$

trong đó: \mathbf{K} , \mathbf{M} là ma trận độ cứng và ma trận khối lượng của kết cấu trong hệ tọa độ tổng thể; ω_i , ϕ_i là véc-tơ tần số dao động và véc-tơ dạng dao động riêng thứ i của kết cấu; $ndof$ là số lượng bậc tự do của kết cấu.

Khi kết cấu ở trạng thái hư hỏng, phương trình trị riêng của kết cấu có thể được biểu diễn bởi Eq. (2):

$$[\mathbf{K}^d - (\omega_i^d)^2 \mathbf{M}] \phi_i^d = 0, \quad (i = 1, \dots, ndof) \quad (2)$$

trong đó: d thể hiện trạng thái hư hỏng của kết cấu. Ở đây, giả thiết khối lượng của hệ kết cấu \mathbf{M} không thay đổi trước và sau khi hư hỏng. Do đó, hư hỏng của kết cấu được biểu thị thông qua sự suy giảm độ cứng tổng thể \mathbf{K} .

Với kết cấu có nhiều phần tử, ma trận độ cứng của phần tử thứ j khi hư hỏng có thể được biểu thị bởi công thức sau [18]:

$$\mathbf{K}_j^d = (1 - \alpha_j) \mathbf{K}_j, \quad \alpha_j \in [0, 1] \quad (3)$$

trong đó: \mathbf{K}_j, α_j là ma trận độ cứng của phần tử thứ j và mức độ suy giảm độ cứng tương ứng. Nghiên cứu này sử dụng dữ liệu dạng dao động của các trường hợp hư hỏng giả định khác nhau, dữ liệu được thu thập thông qua mô phỏng kết cấu bằng phương pháp phần tử hữu hạn sử dụng ngôn ngữ lập trình Python.

2.2. Mạng nơ-ron tích chập một chiều (1D-CNN)

Trong bài báo này, mạng nơ-ron tích chập một chiều (1D Convolutional Neural Network, 1D-CNN) được sử dụng để xây dựng mô hình chẩn đoán hư hỏng kết cấu dựa trên dạng dao động. Kiến trúc mô hình mạng 1D-CNN bao gồm các lớp tích chập, trong đó các bộ lọc trượt dọc theo dữ liệu đầu vào để thực hiện phép tích chập và trích xuất các đặc trưng cục bộ. Các đặc trưng này sau đó được đưa qua các lớp phi tuyến và các lớp kết nối đầy đủ để thực hiện quá trình phân loại hoặc hồi quy. Nhờ khả năng tự động trích xuất đặc trưng từ dữ liệu đầu vào, cùng với cơ chế kết nối cục bộ và chia sẻ trọng số, 1D-CNN có khả năng học đặc trưng hiệu quả với số lượng tham số giảm đáng kể so với các mô hình truyền thống. Tuy nhiên, 1D-CNN cũng tồn tại hạn chế như mô hình phụ thuộc vào thứ tự sắp xếp của dữ liệu đầu vào [20]. Với lĩnh vực chẩn đoán hư hỏng kết cấu, dữ liệu đầu vào thường là các đáp ứng dao động hoặc các véc-tơ dạng dao động được sắp xếp theo thứ tự không gian. Các nghiên cứu trước đây đã chỉ ra rằng 1D-CNN có thể trực tiếp khai thác các dạng dữ liệu này mà không cần bước trích chọn đặc trưng thủ công, đồng thời đạt độ chính xác cao trong việc phát hiện và định vị hư hỏng [21–23].

a. Kiến trúc mạng

Mạng 1D-CNN được xây dựng dựa vào thư viện Pytorch với các tham số của mô hình được trình bày trong Bảng 1 và kiến trúc mạng được minh họa ở Hình 2. Các tham số của mô hình được lựa chọn thông qua quá trình thử và sai liên tục nhằm đạt được độ chính xác chẩn đoán tốt nhất với chi phí tính toán thấp nhất. Dữ liệu đầu vào của mô hình gồm ba dạng dao động của kết cấu khung, mỗi mẫu dữ liệu gồm 432 đặc trưng đối với tập HL1 (đầy đủ bậc tự do) hoặc 216 đặc trưng đối với tập HL2 (chỉ gồm bậc tự do tịnh tiến). Các đặc trưng này được sắp xếp thành một chuỗi một chiều và đưa trực tiếp vào mạng CNN để thực hiện quá trình huấn luyện và dự đoán như sau: Với mỗi trường hợp hư hỏng, ba dạng dao động được tính toán từ phân tích trị riêng. Mỗi dạng dao động cho một véc-tơ giá trị chuyển vị tại tất cả các bậc tự do của kết cấu. Véc-tơ đặc trưng đầu vào được xây dựng bằng cách nối tiếp ba véc-tơ dạng dao động theo thứ tự:

$$x = \{\phi_1, \phi_2, \phi_3\} \quad (4)$$


Trong mỗi véc-tơ $\{\phi_i\}$ được sắp xếp theo thứ tự từ nút 1 đến nút 30, và trong mỗi nút được sắp xếp theo thứ tự bậc tự do. Thứ tự sắp xếp này tuân theo logic không gian của kết cấu: các nút được đánh số theo tọa độ từ dưới lên trên và từ trong ra ngoài trong mô hình phần tử hữu hạn, bảo đảm rằng các nút lân cận về mặt hình học cũng nằm gần nhau trong chuỗi đầu vào. Điều này tạo điều kiện thuận lợi để các bộ lọc tích chập nhận diện các mẫu dữ liệu có tính liên tục không gian.

Bảng 1. Tham số kiến trúc mạng

Đầu vào	Batch size	Bộ lọc	Kích thước bộ lọc	Lớp kết nối đầy đủ + BN + Dropout	Hàm kích hoạt	Dropout	Đầu ra
432*/216**	256	300	432/216	1500 – 1500 – 1000 – 500	ELU	1%	52


Ghi chú: */** - tương ứng với dữ liệu với đầy đủ bậc tự do (HL1) và dữ liệu chỉ xét bậc tự do tịnh tiến (HL2).

Kiến trúc mạng sử dụng một lớp tích chập Conv1D duy nhất với 300 bộ lọc. Kích thước bộ lọc được chọn bằng đúng chiều dài chuỗi đầu vào (432 hoặc 216), nhằm bảo đảm mỗi bộ lọc có thể quét trọn vẹn toàn bộ chuỗi dữ liệu của ba dạng dao động. Lựa chọn này giúp mô hình học được mẫu dữ liệu mang tính tổng thể, thay vì chỉ học đặc trưng cục bộ, giúp giảm chi phí huấn luyện mô hình nhưng vẫn đạt độ tin cậy cần thiết. Tiếp theo, hàm kích hoạt ELU (Hình 1) được sử dụng để xử lý tốt các giá trị âm có thể có của dữ liệu dạng dao động sau khi chuẩn hóa, tránh hiện tượng triệt tiêu thông tin như khi dùng ReLU.



Hình 1. Hàm kích hoạt ELU

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^x - 1), & x < 0 \end{cases} \quad (5)$$



Hình 2. Kiến trúc mạng 1D-CNN đề xuất

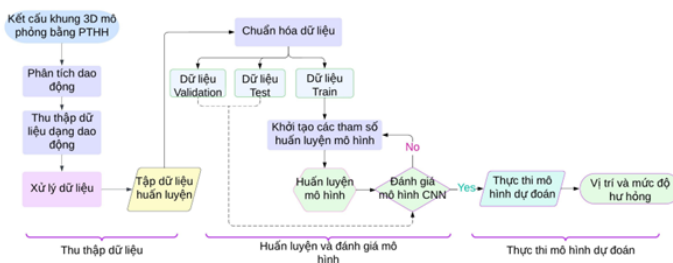
Đầu ra của lớp tích chập được đưa vào lớp tổng hợp nhằm giảm chiều dữ liệu và tăng tính ổn định trong quá trình huấn luyện. Dữ liệu sau đó được làm phẳng và truyền qua bốn lớp kết nối đầy đủ (FC) với số lượng nút lần lượt là 1500 - 1500 - 1000 - 500. Các lớp FC đảm nhiệm việc học quan hệ phi tuyến giữa đặc trưng dao động và mức độ suy giảm độ cứng của các phần tử trong khung. Để mô hình huấn luyện ổn định hơn, chuẩn hóa (BN) được sử dụng xen kẽ giữa các lớp FC nhằm chuẩn hóa phân phối đầu ra của mỗi lớp. Bên cạnh đó, Dropout với tỷ lệ 1% được dùng để hạn chế quá khớp và giảm nhiều dự đoán của mô hình. Lớp đầu ra có 52 nút, tương ứng với 52 phần tử của kết cấu khung. Mỗi giá trị trong véc-tơ đầu ra biểu diễn mức độ suy giảm độ cứng dự đoán của phần tử tương ứng, cho phép mô hình đồng thời xác định cả vị trí và mức độ hư hỏng trong một lần dự đoán. Kích thước luồng dữ liệu qua các lớp trong kiến trúc mạng đề xuất được tóm tắt trong Bảng 2.

Bảng 2. Kích thước luồng dữ liệu qua mạng

Lớp	Đầu vào	Tích chập	Tổng hợp	Làm phẳng	Kết nối đầy đủ	Đầu ra
Kích thước dữ liệu	(432/216, 1)	(1, 300)	(1, 300)	(300)	1500 - 1500 - 1000 - 500	(52)

b. Quy trình chẩn đoán đề xuất

Quy trình chẩn đoán hư hỏng kết cấu trong bài báo này được đề xuất như Hình 3, gồm ba giai đoạn chính: thu thập dữ liệu; huấn luyện và đánh giá mô hình; thực thi mô hình dự đoán. Đầu tiên, kết cấu khung được mô phỏng bằng phương pháp phần tử hữu hạn nhằm thực hiện phân tích dao động và thu thập dữ liệu dạng dao động. Dữ liệu sau đó được xử lý, chuẩn hóa và phân chia thành ba tập: huấn luyện (train), kiểm định (validation) và kiểm tra (test). Tiếp theo, mô hình mạng nơ-ron tích chập được khởi tạo và huấn luyện trên tập dữ liệu đã chuẩn hóa. Thuật toán tối ưu hóa Adam được sử dụng để cập nhật trọng số trong quá trình huấn luyện theo hướng giảm giá trị hàm mất mát. Toàn bộ quá trình cập nhật trọng số tuân theo cơ chế lan truyền ngược, trong đó sai số giữa đầu ra mô hình và giá trị mục tiêu được dùng để tính toán hàm mất mát trung bình bình phương. Bên cạnh đó, tốc độ học được thiết lập giảm dần theo số lần học nhằm cải thiện độ ổn định và tránh hiện tượng dao động ở giai đoạn cuối huấn luyện. Sau khi kết thúc quá trình huấn luyện (300 epochs), mô hình được đánh giá bằng các chỉ số định lượng gồm: Mean Absolute Error (MAE), Root Mean Square Error (RMSE) và hệ số xác định R^2 . Nếu các giá trị này chưa đạt yêu cầu trên tập kiểm định và tập kiểm tra, các siêu tham số sẽ được điều chỉnh và mô hình tiếp tục được huấn luyện lại. Khi mô hình đạt hiệu suất ổn định và tổng quát hóa tốt trên tập kiểm tra từ 95% trở lên, nó được triển khai vào giai đoạn cuối cùng để thực thi chẩn đoán vị trí và mức độ hư hỏng của kết cấu.




Hình 3. Quy trình chẩn đoán đề xuất

3. Bài toán phân tích

3.1. Dữ liệu khung không gian

Để xác thực quy trình chẩn đoán đề xuất, một mô hình phần tử hữu hạn của khung không gian được thiết lập nhằm mô phỏng các đặc trưng dao động của kết cấu. Hệ kết cấu bao gồm 52 phần tử và 30 nút (Hình 4), với các tham số vật liệu và hình học thể hiện trong Bảng 3. Năm trường hợp hư hỏng khác nhau, có từ một đến năm vị trí hư hỏng đồng thời, được mô tả trong Bảng 4. Các trường hợp hư hỏng này được sử dụng để đánh giá hiệu quả chẩn đoán của quy trình đề xuất.



Hình 4. Mô hình PTHH kết cấu khung không gian

Bảng 3. Đặc trưng hình học và thông số vật liệu


Kích thước hình học	
Chiều cao cột	3,2 m
Chiều dài dầm	4,5 m
Mặt cắt ngang cột	(0,25 × 0,25) m
Mặt cắt ngang dầm	(0,25 × 0,40) m
Thuộc tính vật liệu	
Mô đun đàn hồi	$27,5 \times 10^3$ MPa
Hệ số Poisson	0,2
Khối lượng	2500 kg/m ³

Bảng 4. Các trường hợp hư hỏng khảo sát

Trường hợp	1	2	3	4	5
Phần tử hư hỏng	23	27-41	1-14-21	8-19-24-29	10-19-31-33-34
Mức độ hư hỏng (%)	20	5-15	5-25-20	25-20-5-15	20-10-10-20-5

3.2. Dữ liệu huấn luyện

Quá trình phân tích dao động kết cấu khung thu được ba dạng dao động đầu tiên gồm 2 dạng dao động uốn và 1 dạng dao động xoắn (Hình 5). Các dạng dao động này được sử dụng để xây dựng cơ sở dữ liệu (CSDL) huấn luyện mô hình CNN với 32000 trường hợp hư hỏng khác nhau. Trong đó, vị trí hư hỏng là ngẫu nhiên và mức độ hư hỏng của các thanh trong từng trường hợp hư hỏng ngẫu nhiên trong khoảng từ 0% đến 50% với bước 0,1%. Đáng chú ý, tập huấn luyện này chỉ sử dụng dữ liệu của trạng thái hư hỏng, không sử dụng dữ liệu của trạng thái không hư hỏng ban đầu. Như vậy, ba dạng dao động đầu tiên của kết cấu sẽ tạo ra 432 đặc trưng của mẫu huấn luyện với đầy đủ bậc tự do (HL1) và 216 đặc trưng của mẫu huấn luyện chỉ với các bậc tự do chuyển vị tịnh tiến theo ba phương (HL2).



Hình 5. Ba dao động đầu tiên của kết cấu khung

Dữ liệu ba dạng dao động cho 32000 trường hợp hư hỏng khác nhau cho thấy thời gian xây dựng cơ sở dữ liệu (CSDL) khoảng 22 phút. Thời gian huấn luyện cho mỗi mô hình khoảng 8 phút. Để tăng độ ổn định của kết quả, mỗi mô hình được huấn luyện 3 lần độc lập, sau đó kết quả chẩn đoán cuối cùng được xác định bằng giá trị trung bình của 3 lần huấn luyện này. Quá trình xây dựng CSDL, huấn luyện mô hình và chẩn đoán hư hỏng được thực hiện trên máy tính cá nhân Dell Precision 3460 có cấu hình Core i7-12700 (2,10 GHz), Ram DDR5-16 GB, GPU Nvidia T1000-4 GB.

4. Kết quả và thảo luận

4.1. Huấn luyện và đánh giá mô hình

Trước khi huấn luyện, dữ liệu được chuẩn hóa để đưa tất cả các đặc trưng về thang đo tiêu chuẩn. Việc chuẩn hóa này cải thiện khả năng hội tụ của mô hình trong quá trình huấn luyện và giúp ngăn chặn các đặc trưng có trị số lớn chi phối quá trình huấn luyện do độ lớn không tương xứng của chúng. Dữ liệu sau khi được chuẩn hóa trải qua quá trình tích chập, tổng hợp và lớp kết nối đầy đủ. Quá trình huấn luyện sử dụng thuật toán tối ưu Adam với tốc độ học điều chỉnh theo từng epoch, kết hợp với hàm mất mát là trung bình bình phương lỗi (MSE) giữa giá trị thực và giá trị dự đoán.


Bảng 5. Kết quả huấn luyện mô hình CNN với epochs = 300

Dữ liệu huấn luyện	Tập dữ liệu huấn luyện			Tập dữ liệu kiểm tra		
	MAE	RMSE	R^2	MAE	RMSE	R^2
HL1	1.01	1.3	0.99	0.94	1.69	0.98
HL2	1.31	1.75	0.98	1.65	3.11	0.95


Kết quả huấn luyện của mô hình CNN với 300 epochs (Bảng 5) cho thấy mô hình có khả năng tổng quát tốt, thể hiện qua hệ số xác định R^2 luôn duy trì ở mức cao từ 0,95 đến 0,99 trên cả hai tập dữ liệu. Mô hình đặc biệt tối ưu trên HL1 khi đạt độ chính xác gần như tuyệt đối và rất ổn định, với chỉ số R^2 trên tập kiểm tra đạt 0,98 và sai số MAE rất thấp (0,94), chứng tỏ khả năng tổng quát hóa tốt trên tập dữ liệu chưa nhìn thấy và không xảy ra hiện tượng quá khớp trong quá trình huấn luyện. Với HL2, mặc dù mô hình vẫn đảm bảo độ tin cậy cao với R^2 trên tập kiểm tra là 0,95, nhưng đã xuất hiện sự chênh lệch đáng kể về sai số RMSE giữa quá trình huấn luyện (1,75) và kiểm tra (3,11). Điều này cho thấy mô hình với dữ liệu HL1 hiệu quả hơn, trong khi ở HL2 mô hình có dấu hiệu gặp khó khăn hơn trong huấn luyện khi số lượng đặc trưng ít hơn HL1.

4.2. Kết quả chẩn đoán vị trí hư hỏng


Kết quả chẩn đoán hư hỏng các trường hợp đề xuất được trình bày ở Hình 6. Kết quả cho thấy quy trình chẩn đoán đề xuất có thể chẩn đoán vị trí hư hỏng của các phần tử từ đơn hư hỏng tới đa hư hỏng với độ chính xác cao trong cả hai trường hợp dữ liệu. Trong mỗi trường hợp, những phần tử nào thực sự hư hỏng sẽ có giá trị mức độ hư hỏng (MĐHH) lớn hơn so với các phần tử còn lại. Để loại bỏ nhiễu vị trí khi chẩn đoán, ngưỡng hư hỏng $Z_{th} = 1,5\%$ được áp dụng. Theo đó, những phần tử có MĐHH vượt ngưỡng thì xem như hư hỏng, trong khi các phần tử còn lại được xem là không hư hỏng.




(a) Trường hợp 1




(b) Trường hợp 2



(c) Trường hợp 3



(d) Trường hợp 4



(e) Trường hợp 5

Hình 6. Kết quả chẩn đoán vị trí hư hỏng

4.3. Kết quả chẩn đoán mức độ hư hỏng

Bảng 6 đến Bảng 10 trình bày kết quả tính toán sai số chẩn đoán giữa mức độ hư hỏng thực tế và mức độ hư hỏng dự đoán được từ 2 mô hình huấn luyện sau khi vị trí hư hỏng được chẩn đoán chính xác. Nhìn chung, mô hình được huấn luyện bởi dữ liệu HL2 có độ chính xác dự đoán tương đương với huấn luyện trên dữ liệu HL1. Điều này cho thấy bậc tự do chuyển vị xoay mang ít thông tin hư hỏng hơn là bậc tự do chuyển vị tịnh tiến, do đó, loại bỏ đặc trưng bậc tự do chuyển vị góc xoay trong HL2 không ảnh hưởng nhiều đến khả năng xác định vị trí cũng như mức độ hư hỏng của phần tử trên kết cấu. Cụ thể, với mô hình HL1 có sai số chẩn đoán trung bình (Avg) cho trường hợp đa hư hỏng dao động trong khoảng từ 2,6% đến 2,8%, tương ứng với các trường hợp hư hỏng từ 2 phần tử đến 5 phần tử. Trong khi đó, mô hình HL2 với số lượng đặc trưng huấn luyện ít hơn cho kết quả chẩn đoán với sai số lớn hơn (từ 3,9% đến 4,5%) cho trường hợp đa hư hỏng; tuy nhiên, kết quả đáng tin cậy khi vẫn duy trì mức sai số nhỏ hơn 5%. Trường hợp đơn hư hỏng thì cả hai mô hình đều cho kết quả dự đoán tương đương nhau, khi sai số chẩn đoán cho trường hợp 1 đều đạt khoảng 5%. Đáng chú ý, Bảng 9 trình bày kết quả chẩn đoán của kịch bản 4 phần tử hư hỏng. Phần tử 24 với mức hư hỏng thực tế là 5%, trong khi đó, kết quả dự đoán của mô hình HL2 có sai số lớn nhất 12% so với 4% của mô hình HL1, điều này cho thấy mô hình HL2 cho kết quả chẩn đoán chưa thực sự ổn định trên các trường hợp mức độ hư hỏng nhỏ của kịch bản đa hư hỏng. Tuy nhiên, sai số trung bình của kịch bản chẩn đoán vẫn ở mức nhỏ hơn 5% nên vẫn đạt độ tin cậy cần thiết.

Trong đa số các trường hợp khảo sát, sai số lớn nhất (Max) dự đoán của cả hai mô hình đều cho kết quả nhỏ hơn 6%, sai số nhỏ nhất (Min) dao động từ 0% - 5% tùy từng trường hợp. Điều này chứng tỏ kiến trúc mạng CNN và phương pháp huấn luyện đề xuất cho kết quả đáng tin cậy trên cả hai tập dữ liệu dạng dao động, hay mô hình HL2 với dữ liệu huấn luyện chỉ xét bậc tự do tịnh tiến cho kết quả dự đoán gần như tương đương với mô hình HL1.

Bảng 6. Kết quả chẩn đoán mức độ hư hỏng của trường hợp 1

Mức độ hư hỏng	Phần tử		Sai số (%)		
	23		Max	Min	Avg
Thực tế (%)	20				
HL1 (%)	19				
Sai số 1 (%)	5,0		5,0	5,0	5,0
HL2 (%)	19,1				
Sai số 2 (%)	4,5		4,5	4,5	4,5

Bảng 7. Kết quả chẩn đoán mức độ hư hỏng của trường hợp 2

Mức độ hư hỏng	Phần tử			Sai số (%)		
	27	41		Max	Min	Avg
Thực tế (%)	5	15				
HL1 (%)	5	14,2		5,3	0,0	2,7
Sai số 1 (%)	0,0	5,3				
HL2 (%)	4,8	14,2		5,3	4,0	4,7
Sai số 2 (%)	4,0	5,3				

Bảng 8. Kết quả chẩn đoán mức độ hư hỏng của trường hợp 3

Mức độ hư hỏng	Phần tử			Sai số (%)		
	1	14	21	Max	Min	Avg
Thực tế (%)	5	25	20			
HL1 (%)	5,2	24,3	19,6	4,0	2,0	2,9
Sai số 1 (%)	4,0	2,8	2,0			
HL2 (%)	5,2	24	18,9	5,5	4,0	4,5
Sai số 2 (%)	4,0	4,0	5,5			

Bảng 9. Kết quả chẩn đoán mức độ hư hỏng của trường hợp 4

Mức độ hư hỏng	Phần tử				Sai số (%)		
	8	19	24	29	Max	Min	Avg
Thực tế (%)	25	20	5	15			
HL1 (%)	24,3	19,4	4,8	15,2	4,0	1,3	2,8
Sai số 1 (%)	2,8	3,0	4,0	1,3			
HL2 (%)	24,7	19,3	4,4	15,2	12,0	1,2	4,5
Sai số 2 (%)	1,2	3,5	12,0	1,3			

Bảng 10. Kết quả chẩn đoán mức độ hư hỏng của trường hợp 5

Mức độ hư hỏng	Phần tử					Sai số (%)		
	10	19	31	33	34	Max	Min	Avg
Thực tế (%)	20	10	10	20	5			
HL1 (%)	19,5	9,8	10,4	19,5	4,9	4,0	2,0	2,6
Sai số 1 (%)	2,5	2,0	4,0	2,5	2,0			
HL2 (%)	19,1	10,2	10,4	19,4	4,7	6,0	2,0	3,9
Sai số 2 (%)	4,5	2,0	4,0	3,0	6,0			

5. Kết luận

Bài báo này đã đề xuất thành công quy trình chẩn đoán một bước để xác định vị trí và mức độ hư hỏng cho kết cấu khung không gian dựa trên dạng dao động và mạng nơ-ron tích chập. Kết quả phân tích cho thấy chỉ với ba dạng dao động, mô hình đã có thể xác định chính xác vị trí phần tử bị hư hỏng, đồng thời dự đoán mức độ hư hỏng với độ chính xác trung bình từ 95% đến 97%. Tính ổn định và độ tin cậy của quy trình được khẳng định thông qua các chỉ số đánh giá độ chính xác của quá trình huấn luyện và kết quả chẩn đoán hư hỏng của các trường hợp khảo sát khác nhau, từ trường hợp hư hỏng một phần tử đến trường hợp nhiều phần tử bị suy giảm độ cứng. Đáng chú ý, dữ liệu chỉ sử dụng ba thành phần bậc tự do chuyển vị tịnh tiến tại mỗi nút vẫn cho kết quả chẩn đoán tương đương với dữ liệu đầy đủ tất cả các bậc tự do. Đây là một ưu điểm quan trọng đối với khả năng ứng dụng vào thực tiễn, bởi các đại lượng bậc tự do chuyển vị tịnh tiến có thể dễ dàng xác định hơn so với chuyển vị góc xoay nhờ cảm biến gia tốc đặt trên kết cấu thực. Do vậy, quy trình đề xuất cho thấy tiềm năng cao trong việc triển khai trên thực tế nhằm hỗ trợ giám sát và đánh giá tình trạng an toàn của kết cấu công trình. Mặc dù đạt được các kết quả khả quan trong chẩn đoán với dữ liệu mô phỏng, nghiên cứu này vẫn còn một số hạn chế nhất định. Cụ thể, ảnh hưởng của nhiễu và khử nhiễu trong dữ liệu đo dạng dao động chưa được xem xét, trong khi đây là yếu tố không thể tránh khỏi trong điều kiện đo đạc thực tế và có thể ảnh hưởng đáng kể đến độ chính xác của mô hình chẩn đoán. Bên cạnh đó, quy trình chẩn đoán đề xuất mới được kiểm chứng thông qua các dữ liệu mô phỏng số, chưa được đánh giá trên các thí nghiệm thực nghiệm hoặc dữ liệu đo thực tế từ kết cấu. Do đó, các nghiên cứu trong tương lai cần tập trung vào việc đánh giá độ ổn định của mô hình trong điều kiện có nhiễu, cũng như triển khai kiểm chứng thực nghiệm nhằm nâng cao độ tin cậy và khả năng ứng dụng thực tiễn của phương pháp.

Lời cảm ơn

Nghiên cứu này được tài trợ bởi nguồn ngân sách khoa học và công nghệ của Trường Đại học Nha Trang trong đề tài mã số TR2025-13-53.

Tài liệu tham khảo

- [1] Pooya, S., Massumi, A. (2021). [A novel and efficient method for damage detection in beam-like structures solely based on damaged structure data and using mode shape curvature estimation](#). *Applied Mathematical Modelling*, 91:670–694.
- [2] Huang, M., Li, X., Lei, Y., Gu, J. (2020). [Structural damage identification based on modal frequency strain energy assurance criterion and flexibility using enhanced moth-flame optimization](#). *Structures*, 28: 1119–1136.
- [3] Chinka, S., Putti, S., Adavi, B. (2021). [Modal testing and evaluation of cracks on cantilever beam using mode shape curvatures and natural frequencies](#). *Structures*, 32:1386–1397.
- [4] Wu, X., Xia, J., Zhu, X. (2019). [Finding damage localizations of a planar truss using modal strain energy change](#). *Advances in Civil Engineering*, 2019(1).
- [5] Thiện, N. C., Duy, H. Đ., Cường, N. H., Sỹ, B. V., Cao, L. T. (2022). [Đánh giá sự thay đổi của tần số dao động và dạng dao động cho khung bê tông cốt thép dưới tác dụng của tải trọng](#). *Tạp chí Khoa học Công nghệ Xây dựng (KHCNXD) - ĐHXDHN*, 16(1V):22–34.
- [6] Bach, V., Ho, D., Le, T., Vu, K., Dinh, M., Tran, M., Luu, T. (2026). [Multi-damage identification in three-dimensional frame structures via a combined MSE-based method and PSO algorithm](#). *Lecture Notes in Civil Engineering*, 747:149–156.
- [7] Jiang, Y., Sun, J., Lin, Q., Xiang, J. (2023). [A two-stage method to detect damages in aluminum plates using curvature modal shape subtraction indicator and particle swarm optimization](#). *Thin-Walled Structures*, 185:110560.
- [8] Seyedpoor, S., Shahbandeh, S., Yazdanpanah, O. (2015). [An efficient method for structural damage detection using a differential evolution algorithm-based optimisation approach](#). *Civil Engineering and Environmental Systems*, 32(3):230–250.

- [9] Mishra, M., Barman, S., Maity, D., Maiti, D. (2019). [Ant lion optimisation algorithm for structural damage detection using vibration data](#). *Journal of Civil Structural Health Monitoring*, 9(1):117–136.
- [10] Gomes, G., Giovanni, R. (2022). [An efficient two-step damage identification method using sunflower optimization algorithm and mode shape curvature \(MSDBI-SFO\)](#). *Engineering with Computers*, 38(2): 1711–1730.
- [11] Avci, O., Abdeljaber, O., Kiranyaz, S., Hussein, M., Gabbouj, M., Inman, D. (2021). [A review of vibration-based damage detection in civil structures: From traditional methods to machine learning and deep learning applications](#). *Mechanical Systems and Signal Processing*, 147:107077.
- [12] Le, T., Nguyen, T., Khatir, S., Nguyen, P., Mirjalili, S., Nguyen, K. (2022). [An efficient approach for damage identification based on improved machine learning using PSO-SVM](#). *Engineering with Computers*, 38(4):3069–3084.
- [13] Nick, H., Aziminejad, A., Hosseini, M., Laknejadi, K. (2021). [Damage identification in steel girder bridges using modal strain energy-based damage index method and artificial neural network](#). *Engineering Failure Analysis*, 119:105010.
- [14] Hooshyar, H., Ahmadi, H., Bayat, M., Hosseinzadeh, E., Mahdavi, N., Najafi, M. (2025). [New method for damage detection in steel beam using time-frequency functions and machine learning](#). *Structures*, 78: 109236.
- [15] Zhong, K., Teng, S., Liu, G., Chen, G., Cui, F. (2020). [Structural damage features extracted by convolutional neural networks from mode shapes](#). *Applied Sciences*, 10(12):4247.
- [16] Nguyen, D., Abdel Wahab, M. (2023). [Damage detection in slab structures based on two-dimensional curvature mode shape method and faster R-CNN](#). *Advances in Engineering Software*, 176:103371.
- [17] Bui, N., Le, T., Bach, V., Luu, T., Tran, M., Nguyen, C., Ho, D. (2026). [Modal strain energy and convolutional neural network-based damage identification in plate-like structures](#). *Lecture Notes in Civil Engineering*, 747:21–28.
- [18] Tran, M., Bach, V., Luu, T., Nguyen, C., Chiem, H., Vu, K., Ho, D. (2025). [A novel approach for identifying structural damage in beams with diverse boundary conditions using modal strain energy method combined with convolutional neural networks](#). *Structures*, 80:110062.
- [19] Chopra, A. K. (2020). *Dynamics of Structures: Theory and Applications to Earthquake Engineering*. 5 edition, Pearson Education Limited, Harlow, United Kingdom.
- [20] Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., Inman, D. (2021). [1D convolutional neural networks and applications: A survey](#). *Mechanical Systems and Signal Processing*, 151:107398.
- [21] Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M., Inman, D. (2017). [Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks](#). *Journal of Sound and Vibration*, 388:154–170.
- [22] Abdeljaber, O., Avci, O., Kiranyaz, M., Boashash, B., Sodano, H., Inman, D. (2018). [1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data](#). *Neurocomputing*, 275:1308–1317.
- [23] Lin, Y., Nie, Z., Ma, H. (2017). [Structural damage detection with automatic feature-extraction through deep learning](#). *Computer-Aided Civil and Infrastructure Engineering*, 32(12):1025–1046.