

Quy trình một bước xác định hư hỏng cho kết cấu khung không gian sử dụng năng lượng biến dạng và mạng 1D-CNN

Bạch Văn Sỹ^{1,2,3}, Lâm Tuấn Đạt^{1,2,*}, Nguyễn Thị Trúc Ngân^{1,2}, Bùi Văn Nhật Thanh^{1,2}, Võ Văn Tường Khánh^{1,2}, Nguyễn Nhật Quang^{1,2}, Lưu Trần Hữu Tín^{1,2,4}, Hồ Đức Duy^{1,2}



Use your smartphone to scan this QR code and download this article

¹Khoa Kỹ thuật Xây dựng, Trường Đại học Bách khoa TP. Hồ Chí Minh, TP. Hồ Chí Minh, Việt Nam

²Đại học Quốc gia TP. Hồ Chí Minh, TP. Hồ Chí Minh, Việt Nam

³Khoa Xây dựng, Trường Đại học Nha Trang, Khánh Hòa, Việt Nam

⁴Khoa Kỹ thuật Công nghệ, Trường Đại học Tiền Giang, Đồng Tháp, Việt Nam

Liên hệ

Lâm Tuấn Đạt, Khoa Kỹ thuật Xây dựng, Trường Đại học Bách khoa TP. Hồ Chí Minh, TP. Hồ Chí Minh, Việt Nam

Đại học Quốc gia TP. Hồ Chí Minh, TP. Hồ Chí Minh, Việt Nam

Email: ltdat.sd242@hcmut.edu.vn

Lịch sử

- Ngày nhận: 09-04-2026
- Ngày sửa đổi: 27-05-2026
- Ngày chấp nhận: 26-06-2026
- Ngày đăng: 04-08-2026

DOI : <https://doi.org/10.32508/vnuhcmj-et.v9i3.1592>



Bản quyền

© Tạp chí ĐHQG TP.HCM. Đây là bài báo công bố mở được phát hành theo các điều khoản của the Creative Commons Attribution 4.0 International license.

TÓM TẮT

Việc theo dõi sức khỏe kết cấu công trình có ý nghĩa quan trọng trong việc phát hiện sớm hư hỏng, bảo đảm sự an toàn khi vận hành và hỗ trợ công tác bảo trì công trình. Tuy nhiên, các phương pháp chẩn đoán dựa trên đặc trưng dao động hiện nay thường dựa trên quy trình hai bước: xác định vị trí và định lượng mức độ hư hỏng, nên có thể làm tăng chi phí tính toán. Bài báo này đề xuất một quy trình chẩn đoán một bước nhằm xác định đồng thời vị trí và mức độ hư hỏng của phần tử trong kết cấu khung không gian, dựa trên đặc trưng năng lượng biến dạng và mạng nơ-ron tích chập một chiều (1D-CNN). Dữ liệu đầu vào được xây dựng từ năng lượng biến dạng của phần tử, được tính toán từ các dạng dao động thu được thông qua mô phỏng số. Mô hình 1D-CNN được sử dụng để trích lọc đặc trưng và dự đoán trạng thái hư hỏng của phần tử. Để đánh giá quy trình đề xuất, một kết cấu khung thép không gian gồm 52 phần tử được khảo sát với hai trường hợp dữ liệu đầu vào: sử dụng sáu dạng dao động và sử dụng hai dạng dao động đầu tiên. Kết quả huấn luyện cho thấy mô hình đạt hiệu quả dự đoán tốt, với chỉ số đánh giá R^2 trung bình đạt 99% trên tập huấn luyện và 98% trên tập kiểm tra. Bên cạnh đó, thông qua đánh giá sai số chẩn đoán của 250 trường hợp hư hỏng, từ 1 đến 5 phần tử, quy trình đề xuất cho thấy khả năng chẩn đoán chính xác vị trí hư hỏng, với sai số trung bình dự đoán mức độ hư hỏng dao động trong khoảng 1%–5%. Kết quả chẩn đoán cho thấy việc chỉ sử dụng hai dạng dao động đầu tiên đã cho kết quả gần tương đương với trường hợp sử dụng sáu dạng dao động, qua đó cho thấy tính khả thi của quy trình đề xuất khi triển khai trong thực tế.

Từ khoá: Chẩn đoán hư hỏng, năng lượng biến dạng, mạng nơ-ron tích chập, kết cấu khung không gian

GIỚI THIỆU

Trong quá trình khai thác, các công trình xây dựng thường chịu tác động của tải trọng, điều kiện môi trường và sự suy giảm cường độ vật liệu theo thời gian, dẫn đến sự hình thành và phát triển của hư hỏng trong kết cấu. Do đó, theo dõi sức khỏe kết cấu (Structural Health Monitoring: SHM) đã trở thành một hướng nghiên cứu quan trọng. Mục tiêu là phát hiện, định vị và định lượng mức độ hư hỏng nhằm đảm bảo an toàn khai thác và tối ưu hóa công tác bảo trì¹. Trong nhiều năm qua đã có nhiều phương pháp chẩn đoán hư hỏng kết cấu đã được nghiên cứu phát triển, tuy nhiên, cách tiếp cận dựa trên đặc trưng dao động của kết cấu như: tần số riêng, dạng dao động và năng lượng biến dạng được sử dụng rộng rãi do đặc tính không phá hủy kết cấu khi đo đạc và khả năng phản ánh trực tiếp trạng thái làm việc toàn cục của kết cấu^{2,3}.

Trong số các đặc trưng động học, năng lượng biến dạng được biết đến là giá trị nhạy với sự xuất hiện của hư hỏng. Các nghiên cứu cho thấy nếu chỉ sử dụng

giá trị năng lượng biến dạng đơn thuần thì chỉ xác định được vị trí hư hỏng trên kết cấu nhưng rất khó định lượng mức độ hư hỏng của phần tử. Để khắc phục nhược điểm này nhiều nghiên cứu đã đề xuất các quy trình chẩn đoán hai bước, trong đó bước đầu tiên nhằm xác định vị trí hư hỏng, và bước thứ hai đánh giá mức độ suy giảm độ cứng của phần tử dựa trên thuật toán tối ưu hóa ngược⁴⁻⁷. Mặc dù các quy trình này có thể cải thiện độ chính xác, nhưng chúng thường yêu cầu sử dụng các thuật toán tối ưu hóa cho những hàm mục tiêu phức tạp.

Gần đây, sự phát triển của học máy và học sâu đã mở ra hướng tiếp cận mới cho bài toán chẩn đoán hư hỏng kết cấu. Các phương pháp học máy truyền thống, như Support Vector Machine và Artificial Neural Network, đã được sử dụng để thiết lập mối quan hệ giữa đặc trưng dao động và trạng thái hư hỏng⁸. Tuy nhiên, các phương pháp này phụ thuộc nhiều vào quá trình trích chọn đặc trưng thủ công và khó xử lý các quan hệ phi tuyến phức tạp. Để khắc phục hạn chế này, các mô hình học sâu, đặc biệt là mạng nơ-ron

Trích dẫn bài báo này: Sỹ B V, Đạt L T, Ngân N T T, Thanh B V N, Khánh V V T, Quang N N, Tín L T H, Duy H D. Quy trình một bước xác định hư hỏng cho kết cấu khung không gian sử dụng năng lượng biến dạng và mạng 1D-CNN. *VNUHCM J. Eng. Technol.* 2026; 9(3):3097-3106.

tích chập (Convolutional Neural Network: CNN), đã được phát triển và áp dụng rộng rãi trong lĩnh vực chẩn đoán hư hỏng kết cấu. Nghiên cứu của Li và cộng sự đã sử dụng mạng CNN với dữ liệu đầu vào là sự sai khác dạng biến dạng (strain mode) trong điều kiện có nhiễu để chẩn đoán chính xác vị trí và mức độ hư hỏng⁹. Trong khi đó, Naresh và cộng sự thì sử dụng mạng CNN-LSTM với dữ liệu là tần số dao động để thực hiện chẩn đoán hư hỏng tại các mối nối của khung thép¹⁰. Bên cạnh đó, nhiều nghiên cứu đã đề xuất áp dụng đặc trưng năng lượng biến dạng kết hợp với mạng CNN để chẩn đoán cho các dạng kết cấu khác nhau. Chen và Teng¹¹ đã khảo sát bài toán chẩn đoán hư hỏng cho kết cấu dầm đơn giản; trong đó, mạng CNN được sử dụng để đồng thời định vị và định lượng mức độ hư hỏng từ năng lượng biến dạng của dạng dao động bậc một, đạt độ chính xác định vị 100% và sai số dự đoán mức độ hư hỏng khoảng 5%. Teng và cộng sự¹² đã mở rộng sang kết cấu giàn thép 381 thanh, sử dụng tỉ lệ thay đổi năng lượng biến dạng (MSECR) làm đầu vào cho mạng CNN phân loại, và bổ sung kiểm chứng bằng dữ liệu thí nghiệm thực để chứng minh khả năng huấn luyện từ mô phỏng số và áp dụng cho cấu trúc thật. Trong nghiên cứu tiếp theo, Teng và cộng sự¹³ đã nâng cấp đầu vào bằng cách kết hợp năng lượng biến dạng với tín hiệu gia tốc động cho cùng dạng kết cấu giàn 121 thanh, đồng thời khảo sát thêm ảnh hưởng của nhiễu đo, cho thấy việc bổ sung tham số động lực học giúp cải thiện đáng kể tốc độ hội tụ và độ chính xác phân loại của mạng so với khi chỉ sử dụng năng lượng biến dạng đơn thuần. Bùi và cộng sự¹⁴ đã đề xuất quy trình một bước thực hiện chẩn đoán vị trí và mức độ hư hỏng cho kết cấu tấm sử dụng năng lượng biến dạng và thuật toán CNN với độ chính xác chẩn đoán cao. Gần đây, Tran và cộng sự¹⁵ đã cải thiện quy trình một bước sử dụng giá trị năng lượng biến dạng thô làm dữ liệu đầu vào để thực hiện chẩn đoán vị trí và mức độ hư hỏng cho kết cấu dầm với điều kiện biên khác nhau. Các nghiên cứu cho thấy CNN có khả năng tự động trích xuất đặc trưng từ dữ liệu dao động và cải thiện đáng kể độ chính xác dự đoán so với các phương pháp trước đây.

Các nghiên cứu trước đây đã đạt được những kết quả nhất định trong việc chẩn đoán hư hỏng kết cấu dựa trên năng lượng biến dạng và học máy. Tuy nhiên, vẫn còn tồn tại một số hạn chế. Trước hết, các phương pháp chỉ sử dụng năng lượng biến dạng đơn thuần chủ yếu cho phép xác định vị trí mà chưa định lượng được mức độ hư hỏng. Tiếp đó, các quy trình chẩn đoán hai bước có thể khắc phục hạn chế này nhưng đòi hỏi thuật toán tối ưu hóa ngược với hàm mục tiêu phức tạp, dẫn đến thời gian tính toán cao. Bên cạnh đó, các nghiên cứu kết hợp mô hình CNN với năng

lượng biến dạng mới chỉ được khảo sát cho kết cấu dầm, tấm và dầm. Trong khi đó, kết cấu khung không gian, nơi tồn tại sự liên kết phức tạp giữa các phần tử dầm-cột và chịu đồng thời nhiều thành phần nội lực, vẫn chưa được nghiên cứu đầy đủ. Do đó, nghiên cứu này đề xuất một quy trình chẩn đoán một bước dựa trên năng lượng biến dạng và mạng nơ-ron tích chập một chiều (1D-CNN). Đóng góp chính của bài báo bao gồm: (1) đề xuất quy trình một bước cho phép đồng thời xác định vị trí và định lượng mức độ hư hỏng của các phần tử, khắc phục nhược điểm của quy trình hai bước; (2) mở rộng phạm vi áp dụng sang kết cấu khung không gian với phần tử liên kết không gian phức tạp; (3) khảo sát hiệu quả chẩn đoán theo hai trường hợp dữ liệu huấn luyện: trường hợp 1 (TH1) sử dụng năng lượng biến dạng của 6 dạng dao động đầu tiên và trường hợp 2 (TH2) chỉ sử dụng 2 dạng dao động đầu tiên nhằm đánh giá khả năng giảm thiểu yêu cầu đo đạc trong thực tế. Độ chính xác của quy trình đề xuất được đánh giá thông qua quá trình huấn luyện và kiểm chứng với 5 nhóm phần tử tương ứng với 250 kích bản hư hỏng khác nhau.

PHƯƠNG PHÁP NGHIÊN CỨU

Phương pháp năng lượng biến dạng

Năng lượng biến dạng của kết cấu là giá trị đại diện cho mức dự trữ năng lượng trong mỗi phần tử của kết cấu khi dao động. Từ kết quả phân tích dao động tự do của kết cấu theo phương pháp phần tử hữu hạn, năng lượng biến dạng của phần tử tương ứng với dạng dao động đang xét được xác định bởi công thức sau¹⁶:

$$MSE_{ij} = \frac{1}{2} \phi_i^T K_j \phi_i \quad (1)$$

trong đó,

- MSE_{ij} là giá trị năng lượng biến dạng của phần tử j tương ứng với dạng dao động thứ i .
- ϕ_i, ϕ_i^T là véc-tơ dạng dao động thứ i và véc-tơ dạng dao động chuyển vị tương ứng.
- K_j là ma trận độ cứng của phần tử j trong hệ tọa độ tổng thể của kết cấu.

Khi kết cấu xuất hiện những hư hỏng dẫn đến trạng thái của kết cấu thay đổi, khi đó năng lượng biến dạng của phần tử tương ứng với trạng thái trước và sau khi hư hỏng được xác định như sau:

+ Trước khi hư hỏng

$$MSE_{ij}^u = \frac{1}{2} \phi_i^{uT} K_j \phi_i^u \quad (2)$$

+ Sau khi hư hỏng

$$MSE_{ij}^d = \frac{1}{2} \phi_i^{dT} K_j \phi_i^d \quad (3)$$

trong đó, “ u ” là trạng thái ban đầu của kết cấu khi chưa hư hỏng và “ d ” là trạng thái kết cấu khi hư hỏng xuất hiện.

Trong nghiên cứu này, giả thiết khối lượng của phần tử không đổi trước và sau khi hư hỏng và trạng thái hư hỏng của kết cấu được thể hiện bởi sự suy giảm độ cứng của phần tử trên kết cấu. Giá trị năng lượng biến dạng ở trạng thái sau khi hư hỏng MSE^d được sử dụng làm đặc trưng đầu vào cho mạng 1D-CNN. Lựa chọn này phù hợp với hướng tiếp cận dữ liệu thô đã được kiểm chứng hiệu quả trong các nghiên cứu gần đây, đồng thời không đòi hỏi dữ liệu trạng thái ban đầu.

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

Mạng 1D-CNN là một trong những mạng nơ-ron nhân tạo được thiết kế chuyên biệt để xử lý dữ liệu dưới dạng chuỗi tín hiệu theo thời gian hoặc dữ liệu được sắp xếp tuần tự¹⁷. Kiến trúc của mô hình cơ bản bao gồm lớp tích chập, trong đó bộ lọc được dịch chuyển dọc theo chuỗi dữ liệu đầu vào để thực hiện phép tích chập, qua đó khai thác các đặc trưng cục bộ của dữ liệu. Các đặc trưng thu được tiếp tục được đưa qua các hàm kích hoạt phi tuyến và các lớp kết nối đầy đủ (Fully Connected: FC) để thực hiện nhiệm vụ phân loại hoặc hồi quy^{18,19}. Trong nghiên cứu này, mạng 1D-CNN được xây dựng bởi ngôn ngữ lập trình Python trên cơ sở thư viện Pytorch với các siêu tham số cơ bản trình bày như Bảng 1. Các siêu tham số này là kết quả của quá trình hiệu chỉnh nhiều lần theo phương pháp thử và sai nhằm đạt độ chính xác tốt nhất với chi phí tính toán hợp lý.

Kiến trúc mạng 1D-CNN bao gồm các thành phần chính: lớp đầu vào, lớp tích chập một chiều, lớp làm phẳng, lớp kết nối đầy đủ và lớp đầu ra. Dữ liệu đầu vào của mạng 1D-CNN được xây dựng từ năng lượng biến dạng dao động của các phần tử trong kết cấu, được sắp xếp tuần tự theo từng phần tử và theo dạng dao động. Trong Hình 1, x_{ij} biểu thị đặc trưng năng lượng biến dạng thứ j của trường hợp hư hỏng thứ i , với $i = 1, 2, \dots, n$ là số lượng trường hợp hư hỏng và $j = 1, 2, \dots, k$ là số lượng đặc trưng đầu vào của mỗi mẫu. Nếu kết cấu có N_e phần tử và sử dụng N_m dạng dao động, thì số đặc trưng đầu vào được xác định bởi $k = N_e \times N_m$. Trong nghiên cứu này, $N_e = 52$, do đó, khi sử dụng 6 dạng dao động, $k = 312$, còn khi sử dụng 2 dạng dao động, $k = 104$. Lớp tích chập một chiều được biểu thị bởi kích thước bộ lọc (f), bước trượt (s) và đệm (p). Kích thước bộ lọc được chọn bằng chiều dài véc-tơ đầu vào, tức là $f = k$, trong khi $s = 1$ và $p = 0$. Với thiết lập này, mỗi bộ lọc bao quát toàn bộ véc-tơ năng lượng biến dạng của một mẫu, cho phép mạng học mối quan hệ tổng thể giữa phân bố năng

lượng biến dạng và trạng thái hư hỏng của kết cấu. Hàm kích hoạt ELU được sử dụng để xử lý tốt các giá trị âm có thể có của dữ liệu sau khi chuẩn hóa, tránh hiện tượng triệt tiêu thông tin như khi dùng ReLU.

Sau quá trình tích chập, các đặc trưng thu được được chuyển qua lớp làm phẳng để biến đổi thành vectơ một chiều, trước khi đưa vào 4 lớp kết nối đầy đủ, mỗi lớp gồm 1500 nơ-ron, nhằm thực hiện quá trình học và dự đoán. Ngoài ra, kỹ thuật Dropout với tỉ lệ 1% được sử dụng trong quá trình huấn luyện để tăng tính ổn định của mô hình và hạn chế hiện tượng quá khớp. Tỉ lệ này được lựa chọn thông qua quá trình hiệu chỉnh siêu tham số theo phương pháp thử và sai. Do dữ liệu đầu vào là véc-tơ năng lượng biến dạng của phần tử, đã được chuẩn hóa và mang ý nghĩa vật lý trực tiếp đối với trạng thái hư hỏng của kết cấu; tỉ lệ Dropout lớn có thể làm mất một phần thông tin đặc trưng quan trọng, từ đó ảnh hưởng đến khả năng học mối quan hệ giữa phân bố năng lượng biến dạng và mức độ hư hỏng của các phần tử. Vì vậy, tỉ lệ Dropout 1% được sử dụng như một cơ chế kiểm soát quá khớp ở mức nhẹ, đồng thời bảo toàn phần lớn thông tin đặc trưng của dữ liệu đầu vào. Lớp đầu ra gồm 52 nút, tương ứng với mức độ hư hỏng dự đoán của 52 phần tử trong kết cấu.

Quy trình chẩn đoán đề xuất



Quy trình chẩn đoán hư hỏng kết cấu khung không gian đề xuất bao gồm các công việc sau (Hình 2): thu thập dữ liệu, huấn luyện, đánh giá mô hình và thực thi mô hình dự đoán. Đầu tiên, dữ liệu năng lượng biến dạng được tính toán từ các dạng dao động của kết cấu khung được thu thập. Dữ liệu này được tiền xử lý bằng cách sắp xếp lại theo chuỗi tuần tự nhằm phù hợp với cấu trúc dữ liệu đầu vào của mô hình 1D-CNN, đồng thời loại bỏ các trường hợp trùng lặp. Trước khi phân chia thành ba tập: huấn luyện, kiểm định và kiểm tra, tập dữ liệu được chuẩn hóa Z-score để đưa dữ liệu về phân phối có trung bình bằng 0 và độ lệch chuẩn bằng 1.

Tiếp theo, mô hình mạng nơ-ron tích chập được khởi tạo và huấn luyện dựa trên tập dữ liệu đã chuẩn hóa. Quá trình tối ưu sử dụng thuật toán Adam kết hợp cơ chế lan truyền ngược nhằm cực tiểu hóa hàm mất mát trung bình bình phương. Sau quá trình huấn luyện với 500 epochs, độ chính xác của mô hình được đánh giá thông qua các chỉ số định lượng sai số MAE, RMSE và hệ số xác định R^2 trên tập kiểm định và kiểm tra. Trong trường hợp các chỉ số định lượng này chưa đạt yêu cầu thì các siêu tham số sẽ được điều chỉnh và mô hình được huấn luyện lại. Khi mô hình đạt độ chính xác và tổng quát hóa tốt trên tập kiểm tra từ 95% trở lên, mô hình sẽ được sử dụng để dự đoán vị trí và mức độ hư hỏng của các phần tử trên kết cấu.

Bảng 1: Kiến trúc và siêu tham số huấn luyện mạng 1D-CNN [Nguồn: Nhóm tác giả]

Lớp đầu vào	Lớp Conv1D + ELU	Lớp kết nối đầy đủ + ELU	Lớp đầu ra	Tối ưu hóa	Hàm loss	Tốc độ học tập	Kích thước Batch	Epoch
312/104	200 bộ lọc, kernel 312/104	4x1500	52	Adam	Mean Squared Error	10^{-4}	128	500


Ghi chú: Hàm kích hoạt ELU; đệm ($p = 0$); bước trượt ($s = 1$); tỉ lệ chia train/validation/test = 80/10/10. Giá trị 312/104 lần lượt tương ứng với TH1 (6 dạng dao động) và TH2 (2 dạng dao động).



KẾT QUẢ VÀ THẢO LUẬN

Bài toán phân tích

Để xác thực quy trình chẩn đoán đề xuất, một mô hình kết cấu khung thép không gian với điều kiện biên ngàm gồm 30 nút và 52 phần tử (Hình 3) được khảo sát, với kích thước hình học và đặc trưng vật liệu được trình bày như Bảng 2.



Hình 3: Mô hình phần tử hữu hạn kết cấu [Nguồn: Nhóm tác giả]

Bảng 2: Đặc trưng hình học và thông số vật liệu²⁰

Kích thước hình học	
Chiều cao cột	0.6096 m
Chiều dài dầm	0.6096 m
Tiết diện cột	(0.00635×0.0508) m
Tiết diện dầm	(0.00635×0.0508) m
Thuộc tính vật liệu	
Mô đun đàn hồi	1.96×10^8 kN/m ²
Hệ số Poisson	0.3
Khối lượng riêng	7800 kg/m ³

Dữ liệu huấn luyện

Dữ liệu huấn luyện được thu thập là giá trị năng lượng biến dạng của 50,000 trường hợp hư hỏng khác nhau, trong đó vị trí phần tử hư hỏng được lấy ngẫu nhiên và mức độ hư hỏng cũng được lấy ngẫu nhiên trong khoảng 0% đến 50% với bước 0.1%, số lượng các trường hợp cụ thể như Bảng 3. Hai trường hợp huấn luyện được đề xuất gồm: trường hợp huấn luyện 1 (TH1) sử dụng 6 dạng dao động đầu tiên (312 đặc trưng) và trường hợp huấn luyện 2 (TH2) chỉ sử dụng 2 dạng dao động uốn đầu tiên (104 đặc trưng). Mức độ chính xác chẩn đoán được kiểm chứng bởi 250 trường hợp hư hỏng từ 1 phần tử (1pt) đến 5 phần tử hư hỏng (5pt) với số lượng như Bảng 4, với mức độ hư hỏng của các phần tử trong mỗi trường hợp dao động trong khoảng 5% - 20%, bước 5%.

Bảng 4: Số lượng kích bản hư hỏng [Nguồn: Nhóm tác giả]

Nhóm phần tử	5pt	4pt	3pt	2pt	1pt
Số lượng	50	50	50	50	50
Tổng	250				

Kết quả huấn luyện và dự đoán

Kết quả huấn luyện mô hình CNN với 500 epochs (Bảng 5) cho thấy cả hai mô hình đều có khả năng tổng quát hóa tốt trên dữ liệu chưa nhìn thấy, khi chỉ số R² luôn duy trì ở mức 97% đến 99%. Mô hình đặc biệt vượt trội trên tập dữ liệu TH1 khi chỉ số định lượng MAE và RMSE ở tập kiểm tra đều ở mức thấp (0.26 và 0.41) so với (0.90 và 2.12) ở tập dữ liệu TH2. Xu hướng này cho thấy ít có sự chênh lệch giữa giá trị dự đoán và giá trị thực tế trong tập dữ liệu TH1, trong khi đó, dữ liệu trường hợp TH2 gặp khó khăn hơn trong việc chẩn đoán. Tuy nhiên, cần lưu ý rằng

các kết quả về MAE, RMSE nêu trên được thiết lập với kiến trúc mạng và bộ dữ liệu cụ thể cho kết cấu 52 phần tử, khi quy mô dự đoán tăng lên (lớn hơn 52 phần tử), để duy trì được mức MAE và RMSE tương đương, mô hình cần được huấn luyện lại trên bộ dữ liệu mới để có sự điều chỉnh tham số kiến trúc mạng phù hợp với số phần tử của kết cấu.

Đáng chú ý, không có sự chênh lệch đáng kể về thời gian huấn luyện mô hình trên hai tập dữ liệu này khi cả hai mô hình đều được huấn luyện trên cùng máy tính có cấu hình Core i7-12700 (2.10 GHz), Ram DDR5-16 GB, GPU Nvidia T1000-4 GB. Điều này được lý giải bởi kiến trúc mạng đề xuất: với kích thước bộ lọc tích chập bằng độ dài véc-tơ đầu vào ($f=k$), đầu ra sau lớp Conv1D của cả hai trường hợp đều có cùng kích thước (200 giá trị). Do đó, toàn bộ phần tính toán tại 4 lớp kết nối đầy đủ phía sau là tương đương giữa hai trường hợp, trong khi chi phí tính toán tại lớp Conv1D chỉ chiếm tỷ trọng nhỏ trong tổng khối lượng tính toán của mô hình.

Kết quả chẩn đoán vị trí hư hỏng của 250 trường hợp được đánh giá thông qua kết quả dự đoán mức độ hư hỏng của các phần tử gây nhiễu. Các phần tử này là những phần tử thực tế không bị hư hỏng nhưng được mô hình dự đoán là có hư hỏng với mức độ vượt quá ngưỡng hư hỏng Zth (%). Ngưỡng hư hỏng được hiểu là giá trị giới hạn dùng để phân biệt phần tử được xem là hư hỏng và phần tử không hư hỏng dựa trên mức độ hư hỏng dự đoán của mô hình 1D-CNN. Việc lựa chọn ngưỡng Zth (%) cần thỏa mãn đồng thời hai điều kiện: (i) đủ thấp để không bỏ sót các phần tử có hư hỏng thực ở mức độ thấp nhất trong tập dữ liệu dự đoán (5%), tức Zth (%) < 5%; (ii) đủ cao để loại bỏ các giá trị nhiễu dự đoán của những phần tử không hư hỏng. Theo Bảng 6 mức nhiễu dự đoán cao nhất quan sát được trên các phần tử không hư hỏng là 1.84% (TH2, nhóm 5pt), trong khi mức hư hỏng thực tối thiểu trong tập dự đoán là 5%. Do đó, trong nghiên cứu này, ngưỡng Zth = 1.5% được lựa chọn là giá trị cân bằng: đủ thấp so với 5% để đảm bảo độ nhạy phát hiện hư hỏng, đồng thời đủ cao để loại bỏ phần lớn nhiễu dự đoán quan sát được.

Để minh họa hiệu quả chẩn đoán vị trí của quy trình đề xuất, 5 kích bản được lựa chọn ngẫu nhiên từ 5 nhóm phần tử hư hỏng (1pt, 2pt, 3pt, 4pt, 5pt), bao gồm KB250 (nhóm 1pt), KB166 (nhóm 2pt), KB140 (nhóm 3pt), KB70 (nhóm 4pt) và KB39 (nhóm 5pt). Cách lựa chọn ngẫu nhiên này nhằm đảm bảo tính khách quan trong việc trình bày kết quả, tránh thiên vị về phía các kích bản có kết quả tốt nhất hoặc xấu nhất, qua đó phản ánh trung thực khả năng chẩn đoán của mô hình trên bất kỳ trường hợp nào. Kết quả chẩn

Bảng 3: Phân bố số lượng trường hợp hư hỏng [Nguồn: Nhóm tác giả]

Kịch bản hư hỏng	1pt	2pt	3pt	4pt	5pt	6pt	7pt	8pt	9pt	10pt
Số lượng	2000	3500	3500	3500	3500	3500	3500	3500	3500	3500
Kịch bản hư hỏng	15pt	20pt	25pt	30pt	35pt	40pt	45pt	50pt	52pt	
Số lượng	3500	3500	3500	1000	1000	1000	1000	1000	1000	
Tổng cộng: 50,000 trường hợp										

Bảng 5: Kết quả huấn luyện mô hình CNN [Nguồn: Nhóm tác giả]

Tập dữ liệu huấn luyện				
Trường hợp	MAE	RMSE	R2	Thời gian (phút)
TH1	0.38	0.61	0.99	31
TH2	0.43	0.68	0.99	32
Tập dữ liệu kiểm tra				
Trường hợp	MAE	RMSE	R2	
TH1	0.26	0.41	0.99	
TH2	0.90	2.12	0.97	


đoán vị trí hư hỏng của 5 kịch bản đại diện được trình bày trong Hình 4.

Kết quả thống kê trong Bảng 6 và Hình 4 cho thấy đối với trường hợp TH1, mô hình chẩn đoán chính xác toàn bộ vị trí hư hỏng mà không xuất hiện phần tử nhiễu. Ngược lại, đối với trường hợp TH2, xuất hiện trường hợp có nhiều vị trí hư hỏng, cụ thể, trong nhóm 5pt. Hình 5 trình bày phân bố sai số trung bình trong chẩn đoán mức độ hư hỏng của các nhóm kịch bản hư hỏng. Kết quả cho thấy TH1 có phân bố sai số tập trung và ổn định cao ở tất cả các nhóm kịch bản, với trung vị dao động trong khoảng 1.3%-2.0% và khoảng tứ phân vị hẹp (dưới 2%). Mặc dù tồn tại một số giá trị ngoại lai, các giá trị này đều dưới 8%, vẫn nằm trong giới hạn chấp nhận được đối với bài toán chẩn đoán hư hỏng kết cấu. Đối với TH2, trung vị sai số chỉ ở mức 2%-3%, tương đương với TH1 ở các nhóm có ít phần tử hư hỏng, nhưng độ phân tán lớn hơn đáng kể do xuất hiện nhiều giá trị ngoại lai vượt quá 10%. Đặc biệt, một số kịch bản trong nhóm 1pt và 2pt ghi nhận sai số cá biệt lên tới gần 15% và 28%. Tuy nhiên, các giá trị ngoại lai này chiếm tỷ trọng nhỏ trong số 50 trường hợp hư hỏng, phần lớn kết quả vẫn tập trung quanh trung vị. Điều này cho thấy khi chỉ sử dụng 2 dạng dao động, phần lớn các kịch bản có kết quả chẩn đoán tốt, nhưng mô hình kém ổn định hơn và có thể gặp khó khăn ở một số cấu hình hư hỏng đặc thù, chẳng hạn khi vị trí có mức hư hỏng nhỏ nằm tại

các phần tử ít đóng góp vào năng lượng biến dạng của 2 dạng dao động đầu tiên.

KẾT LUẬN VÀ KIẾN NGHỊ


Bài báo này đã đề xuất phương pháp chẩn đoán một bước nhằm đồng thời xác định vị trí và mức độ hư hỏng cho kết cấu khung không gian dựa trên năng lượng biến dạng và mạng nơ-ron tích chập. Kết quả phân tích cho thấy chỉ với giá trị năng lượng biến dạng của hai dạng dao động đầu tiên, mô hình đã có thể xác định chính xác vị trí phần tử bị hư hỏng với mức nhiều vị trí rất thấp, đồng thời dự đoán mức độ hư hỏng của các nhóm kịch bản với độ chính xác trung bình trên 95%. Tính ổn định và độ tin cậy của quy trình đề xuất được đánh giá thông qua chỉ số định lượng của quá trình huấn luyện và khả năng dự đoán hư hỏng của các nhóm phần tử từ nhóm 1 phần tử hư hỏng đến nhóm 5 phần tử hư hỏng. Việc sử dụng năng lượng biến dạng của hai dạng dao động đầu tiên cho kết quả chẩn đoán gần tương đương với việc sử dụng năng lượng biến dạng của sáu dạng dao động, cho thấy tiềm năng ứng dụng của phương pháp cho việc chẩn đoán hư hỏng trong thực tế khi đòi hỏi năng lượng kích động lên công trình ở mức vừa phải. Bên cạnh những kết quả tích cực thu được trên dữ liệu mô phỏng, quy trình đề xuất vẫn còn một vài hạn chế. Trước hết, nhiều trong tín hiệu đo dạng dao động chưa được đưa vào khảo sát, mặc dù đây là yếu tố luôn hiện hữu trong thực tế đo đạc và có




Hình 4: Kết quả chẩn đoán vị trí hư hỏng của năm kịch bản hư hỏng điển hình [Nguồn: Nhóm tác giả]

Bảng 6: Mức độ hư hỏng của phần tử nhiễu [Nguồn: Nhóm tác giả]

Trường hợp	Mức độ hư hỏng, %				
	5pt	4pt	3pt	2pt	1pt
TH1	0.26 (0)	0.22 (0)	0.17 (0)	0.15 (0)	0.12 (0)
TH2	1.84 (1)	1.08 (0)	0.6 (0)	0.65 (0)	0.50 (0)
Ghi chú: () là số lượng kịch bản có nhiễu					



a) Dữ liệu sai số chuẩn đoán TH1



b) Dữ liệu sai số chuẩn đoán TH2

Hình 5: Sai số trung bình chuẩn đoán của các nhóm kịch bản [Nguồn: Nhóm tác giả]

thể làm suy giảm hiệu quả chuẩn đoán của mô hình. Tiếp theo, toàn bộ kết quả mới chỉ được xác thực qua mô phỏng số, chưa có sự đối chứng với thí nghiệm vật lý hoặc số liệu đo trực tiếp trên kết cấu thực. Vì vậy, hướng nghiên cứu tiếp theo cần khảo sát tính bền vững của mô hình khi có nhiễu, đồng thời tiến hành kiểm chứng thực nghiệm nhằm khẳng định khả năng triển khai phương pháp trong các bài toán giám sát kết cấu thực tế.

LỜI CẢM ƠN

Chúng tôi xin cảm ơn Trường Đại học Bách khoa, ĐHQG-HCM đã hỗ trợ cho nghiên cứu này.

XUNG ĐỘT LỢI ÍCH

Nhóm tác giả xin cam đoan rằng không có bất kỳ xung đột lợi ích nào trong công bố bài báo.

ĐÓNG GÓP CỦA CÁC TÁC GIẢ

Bạch Văn Sỹ, Lâm Tuấn Đạt, Nguyễn Thị Trúc Ngân, Bùi Văn Nhật Thanh, Võ Văn Tường Khánh, Nguyễn

Nhật Quang đã thực hiện mô hình, lập trình tính toán, phân tích kết quả và viết bản thảo bài báo. Hồ Đức Duy, Lưu Trần Hữu Tín đã đưa ra ý tưởng nghiên cứu, chỉnh sửa và hoàn thiện bản thảo bài báo.

DANH MỤC TỪ VIẾT TẮT

1D-CNN: Mạng nơ-ron tích chập một chiều (One-Dimensional Convolutional Neural Network).

Adam: Thuật toán tối ưu Adam (Adaptive Moment Estimation).

CNN: Mạng nơ-ron tích chập (Convolutional Neural Network).

CNN-LSTM: Mạng kết hợp tích chập – bộ nhớ dài ngắn hạn (CNN – Long Short-Term Memory).

Conv1D: Lớp tích chập một chiều (1D Convolution layer).

ELU: Hàm kích hoạt tuyến tính mũ (Exponential Linear Unit).

FC: Kết nối đầy đủ (Fully Connected).

FEM: Phương pháp phần tử hữu hạn (Finite Element Method).

KB: Kích bản hư hỏng.
LSTM: Mạng bộ nhớ dài-ngắn hạn (Long Short-Term Memory).
MAE: Sai số tuyệt đối trung bình (Mean Absolute Error).
MĐHH: Mức độ hư hỏng.
MSE: Năng lượng biến dạng (Modal Strain Energy).
MSECR: Tỷ lệ thay đổi năng lượng biến dạng (Modal Strain Energy Change Ratio).
PSO: Thuật toán tối ưu hóa bầy đàn (Particle Swarm Optimization).
 R^2 : Hệ số xác định (Coefficient of Determination).
ReLU: Hàm kích hoạt tuyến tính chỉnh lưu (Rectified Linear Unit).
RMSE: Sai số toàn phương trung bình quân phương (Root Mean Square Error).
SHM: Theo dõi sức khỏe kết cấu (Structural Health Monitoring).
TH1, TH2: Trường hợp huấn luyện 1 và 2.

TÀI LIỆU THAM KHẢO

- Doebeling SW, Farrar CR, Prime MB. A summary review of vibration-based damage identification methods. *Shock and Vibration Digest*. 1998;30(2):91–105. Available from: <https://doi.org/10.1177/058310249803000201>.
- Carden E, Fanning P. Vibration-based condition monitoring: a review. *Structural Health Monitoring*. 2004;3(4):355–77. Available from: <https://doi.org/10.1177/1475921704047500>.
- Thiện NC, Đ Duy H, Cường NH, Sỹ BV, Cao LT. 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*. 2022;16(1V):22–34. Available from: [https://doi.org/10.31814/stce.huice\(nuce\)2022-16\(1V\)-03](https://doi.org/10.31814/stce.huice(nuce)2022-16(1V)-03).
- Shi ZY, Law SS, Zhang LM. Structural damage localization from modal strain energy change. *Journal of Sound and Vibration*. 1998;218(5):825–44. Available from: <https://doi.org/10.1006/jsvi.1998.1878>.
- Huajun L, Hezhen Y, James HS. Modal strain energy decomposition method for damage localization in 3d frame structures. *Journal of Engineering Mechanics*. 2006;132(9):941–51. Available from: [https://doi.org/10.1061/\(ASCE\)0733-9399\(2006\)132:9\(941\)](https://doi.org/10.1061/(ASCE)0733-9399(2006)132:9(941)).
- Bach VS, Ho DD, Le TC, Vu KH, Dinh MT, Tran MH, et al. Multi-damage identification in three-dimensional frame structures via a combined MSE-based method and PSO algorithm. *Lecture Notes in Civil Engineering*. 2025;747:149–56. Available from: https://doi.org/10.1007/978-3-032-04645-1_18.
- Sỹ BV, Cao LT, Đ Duy H. Chẩn đoán hư hỏng trong kết cấu khung thép sử dụng phương pháp năng lượng biến dạng kết hợp với thuật toán di truyền. *Tạp chí Phát triển Khoa học và Công nghệ – Kĩ thuật và Công nghệ*. 2021;4(4):1254–1262. Available from: <https://doi.org/10.32508/stdjet.v4i4.904>.
- Worden K, Manson G. The application of machine learning to structural health monitoring. *Philosophical Transactions Series A, Mathematical, Physical, and Engineering Sciences*. 2007;365:515–37. Available from: <https://doi.org/10.1098/rsta.2006.1938>.
- Li M, Jia D, Wu Z, Qiu S, He W. Structural damage identification using strain mode differences by the iFEM based on the convolutional neural network (CNN). *Mechanical Systems and Signal Processing*. 2022;165:108289. Available from: <https://doi.org/10.1016/j.ymssp.2021.108289>.
- Nareesh M, Jadhav AB, Patil YS. A combined CNN-LSTM-based technique for joint damage detection in steel frame structures. *Asian Journal of Civil Engineering*. 2025;26(6):2399–408. Available from: <https://doi.org/10.1007/s42107-025-01315-w>.
- Chen G, Teng S. Structural damage detection with modal strain energy using convolution neural network. *Lecture Notes in Civil Engineering*. 2021;101:1289–98. Available from: https://doi.org/10.1007/978-981-15-8079-6_121.
- Teng S, Chen G, Liu G, Lv J, Cui F. Modal strain energy-based structural damage detection using convolutional neural networks. *Applied Sciences (Basel, Switzerland)*. 2019;9(16):3376. Available from: <https://doi.org/10.3390/app9163376>.
- Teng S, Chen G, Gong P, Liu G, Cui F. Structural damage detection using convolutional neural networks combining strain energy and dynamic response. *Meccanica*. 2020;55(4):945–59. Available from: <https://doi.org/10.1007/s11012-019-01052-w>.
- Hùng BNT, Khải NC, Anh TPT, Trọng TT, Đại LQ, Đ Duy H. Xác định vị trí và mức độ suy giảm độ cứng trong kết cấu tấm dầm trên phương pháp năng lượng biến dạng và mạng nơ-ron tích chập. *Tạp chí Khoa học và Công nghệ Trường Đại học Xây dựng Miền Tây*. 2025;14(3):39–45. Available from: <https://doi.org/10.66195/mtu.2025.14.123>.
- Tran MH, Bach VS, Luu TH, Nguyen CK, Chiêm HH, Vu KH, et al. A novel approach for identifying structural damage in beams with diverse boundary conditions using modal strain energy method combined with convolutional neural networks. *Structures (Oxford)*. 2025;80. Available from: <https://doi.org/10.1016/j.istruc.2025.110062>.
- Seyedpoor SM. A two-stage method for structural damage detection using a modal strain energy-based index and particle swarm optimization. *International Journal of Non-linear Mechanics*. 2012;47(1):1–8. Available from: <https://doi.org/10.1016/j.ijnonlinmec.2011.07.011>.
- Kiranyaz S, Avci O, Abdeljaber O, Ince T, Gabbouj M, Inman DJ. 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*. 2021;151:107398. Available from: <https://doi.org/10.1016/j.ymssp.2020.107398>.
- Abdeljaber O, Avci O, Kiranyaz MS, Boashash B, Sodano H, Inman DJ. 1-D CNNs for structural damage detection: verification on a structural health monitoring benchmark data. *Neurocomputing*. 2018;275:1308–17. Available from: <https://doi.org/10.1016/j.neucom.2017.09.069>.
- Shubham K, Metya S, Sinha AK, Gobinath R. One-dimensional convolutional neural network (1D-CNN) based reliability analysis of foundation over cavity incorporating the effect of simulated noise. *Advances in Civil Engineering*. 2024;2024:20 pages. Available from: <https://doi.org/10.1155/2024/9981433>.
- Cha YJ, Buyukozturk O. Structural damage detection using modal strain energy and hybrid multiobjective optimization. *Computer-Aided Civil and Infrastructure Engineering*. 2015;30(5):347–58. Available from: <https://doi.org/10.1111/mice.12122>.

One-step structural damage detection in spatial frames using modal strain energy and 1D-CNN

Van-Sy Bach^{1,2,3}, Tuan-Dat Lam^{1,2,*}, Thi-Truc-Ngan Nguyen^{1,2}, Van-Nhat-Thanh Bui^{1,2},
Van-Tuong-Khanh Vo^{1,2}, Nhat-Quang Nguyen^{1,2}, Tran-Huu-Tin Luu^{1,2,4}, Duc-Duy Ho^{1,2}



Use your smartphone to scan this
QR code and download this article

ABSTRACT

Structural health monitoring plays a crucial role in the early detection of structural damage, ensuring operational safety, and supporting structural maintenance. However, current vibration-based damage identification methods have relied on a two-step procedure, including damage localization and damage severity quantification, which may increase computational cost. This paper proposes a one-step damage identification procedure that simultaneously determines the location and severity of element-level damage in a three-dimensional frame structure, using strain energy features and a one-dimensional convolutional neural network (1D-CNN). The input data are constructed from element strain energy, which is calculated from mode shapes obtained through numerical simulation. The 1D-CNN model is used to extract features and predict the damage state of structural elements. To evaluate the proposed procedure, a three-dimensional steel frame consisting of 52 elements is investigated with two input data cases: using six mode shapes and using the first two mode shapes. The training results show that the model achieves good prediction performance, with average R^2 values of 99% for the training set and 98% for the testing set. In addition, through the assessment of damage identification errors for 250 damage cases involving one to five damaged elements, the proposed procedure demonstrates its ability to accurately identify damage locations, with the average error in predicting damage severity ranging from 1% to 5%. The identification results show that using only the first two mode shapes provides results nearly equivalent to those obtained with six mode shapes, thereby demonstrating the feasibility of the proposed procedure for practical implementation.

Key words: Damage detection, modal strain energy, convolutional neural network, space frame

¹Faculty of Civil Engineering, Ho Chi Minh City University of Technology (HCMUT), Ho Chi Minh City, Vietnam

²Vietnam National University Ho Chi Minh City, Ho Chi Minh City, Vietnam

³Faculty of Civil Engineering, Nha Trang University, Khanh Hoa Province, Vietnam

⁴Faculty of Engineering Technology, Tien Giang University, Dong Thap Province, Vietnam

Correspondence

Tuan-Dat Lam, Faculty of Civil Engineering, Ho Chi Minh City University of Technology (HCMUT), Ho Chi Minh City, Vietnam

Vietnam National University Ho Chi Minh City, Ho Chi Minh City, Vietnam

Email: ltdat.sdh242@hcmut.edu.vn

History

- Received: 09-04-2026
- Revised: 27-05-2026
- Accepted: 26-06-2026
- Published Online: 04-08-2026

DOI : <https://doi.org/10.32508/vnuhcmj-et.v9i3.1592>



Copyright

© VNUHCM Journal. This is an open-access article distributed under the terms of the Creative Commons Attribution 4.0 International license.

Cite this article : Bach V S, Lam T D, Nguyen T T N, Bui V N T, Vo V T K, Nguyen N Q, Luu T H T, Ho D D. **One-step structural damage detection in spatial frames using modal strain energy and 1D-CNN.** *VNUHCM J. Eng. Technol.* 2026; 9(3):3097-3106.