



Nghiên cứu chẩn đoán các hư hỏng của kết cấu khung thép bằng mạng nơ-ron nhân tạo cải tiến

Study of diagnosing damages in steel frame structures using improved Artificial Neural Network

Nguyễn Hữu Khải¹, Ngô Văn Thức^{1,*}

¹ Trường Đại học Xây dựng Miền Tây

Từ khóa:

TÓM TẮT

Giám sát sức khỏe kết cấu (SHM)
Mạng nơ-ron nhân tạo (ANN)
Thuật toán tối ưu PSO-GA
Mạng tự mã hóa (Autoencoder)
Chẩn đoán hư hỏng

Giám sát sức khỏe kết cấu (SHM) là hướng tiếp cận quan trọng nhằm theo dõi và cảnh báo sớm các dấu hiệu xuống cấp của công trình. Tuy nhiên, dữ liệu dao động thực tế thường không đầy đủ do giới hạn về cảm biến, gây khó khăn cho việc chẩn đoán chính xác. Nghiên cứu này đề xuất mô hình mạng nơ-ron nhân tạo cải tiến (ANN-PSO-GA-AE), tích hợp thuật toán tối ưu PSO-GA và mạng tự mã hóa Autoencoder nhằm cải thiện khả năng dự đoán trong điều kiện dữ liệu bị giới hạn. Mô hình có thể xác định đồng thời vị trí phần tử hư hỏng và mức độ suy giảm độ cứng từ dữ liệu dao động không đầy đủ. Kết quả kiểm chứng trên mô hình kết cấu khung thép bốn tầng cho thấy mô hình vẫn duy trì độ chính xác ổn định và khả năng tổng quát hóa tốt. Đây là hướng tiếp cận có tiềm năng ứng dụng trong các hệ thống SHM thực tế, đặc biệt tại các công trình dân dụng và công nghiệp, nơi điều kiện đo đạc thường bị hạn chế.

Keywords:

ABSTRACT

Structural Health Monitoring (SHM)
Artificial Neural Networks (ANN)
Particle Swarm Optimization-Genetic Algorithm (PSO-GA)
Autoencoder
Damage Diagnosis

Structural Health Monitoring (SHM) is a crucial approach for tracking and providing early warnings of structural degradation in civil infrastructure. However, in real-world applications, vibration data are often incomplete due to sensor limitations, making accurate damage diagnosis challenging. This study proposes an improved artificial neural network model (ANN-PSO-GA-AE), which integrates a hybrid Particle Swarm Optimization-Genetic Algorithm and an Autoencoder to enhance prediction performance under limited data conditions. The model is capable of simultaneously identifying the damaged structural element and estimating its stiffness reduction from incomplete vibration data. Validation on a four-story steel frame structure demonstrates that the proposed model maintains stable accuracy and generalization capability, even when full measurement data are not available. This approach shows strong potential for application in practical SHM systems, particularly in civil and industrial structures where sensor deployment is constrained.

* Ngô Văn Thức. Trường Đại học Xây dựng Miền Tây
Email: ngovanthuc@mtu.edu.vn

<https://www.doi.org/10.55228/JTST150102>

Ngày nhận bài: 09/05/2025; Ngày nộp bài sửa: 03/08/2025; Ngày chấp nhận đăng: 01/12/2025

Ngày xuất bản trực tuyến: 15/01/2026

pISSN: 1859-4263; eISSN: 3030-4261

1. Đặt vấn đề

Giám sát sức khỏe kết cấu (Structural Health Monitoring – SHM) là một lĩnh vực nghiên cứu và ứng dụng quan trọng nhằm đảm bảo an toàn, kéo dài tuổi thọ và tối ưu hóa chi phí bảo trì cho các công trình xây dựng. Thông qua việc theo dõi liên tục các tham số dao động, ứng suất, biến dạng hoặc dịch chuyển, SHM cho phép phát hiện sớm các dấu hiệu bất thường trong kết cấu, từ đó đưa ra các quyết định can thiệp kịp thời [1]. Trong những năm gần đây, nhu cầu triển khai các hệ thống SHM tại Việt Nam ngày càng gia tăng, đặc biệt đối với các công trình quy mô lớn như cầu dây văng, nhà cao tầng, hoặc các kết cấu công nghiệp [2].

Trong số các phương pháp tiếp cận trong SHM, kỹ thuật phân tích dao động được coi là một công cụ mạnh mẽ nhờ khả năng phản ánh trực tiếp sự thay đổi của độ cứng kết cấu thông qua các đặc trưng như tần số dao động riêng và dạng dao động [3]. Tuy nhiên, dữ liệu đo đạc thực tế trong SHM thường gặp phải các thách thức như nhiễu, mất mát dữ liệu hoặc sai lệch do điều kiện môi trường, gây ảnh hưởng đến độ tin cậy của các phương pháp truyền thống [4].

Để vượt qua các hạn chế trên, việc ứng dụng trí tuệ nhân tạo (Artificial Intelligence – AI), đặc biệt là mạng nơ-ron nhân tạo (Artificial Neural Networks – ANN), đã nhận được sự quan tâm rộng rãi trong cộng đồng nghiên cứu SHM. ANN có khả năng học và mô hình hóa các mối quan hệ phi tuyến phức tạp giữa dữ liệu đầu vào và trạng thái kết cấu, từ đó hỗ trợ dự đoán vị trí, mức độ hư hỏng một cách hiệu quả [5]. Nhiều nghiên cứu đã chỉ ra rằng ANN có thể đạt được độ chính xác cao trong bài toán nhận dạng hư hỏng, ngay cả khi dữ liệu đầu vào bị nhiễu hoặc không hoàn chỉnh [6].

Tuy nhiên, ANN truyền thống vẫn tồn tại một số hạn chế như quá trình huấn luyện dễ mắc kẹt tại các điểm cực trị cục bộ, phụ thuộc mạnh vào khởi tạo trọng số ban đầu và siêu tham số học, dẫn đến hiệu suất không ổn định [7]. Để khắc phục nhược điểm này, nhiều nghiên cứu đã tích cực đề xuất kết hợp ANN với các thuật toán tối ưu hóa toàn cục nhằm cải thiện khả năng hội tụ và độ chính xác của mô hình.

Trong đó, thuật toán lai PSO-GA đã được chứng minh là một công cụ hiệu quả, tận dụng được khả năng tìm kiếm toàn cục nhanh chóng của Particle

Swarm Optimization (PSO) và khả năng khai thác cực bộ chi tiết của Genetic Algorithm (GA) [3], [8]. Ứng dụng PSO-GA trong huấn luyện mạng nơ-ron không những giúp tối ưu hóa trọng số và bias mạng, mà còn giảm thiểu nguy cơ rơi vào cực trị cục bộ, từ đó nâng cao khả năng dự đoán chính xác trạng thái kết cấu [3], [8].

Song song với các kỹ thuật tối ưu hóa, các phương pháp học sâu không giám sát như Autoencoder cũng được ứng dụng mạnh mẽ trong SHM. Autoencoder có khả năng nén và tái tạo dữ liệu, từ đó hỗ trợ làm sạch tín hiệu, phát hiện bất thường, và trích xuất các đặc trưng tiềm ẩn có ý nghĩa trong dữ liệu cảm biến [9], [10]. Ứng dụng Autoencoder đặc biệt hữu ích trong bối cảnh dữ liệu đo dao động thực tế thường không đầy đủ hoặc bị nhiễu loạn mạnh.

Mặc dù đã có nhiều nghiên cứu sử dụng ANN kết hợp với PSO hoặc GA để tối ưu trọng số và tham số huấn luyện trong bài toán SHM, cũng như một số công trình gần đây ứng dụng Autoencoder để xử lý dữ liệu cảm biến bị thiếu hoặc nhiễu, tuy nhiên phần lớn các nghiên cứu hiện tại chỉ triển khai từng kỹ thuật này một cách riêng lẻ hoặc trong các bước tách biệt.

PSO là một thuật toán tìm kiếm toàn cục có tốc độ hội tụ nhanh nhưng nhược điểm dễ phát hiện sớm và hiệu suất tính toán thấp. Trong khi đó, GA có khả năng duy trì tính đa dạng thông qua các phép lai và đột biến, nhưng lại hội tụ chậm hơn, và hiệu quả suy giảm nếu không được kết hợp với chiến lược khai thác tốt [3], [8]. Về phía Autoencoder không trực tiếp dự đoán mức độ hay vị trí hư hỏng. Khi dùng riêng, Autoencoder chỉ đóng vai trò tiền xử lý dữ liệu mà không thể thay thế mô hình dự đoán đầu ra hoặc đảm nhiệm vai trò phân loại – hồi quy [9], [10].

Khi sử dụng riêng lẻ, các kỹ thuật trên thường không đủ mạnh để xử lý các bài toán SHM thực tế, vốn chứa nhiều nhiễu và thiếu dữ liệu. Trên cơ sở đó, nghiên cứu này đề xuất mô hình mạng nơ-ron nhân tạo cải tiến, kết hợp đồng thời giữa PSO-GA và Autoencoder, nhằm mục tiêu nâng cao hiệu quả chẩn đoán hư hỏng. Autoencoder đảm nhận vai trò tiền xử lý, giúp phục hồi dữ liệu đặc trưng dao động bị thiếu – vốn là tình trạng phổ biến trong hệ thống SHM thực tế do giới hạn số lượng cảm biến hoặc nhiễu tín hiệu. Nhờ tái tạo dữ liệu đầy đủ và trích xuất đặc trưng ẩn,

Autoencoder cung cấp đầu vào nhất quán, đầy đủ và ít nhiễu hơn cho mô hình học máy phía sau Đồng thời, PSO-GA cải thiện khả năng hội tụ và độ chính xác của mạng ANN, giúp thích ứng tốt hơn với dữ liệu đã được phục hồi bởi Autoencoder, nhờ khả năng tìm kiếm không gian siêu tham số hiệu quả. Tính bổ sung này đảm bảo toàn bộ hệ thống vừa có khả năng học sâu, vừa chống chịu với dữ liệu không hoàn chỉnh, đồng thời đạt được hiệu quả tối ưu trong quá trình huấn luyện.

Để kiểm tra tính hiệu quả của các thuật toán, nghiên cứu đã sử dụng dữ liệu đầu vào từ kết quả mô phỏng dao động tự nhiên của kết cấu khung thép bốn tầng, với các kích bản hư hỏng mô phỏng dưới dạng suy giảm độ cứng phần tử từ 1% đến 70%.

Bài toán đặt ra bao gồm hai nhiệm vụ chính: (i) phân loại đúng vị trí phần tử hư hỏng trong mô hình kết cấu, và (ii) ước lượng chính xác mức độ suy giảm độ cứng tại vị trí đó. Việc đồng thời thực hiện bài toán phân loại và hồi quy đòi hỏi mô hình học máy phải có khả năng học đặc trưng sâu sắc, khả năng tổng quát hóa cao, cũng như khả năng chống chịu với dữ liệu nhiễu.

Mô hình ANN cải tiến được huấn luyện và đánh giá thông qua so sánh với hai mô hình đối chứng: ANN truyền thống và ANN kết hợp PSO-GA. Các chỉ số đánh giá hiệu quả bao gồm hệ số tương quan hồi quy (R), sai số trung bình bình phương (MSE), và sai số tuyệt đối trung bình (MAE).

Phần còn lại của bài báo được tổ chức như sau: Phần 2 trình bày chi tiết kiến trúc mạng cải tiến, thuật toán tối ưu hóa PSO-GA và cơ chế Autoencoder. Phần

3 mô tả quá trình xây dựng mô hình kết cấu, mô phỏng các trường hợp hư hỏng, quá trình huấn luyện và kiểm tra mô hình. Phần 4 thảo luận kết quả và đưa ra kết luận cũng như hướng nghiên cứu tương lai.

2. Mô hình mạng cải tiến

2.1. Thuật toán PSO-GA

Mạng nơ-ron truyền thống thường gặp hạn chế trong khả năng hội tụ và dễ rơi vào cực trị cục bộ khi huấn luyện bằng phương pháp lan truyền ngược. Để khắc phục vấn đề này, nghiên cứu đề xuất sử dụng thuật toán tối ưu lai PSO-GA để tìm ra tổ hợp trọng số và bias phù hợp cho mô hình ANN [3].

Thuật toán PSO-GA kết hợp giữa tìm kiếm toàn cục của Particle Swarm Optimization (PSO) và khai thác cục bộ của Genetic Algorithm (GA). Trong quá trình tiến hóa, các phép lai ghép và đột biến được áp dụng nhằm duy trì tính đa dạng quần thể và cải thiện tốc độ hội tụ.

Cụ thể, quá trình lai ghép giữa hai cá thể cha mẹ được thực hiện theo biểu thức sau [3]:

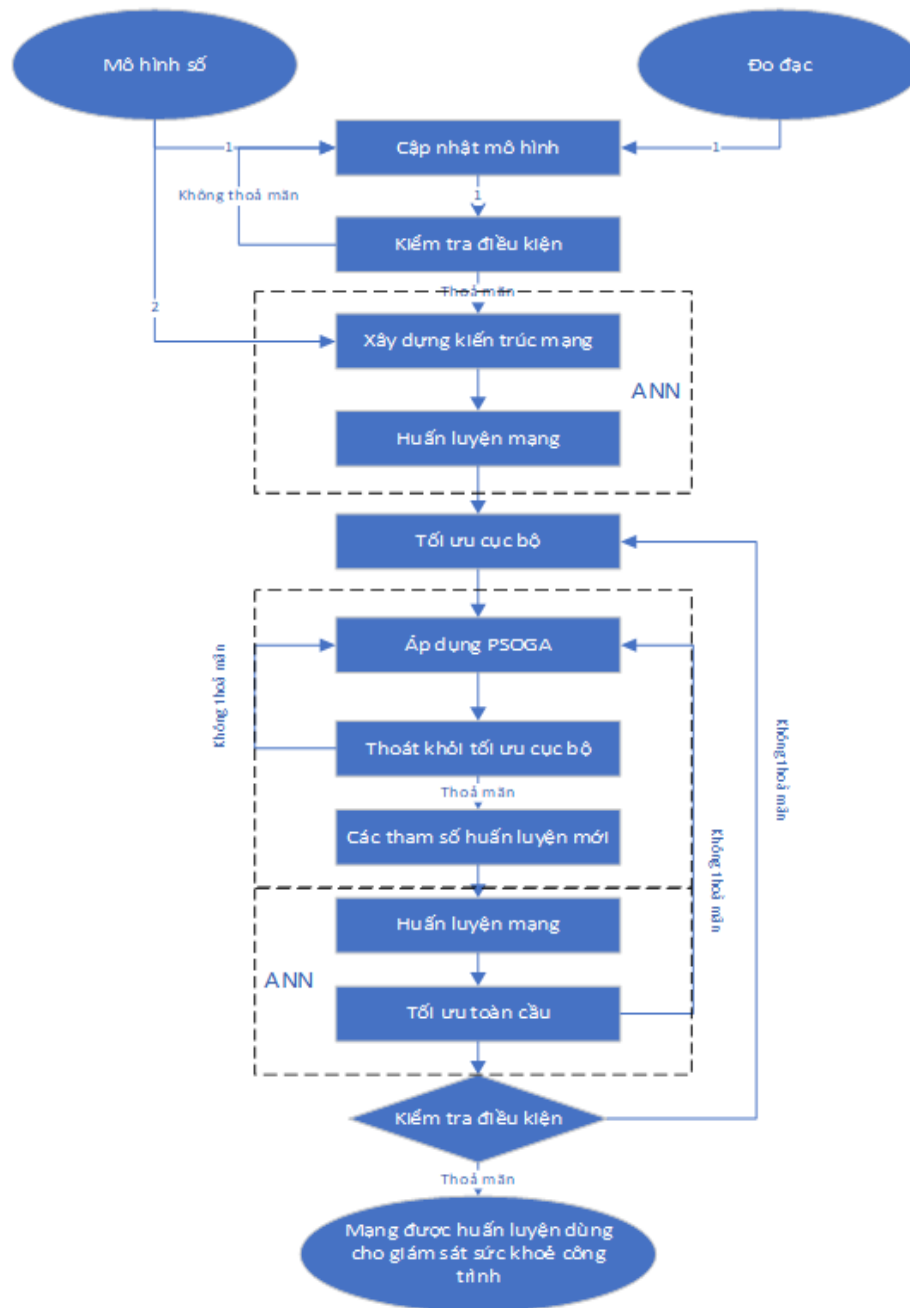
$$x_{child} = a \cdot x_{parent1} + a \cdot x_{parent2} \quad a \in [0,1] \quad (1)$$

Với $a \in [0,1]$ là hệ số trọng số ngẫu nhiên. Sau đó, cá thể con có thể được đột biến theo biểu thức:

$$x_j^{new} = x_j + \sigma \cdot N[0, 1] \quad (2)$$

Với, σ là hệ số điều chỉnh và $N[0, 1]$ là biến ngẫu nhiên phân phối chuẩn.

Quy trình tổng quát của thuật toán PSO-GA trong việc huấn luyện mạng ANN được minh họa trong Hình 1.



Hình 1. Sơ đồ hoạt động của ANN-PSO-GA [3].

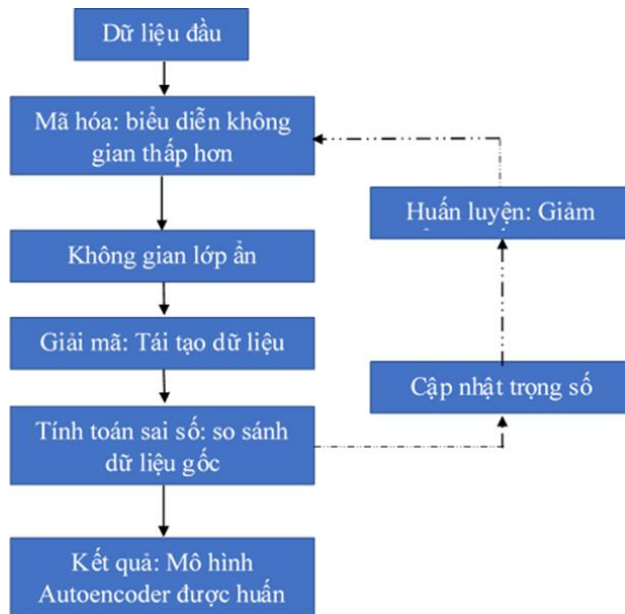
2.2. Thuật toán Autoencoder

Để giải quyết hạn chế trong việc đo đồng thời toàn bộ 20 mode dao động, nghiên cứu ứng dụng Autoencoder (AE) để nén dữ liệu đầu vào và tái tạo các đặc trưng phi tuyến cần thiết cho việc huấn luyện mạng ANN [9], [10]. Mạng AE được huấn luyện từ tập đầy đủ 20 dao động, với mục tiêu nén thông tin vào không gian tiềm ẩn 10 chiều.

Sau khi huấn luyện xong, tầng mã hóa (encoder) được sử dụng để rút trích 10 đặc trưng từ 20 mode đầu vào. Các đặc trưng này sau đó được ghép với 10

mode đo thực tế để tạo thành bộ đầu vào đầy đủ gồm 20 thành phần cho mô hình ANN-PSO-GA.

Kiến trúc Autoencoder sử dụng trong nghiên cứu có cấu trúc 20-10-20 và được trình bày trong Hình 2.



Hình 2. Sơ đồ hoạt động của Autoencoder.

2.3. Mô hình ANN-PSO-GA-AE

Mô hình đề xuất trong nghiên cứu này là một mô hình học máy kết hợp, gọi tắt là ANN-PSO-GA-AE, nhằm xử lý hiệu quả các thách thức trong chẩn đoán hư hỏng kết cấu từ dữ liệu dao động. Mô hình vận hành theo chuỗi xử lý gồm ba khối chức năng Cấu trúc mô hình vận hành theo chuỗi gồm ba giai đoạn chính: (i) phục hồi và chuẩn hóa dữ liệu, (ii) suy luận trạng thái kết cấu, và (iii) tối ưu hoá mô hình học.

Trong giai đoạn (i), Autoencoder đóng vai trò tiền xử lý, giúp tái tạo các mode dao động bị thiếu thông qua cơ chế học không giám sát. Điều này đặc biệt hữu ích khi chỉ đo được một phần mode dao động do hạn chế số lượng cảm biến hoặc điều kiện đo thực tế. Dữ liệu đầy đủ sau AE được đưa vào ANN để huấn luyện.

Giai đoạn (ii) sử dụng mạng ANN để thực hiện bài toán chẩn đoán đồng thời vị trí và mức độ hư hỏng – tức là mô hình vừa phân loại vừa hồi quy. Mạng được


thiết kế với nhiều lớp ẩn có khả năng học phi tuyến mạnh, nhưng hiệu quả phụ thuộc lớn vào cấu trúc và khởi tạo tham số.

Giai đoạn (iii) ứng dụng thuật toán tối ưu hóa lai PSO-GA để tự động điều chỉnh toàn bộ trọng số, bias, và các tham số của ANN. Thuật toán này kết hợp ưu điểm của PSO và GA, giúp tăng độ chính xác, ổn định quá trình học và giảm nguy cơ kẹt cục bộ.

3. Mô phỏng và đánh giá kết quả

3.1. Mô hình mô phỏng và cấu hình huấn luyện

Mô hình kết cấu khung thép bốn tầng được xây dựng nhằm thu thập dữ liệu dao động đầu vào cho huấn luyện mạng. Mô hình kết cấu sử dụng trong nghiên cứu là khung thép không gian bốn tầng, được thiết kế với các thông số vật liệu phổ biến cho thép kết cấu: mô đun đàn hồi $E=210 \times 10^9 \text{ N/m}^2$, khối lượng riêng $\rho = 7850 \text{ kg/m}^3$ và hệ số Poisson là 0.3. Các cấu kiện cột chính thép I400×200×8×13 mm, dầm ngang được tiết diện I350×175×7×11 mm. Hệ khung được thiết kế với 5 trục chính chạy dọc theo chiều dài nhà và chia thành 4 tầng theo phương đứng. Liên kết giữa dầm và cột sử dụng bản mã liên kết bu lông, liên kết tại chân cột được mô phỏng là liên kết ngàm cố định, phản ánh đúng điều kiện làm việc thường thấy giữa cột thép và móng bê tông cốt thép trong các công trình thực tế. Để mô phỏng dao động kết cấu trong nghiên cứu này, tác giả áp dụng phương pháp phần tử hữu hạn (FEM) để giải bài toán trị riêng xác định các tần số dao động của mô hình nhà khung thép bốn tầng. Các kích bản hư hỏng được mô phỏng bằng cách giảm độ cứng từng phần tử theo từng bước từ 1% đến 70%, tạo ra tập dữ liệu với nhiều mức độ tổn thương. Hình ảnh mô hình số hóa được thể hiện trong Hình 3.



Hình 3. Mô phỏng kết cấu khung thép nhà 4 tầng.

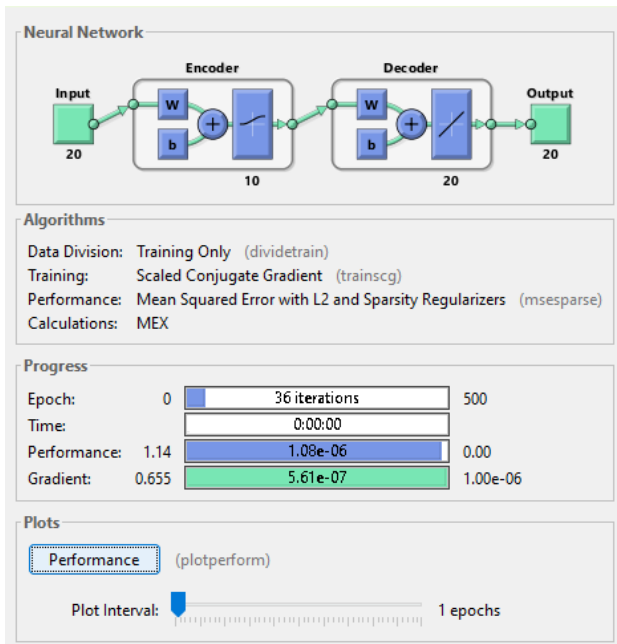
Tập dữ liệu được chuẩn hóa và phân chia theo tỷ lệ 80% huấn luyện và 20% kiểm tra. Quá trình xử lý dữ liệu đầu vào, chuẩn hóa và cấu trúc output được thực hiện trực tiếp trong môi trường MATLAB. Mỗi mẫu bao gồm 20 mode dao động đầu tiên làm đầu vào và hai đầu ra: vị trí phần tử hư hỏng (dạng phân loại) và mức suy giảm độ cứng (dạng hồi quy).

Quá trình huấn luyện mô hình diễn ra trong hai giai đoạn liên tiếp. Giai đoạn đầu xử lý đặc trưng dữ liệu để khắc phục giới hạn đo mode shape trong thực tế. Giai đoạn sau là huấn luyện mạng chính và tìm kiếm cấu hình trọng số phù hợp.

Trong giai đoạn (i), Các thông số kỹ thuật của thuật toán được tổng hợp trong Bảng 1 và quá trình huấn luyện trong Matlab như Hình 4.

Bảng 1. Cấu trúc mạng Autoencoder.

Nội dung	Ký hiệu	Giá trị
Tầng đầu vào – 20 giá trị mode dao động ban đầu	Input layer	20
Tầng mã hóa - Trích đặc trưng và nén xuống không gian tiềm ẩn 10 mode	Encoder	10
Tầng giải mã – Giải mã các mode đã nén ứng với 20 giá trị ban đầu	Decoder	20



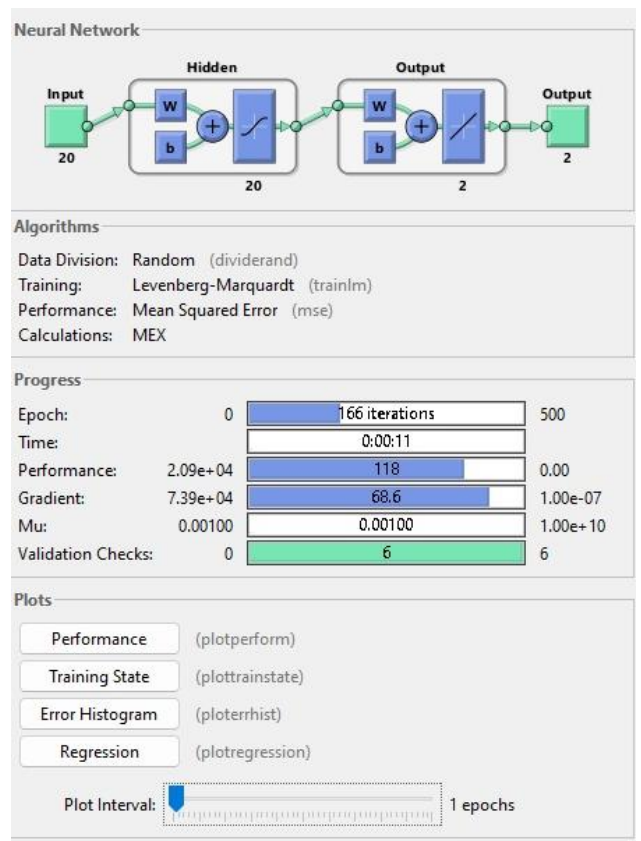
Hình 4. Giao diện huấn luyện Autoencoder.

Trong giai đoạn (ii) và (iii), Các thông số mạng được lựa chọn thông qua phương pháp thử sai từ nhiều giá trị. Kết quả cho thấy với việc chuẩn đoán vị trí và mức độ hư hỏng trong nghiên cứu này thì số lớp ẩn 20 mang lại hiệu suất cao và ổn định nhất. Đồng thời, Thuật toán tối ưu PSO-GA, kích thước quần thể được đặt là 50, hệ số quán tính là 1, thông số lai ghép GA $P_c = 0,7$ và hệ số đột biến $\sigma = 0,1$ cũng được hiệu chỉnh trong quá trình thử nghiệm. Các thông số kỹ thuật của thuật toán được tổng hợp trong Bảng 2 và quá trình huấn luyện trong Matlab như Hình 5.

Bảng 2. Cấu mạng ANN và thuật toán tối ưu PSO-GA.

Nội dung	Ký hiệu	Giá trị
Lớp đầu vào - 10 mode giá trị ban đầu và 10 mode tái tạo	Inputs	20
Lớp ẩn - lớp ẩn học các quan hệ phi tuyến giữa đầu vào và đầu ra	Hidden number	20
Lớp đầu ra - kết quả dự đoán mức độ và vị trí hư hỏng	targets	2
Số vòng lặp	Number of epochs	500
Số vòng lặp tối đa của PSO	MaxIt	200
Kích thước quần thể	nPop	50
Hệ số học hỏi cá nhân	c1	1,5
Hệ số học hỏi toàn cục	c2	2,2
Hệ số quán tính	w	1

Tỉ lệ giảm quán tính	wdamp	0,99
Tỉ lệ lai - Tỷ lệ quần thể tham gia quá trình lai chéo	Pc	0,7
Số cá thể lai - Số lượng cá thể sinh ra từ phép lai	nc	$2 * \text{round}(pc * nPop / 2)$
Biên độ mở rộng lai	gamma	0,45
Tỉ lệ đột biến	pm	0,3
Số cá thể đột biến - Số lượng cá thể sẽ bị thay đổi do đột biến	nm	$\text{round}(pm * nPop)$
Tỷ lệ đột biến - Cường độ thay đổi gen trong phép đột biến	mu	0,1



Hình 5. Giao diện huấn luyện ANN-PSO-GA-AE.

Ngoài ra, để đánh giá mức độ ảnh hưởng của từng biến đầu vào đến kết quả dự đoán, mô hình được kiểm tra độ nhạy bằng cách loại bỏ lần lượt từng mode dao động trong tập dữ liệu đầu vào. Khi loại bỏ các mode dao động bậc cao (từ mode 10 trở lên), độ chính xác của mô hình giảm đáng kể - biểu hiện qua tăng MSE và giảm hệ số R, cho thấy những mode này chứa thông tin quan trọng giúp mô hình nhận diện chính xác hư hỏng cục bộ. Trong khi đó, khi loại bỏ các mode bậc thấp hơn (mode 1-5), độ chính xác chỉ

giảm nhẹ. Kết quả này khẳng định rằng mô hình nhạy nhất với các đặc trưng dạng mode trung bình – cao, đây là cơ sở quan trọng giúp định hướng việc lựa chọn và sắp xếp cảm biến khi triển khai thực tế hệ thống SHM.

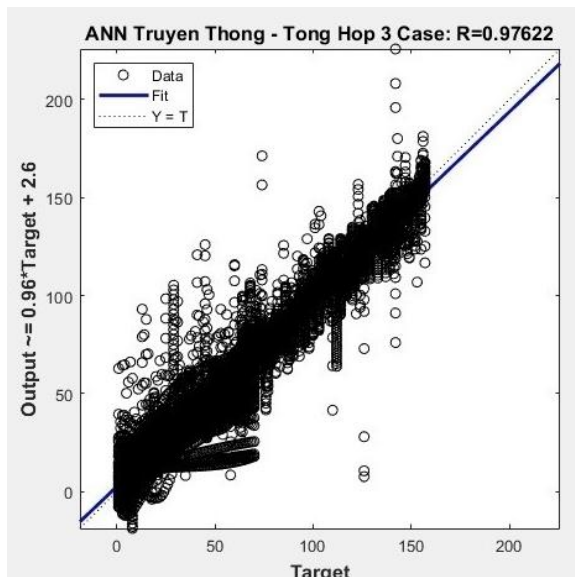
3.2. Đánh giá và so sánh kết quả

Mô hình ANN-PSO-GA-AE được thiết lập nhằm thực hiện đồng thời hai nhiệm vụ trong giám sát kết cấu khung thép: (1) xác định vị trí phần tử bị hư hỏng (phân loại), và (2) dự đoán mức độ suy giảm độ cứng tại vị trí đó (hồi quy). Dữ liệu đầu vào bao gồm 20 đặc trưng dao động, trong đó 10 đặc trưng dao động gốc trích từ mô phỏng và 10 đặc trưng dao động được tái tạo bằng Autoencoder từ không gian đặc trưng nén.


Khác với các mô hình đối chứng, mô hình đề xuất sử dụng AE để bù đắp phần thiếu hụt trong dữ liệu dao động, cho phép dự đoán trong điều kiện không thể đo đủ toàn bộ mode. Điều này phản ánh rõ trong khả năng duy trì độ chính xác hồi quy ngay cả khi đầu vào không đầy đủ.

Kết quả thử nghiệm cho thấy mô hình ANN-PSO-GA-AE đạt hệ số tương quan tổng thể $R = 0.9493$ (hình 6c), thấp hơn so với ANN $R=0.97622$ (hình 6.a) và ANN-PSO-GA $R = 0.98219$ (hình 6.b), nhưng các biểu đồ hồi quy (Hình 6) vẫn cho thấy đầu ra tập trung quanh đường lý tưởng, phản ánh khả năng học đặc trưng hiệu quả. Đồng thời, biểu đồ phân bố sai số (Hình 7) cho thấy phần lớn dự đoán dao động trong khoảng sai số nhỏ, chứng minh khả năng định lượng mức độ hư hỏng ổn định.

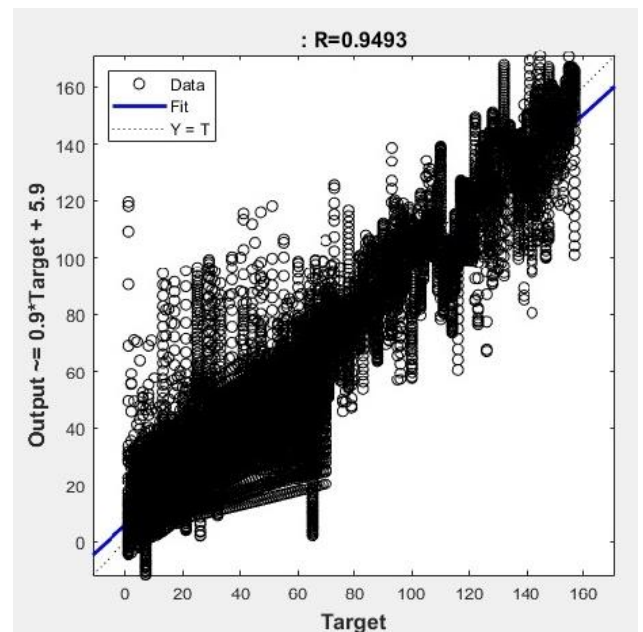
a)



b)




c)




Hình 6. Biểu đồ Hồi quy đầu ra của 3 mô hình. (a) Mô hình ANN truyền thống, (b) Mô hình ANN-PSO-GA, (c) Mô hình ANN-PSO-GA-AE.

a)




Mô hình ANN-PSO-GA-AE dự đoán chính xác mức độ tổn thương với $R_{test} = 0.9425$ (hình 8) trong điều kiện đầu vào thiếu 10 mode là minh chứng cho khả năng chẩn đoán thực tế khả thi.


a)




b)




b)




c)



c)

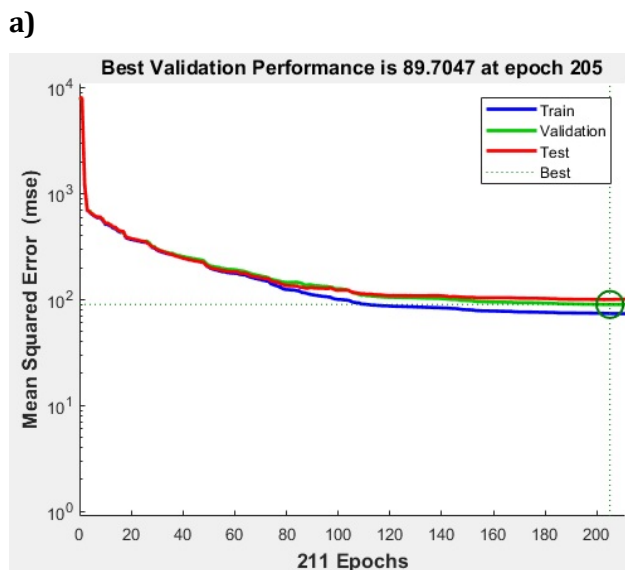


Hình 7. Biểu đồ phân bố sai số của 3 mô hình. (a) Mô hình ANN truyền thống, (b) Mô hình ANN-PSO-GA, (c) Mô hình ANN-PSO-GA-AE.





Hình 8. Biểu đồ các giá trị hồi quy ANN-PSO-GA-AE. (a) Giá trị R_{Training} , (b) Giá trị $R_{\text{validation}}$, (c) Giá trị R_{test} , (d) giá trị R_{all} .

Cuối cùng, mô hình được huấn luyện và triển khai trên hệ thống cấu hình phổ thông (CPU i5-10400, RAM 16GB, Windows 10) với môi trường MATLAB. Thời gian huấn luyện trung bình cho mỗi kịch bản vào khoảng 3-5 phút với số vòng lặp nhỏ (96-120 epoch), và thời gian dự đoán cho mỗi mẫu chỉ dưới 1 giây. Điều này cho thấy chi phí tính toán và tài nguyên phần cứng không cao, hoàn toàn khả thi để tích hợp vào các hệ thống SHM bán thời gian thực. Tốc độ hội tụ nhanh cũng được thể hiện rõ trong biểu đồ huấn luyện (Hình 9c), xác nhận mô hình hội tụ ổn định, không bị overfitting, với số epoch dừng sớm là 96, và MSE nhỏ nhất là 151.95.

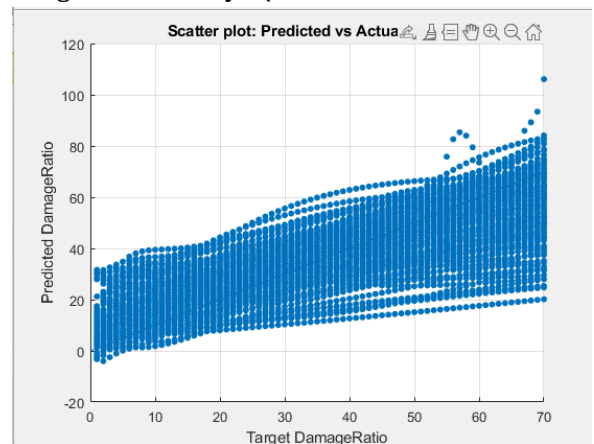


Hình 9. Biểu đồ huấn luyện sai số kiểm định của 3 mô hình. (a) Mô hình ANN truyền thống, (b) Mô hình ANN-PSO-GA, (c) Mô hình ANN-PSO-GA-AE.



Hình 9. Biểu đồ huấn luyện sai số kiểm định của 3 mô hình. (a) Mô hình ANN truyền thống, (b) Mô hình ANN-PSO-GA, (c) Mô hình ANN-PSO-GA-AE.

Biểu đồ tương quan giữa giá trị thực tế và giá trị dự đoán (Hình 10) cho thấy các điểm phân bố gần đường chéo cho thấy độ chính xác cao.



Hình 10. Biểu đồ tương quan giữa giá trị thực tế và giá trị dự đoán bởi mô hình ANN-PSO-GA-AE.

Sai số dự đoán được kiểm định thống kê bằng kiểm định t (t-test) một mẫu với giả thuyết H_0 : sai số trung bình bằng 0. Kết quả kiểm định cho p-value = 0.0656, lớn hơn mức ý nghĩa 0.05, tức không đủ bằng chứng để bác bỏ H_0 . Điều này cho thấy sai số trung bình không khác biệt có ý nghĩa so với 0, hàm ý rằng mô hình không có xu hướng dự đoán lệch về một phía.

Những kết quả trên không chỉ bổ sung tính toàn diện cho phân tích đánh giá mô hình, mà còn làm rõ tính khả thi khi ứng dụng mô hình ANN-PSO-GA-AE vào các hệ thống giám sát thực tế, nơi yêu cầu cao về thời gian phản hồi và chi phí phần cứng thấp. Bên cạnh đó, việc sử dụng Autoencoder. Trong quá trình thử nghiệm, mô hình có thể xử lý và dự đoán từng mẫu đầu vào trong thời gian ngắn (dưới một giây), mở ra tiềm năng tích hợp vào các hệ thống giám sát thời gian thực.

Sau khi hoàn tất quá trình huấn luyện và kiểm tra, các mô hình mạng nơ-ron được đề xuất không chỉ được đánh giá nội tại dựa trên các chỉ số như hệ số tương quan hồi quy (R), sai số bình phương trung bình (MSE), và sai số tuyệt đối trung bình (MAE), mà còn được đối chiếu với các phương pháp đã công bố trong cùng lĩnh vực.

Bảng 3 trình bày kết quả so sánh giữa mô hình ANN-PSO-GA-AE với các phương pháp khác, bao gồm ANN thông thường [11] và ANN kết hợp Autoencoder + Deep Learning [12].

Bảng 3. So sánh giữa mô hình ANN-PSO-GA-AE và các phương pháp khác.

Hạng mục	ANN-PSO-GA-AE	ANN [11]	ANN-AE-DL[12]
Kết cấu	Khung thép 4 tầng	Khung thép	Khung thép
Nguồn dữ liệu đầu vào	Mode shape (dao động) từ mô phỏng và tái tạo	Gia tốc dao động → EEMD + Hilbert Transform	Gia tốc và đặc trưng giảm chiều từ AE
Mục tiêu dự đoán	Vị trí hư hỏng, mức độ hư hỏng	Mức độ hư hỏng	Mức độ hư hỏng & độ cứng
Hệ số hồi quy R	0.9493	0.99	0.794– 0.711
MSE	151,95	0.0016	3.6e-4 đến 5.2e-4

Khác với các nghiên cứu trước chỉ tập trung vào một mục tiêu dự đoán (vị trí hoặc mức độ hư hỏng), mô hình này xử lý đồng thời cả hai bài toán phân loại và hồi quy, mở rộng phạm vi ứng dụng thực tế. So với các nghiên cứu khác, mô hình đề xuất có độ chính xác cao hơn trong điều kiện dữ liệu thiếu, đồng thời linh hoạt hơn khi triển khai trong môi trường đo đạc thực tế có nhiễu và hạn chế cảm biến. Đồng thời, việc tích hợp PSO-GA giúp cải thiện tốc độ hội tụ và tránh hiện tượng rơi vào cực trị cục bộ trong quá trình huấn luyện mạng.

4. Kết luận

Bài báo đã đề xuất một mô hình mạng nơ-ron nhân tạo cải tiến (ANN-PSO-GA-AE) có khả năng chẩn đoán vị trí và mức độ hư hỏng trong kết cấu khung thép nhiều tầng. Việc kết hợp Autoencoder để tái tạo đặc trưng dao động trong điều kiện dữ liệu hạn chế là điểm mới nổi bật của phương pháp.

Kết quả kiểm tra cho thấy mô hình duy trì được khả năng phân biệt phần tử hư hỏng và định lượng chính xác mức độ suy giảm độ cứng với sai số phân bố ổn định. Đây là cơ sở để ứng dụng mô hình vào các hệ thống giám sát sức khỏe công trình có giới hạn cảm biến.

Trong tương lai, mô hình có thể được mở rộng kiểm chứng với dữ liệu thực nghiệm và các dạng kết cấu phức tạp hơn nhằm đánh giá toàn diện hơn tính ứng dụng.

Đóng góp của các tác giả trong bài báo

Nguyễn Hữu Khải: Phương pháp, Quản lý dữ liệu, Phân tích chính thức, phản hồi ý kiến phản biện, Viết – bản thảo gốc. **Ngô Văn Thức:** Phương pháp, giám sát, phản hồi ý kiến phản biện, chỉnh sửa bản thảo.

Tuyên bố không xung đột lợi ích và cam kết bản quyền

Nhóm tác giả xin cam đoan rằng nghiên cứu này là công trình nghiên cứu khoa học của riêng chúng tôi. Các số liệu, kết quả nghiên cứu và tài liệu tham khảo trong nghiên cứu đều được chúng tôi trích dẫn rõ ràng, trung thực và đảm bảo tuân thủ các quy định về đạo đức nghiên cứu. Chúng tôi khẳng định rằng nghiên cứu này không sao chép từ bất kỳ công trình nào khác mà không được trích dẫn đầy đủ hoặc không được phép.

Chia sẻ dữ liệu theo yêu cầu

Nhóm tác giả sẽ cung cấp các dữ liệu có liên quan theo yêu cầu.

Lời cảm ơn

Nhóm tác giả trân trọng cảm ơn Trường Đại học Xây dựng Miền Tây đã hỗ trợ cơ sở vật chất và tạo

điều kiện thuận lợi trong quá trình thực hiện nghiên cứu này.

1st Nguyen Huu Khai. Mien Tay Construction University

2nd Ngo Van Thuc *. Mien Tay Construction University

*Corresponding author: ngovanthuc@mtu.edu.vn

Tài liệu tham khảo

- [1] P. N. Nirupama, T. Raghavendra, N. G. Shahanawaz, and C. V. Manjunath, "A Brief Review on Smart Structural Health Monitoring Technologies," *Engineering Research Transcripts*, vol. 6, pp. 81–88, Dec.2023, doi: 10.55084/grinrey/ERT/978-81-964105-2-0_8.
- [2] H. Nam, L. Nam, N. V. Thành, and M. L. Thông, "Hệ quan trắc công trình cầu Cần Thơ," *Giao thông Vận tải*, no. 3, pp. 145–147, Mar.2018. [Online]. Available: <https://scholar.dlu.edu.vn/thuvienso/handle/DLU123456789/217297>. Accessed: Feb. 23, 2025.
- [3] L. H. Minh, T. N. Hòa, P. V. Phê, T. V. Hưng, L. H. Anh, N. T. C. Nhung, N. T. Khanh, N. T. Hà, L. A. Tuấn, and N. H. Quyết, "Nghiên cứu ứng dụng phương pháp trí tuệ nhân tạo trong chẩn đoán hư hỏng và theo dõi đặc trưng dao động kết cấu dầm cầu nhịp lớn ở Việt Nam phục vụ đánh giá định kỳ về an toàn công trình và an toàn giao thông" *Viện Khoa học và Công nghệ Giao thông Vận tải*, Bộ Giao thông Vận tải, Hà Nội, Việt Nam, mã số AT22308, 2023.
- [4] Y. Wei, "Discussion on structural health monitoring of urban underground road tunnel," *Journal of World Architecture*, vol. 18, no. 5, pp. 18–23, Nov.2024. doi: 10.26689/jwa.v8i5.8740.
- [5] S. Haykin, *Neural networks and learning machines*, 3rd ed. Upper Saddle River, NJ, USA: Pearson Education, Inc., 2009.
- [6] T. Bui-Tien, T. Le-Xuan, H. Tran-Viet, T. Nguyen-Xuan, L. Nguyen-Ngoc, L. Dao-Thuy, and H. N. Tran, "Damage detection for a cable-stayed bridge under the effect of moving loads using transmissibility and artificial neural network," *Journal of Materials and Engineering Structures*, vol. 9, no. 4, pp. 411–420, 2022. [Online]. Available: <https://revue.ummtto.dz/index.php/JMES/article/view/3295>. Accessed: Jan. 5, 2025.
- [7] H. Saeed, Y. Abolfzl, and J. Hashem, "A comprehensive overview of neural networks, deep learning and machine learning applications in engineering fields," in *Proc. 14th National Congress on Civil Engineering*, Zanjan, Iran, 2024.
- [8] L. Yu and Y. M. Fu, "Structural damage detection by fusion of GA and PSO," *Adv. Mater. Res.*, vols. 919–921, pp. 338–343, Apr. 2014. doi: 10.4028/www.scientific.net/AMR.919-921.338.
- [9] X. Li, H. Bolandi, M. Masmoudi, T. Salem, A. Jha, N. Lajnef, and V. N. Boddeti, "Mechanics-informed autoencoder enables automated detection and localization of unforeseen structural damage," *Nature Communications*, vol. 15, no. 9229, Oct.2024, doi: 10.1038/s41467-024-52501-4.
- [10] M. Spínola Neto, R. Finotti, F. Barbosa, and A. Cury, "Structural damage identification using autoencoders: A comparative study," *Buildings*, vol. 14, no. 7, Jul. 2024. doi: 10.3390/buildings14072014.
- [11] K. H. Padil and N. Bakhary, "Comparison between modal domain and frequency domain input data for artificial neural network based damage detection," in *Proc. Int. Symp. Structural Health Monitoring and Nondestructive Testing (SHM-NDT)*, Saarbruecken, Germany, Oct. 4–5, 2018.
- [12] C. S. N. Pathirage, J. Li, L. Li, H. Hao, W. Liu, and P. Ni, "Structural damage identification based on autoencoder neural networks and deep learning," *Engineering Structures*, vol. 172, pp. 13–28, Oct. 2018. doi: 10.1016/j.engstruct.2018.05.109.