

BỘ GIÁO DỤC VÀ ĐÀO TẠO

BỘ XÂY DỰNG

TRƯỜNG ĐẠI HỌC XÂY DỰNG MIỀN TÂY

KHOA XÂY DỰNG



NGUYỄN HỮU KHẢI

**NGHIÊN CỨU ỨNG DỤNG MẠNG NƠ RON NHÂN TẠO
CẢI TIẾN ĐỂ CHẨN ĐOÁN HƯ HỎNG CHO
KẾT CẤU DẠNG KHUNG THÉP**

TÓM TẮT ĐỀ ÁN THẠC SĨ KỸ THUẬT XÂY DỰNG

Cần Thơ, năm 2025

BỘ GIÁO DỤC VÀ ĐÀO TẠO

BỘ XÂY DỰNG

TRƯỜNG ĐẠI HỌC XÂY DỰNG MIỀN TÂY

KHOA XÂY DỰNG



NGUYỄN HỮU KHẢI

**NGHIÊN CỨU ỨNG DỤNG MẠNG NƠ RON NHÂN TẠO
CẢI TIẾN ĐỂ CHẨN ĐOÁN HƯ HỎNG CHO
KẾT CẤU DẠNG KHUNG THÉP**

NGÀNH: KỸ THUẬT XÂY DỰNG

MÃ SỐ: 8.58.02.01

TÓM TẮT ĐỀ ÁN THẠC SĨ KỸ THUẬT XÂY DỰNG

NGƯỜI HƯỚNG DẪN KHOA HỌC:

1. TS. TRẦN NGỌC HÒA

2. TS. NGÔ VĂN THỨC

Cần Thơ, năm 2025

1. Lý do chọn đề tài

Trong bối cảnh sự phát triển mạnh mẽ của ngành xây dựng tại Việt Nam, việc giám sát sức khỏe công trình trở nên cực kỳ quan trọng để đảm bảo an toàn và hiệu quả khai thác. Tuy nhiên, các sự cố nghiêm trọng trong nước cho thấy hệ thống giám sát sức khỏe công trình còn chưa phổ biến, đặc biệt trong công trình dân dụng và công nghiệp. Trong lĩnh vực này, các phương pháp truyền thống vẫn còn nhiều hạn chế, cần sự ứng dụng của học máy, đặc biệt là mạng nơ ron nhân tạo và học sâu để cải thiện khả năng chẩn đoán hư hỏng kết cấu. Việc ứng dụng mạng nơ ron nhân tạo (ANN), đặc biệt là mạng nơ ron nhân tạo cải tiến trong việc chẩn đoán hư hỏng trong kết cấu khung thép trở nên cần thiết và hứa hẹn.

2. Mục tiêu nghiên cứu

Phát triển mô hình ANN cải tiến nhằm xác định vị trí và mức độ hư hỏng trong kết cấu khung thép, kể cả trong điều kiện dữ liệu đầu vào hạn chế, góp phần hỗ trợ bảo trì, bảo dưỡng hiệu quả.

3. Đối tượng và phạm vi nghiên cứu

- *Đối tượng nghiên cứu:* Kết cấu khung thép.
- *Phạm vi nghiên cứu:* Nghiên cứu ứng dụng các mô hình ANN cải tiến trong chẩn đoán hư hỏng khung thép nhà công nghiệp.

4. Phương pháp nghiên cứu

Đề tài kết hợp nghiên cứu lý thuyết và mô phỏng số, xây dựng mô hình khung thép giả lập hư hỏng để huấn luyện và đánh giá hiệu quả mô hình ANN cải tiến trong điều kiện dữ liệu hạn chế.

5. Ý nghĩa khoa học và thực tiễn của đề tài

Về khoa học: Đề tài góp phần phát triển mô hình ANN kết hợp các thuật toán tối ưu, giúp nâng cao độ chính xác chẩn đoán hư hỏng trong kết cấu.

Về thực tiễn: Đề xuất mô hình có thể áp dụng cho công trình khung thép thực tế, hỗ trợ phát hiện sớm hư hỏng và tối ưu hóa công tác bảo trì trong điều kiện thiếu dữ liệu đo đạc.

6. Kết cấu của luận văn

Chương 1: Tổng quan về SHM và các dạng hư hỏng trong kết cấu khung thép.

Chương 2: Các phương pháp chẩn đoán hư hỏng, Cơ sở lý thuyết để đánh giá khả năng chẩn đoán hư hỏng của các mạng ANN và ANN cải tiến.

Chương 3: Xây dựng mô hình ANN cải tiến, huấn luyện, đánh giá và so sánh kết quả.

Kết luận và kiến nghị: Tổng hợp kết quả và đề xuất định hướng tiếp theo.

7. Dự kiến những đóng mới của luận văn


Đề tài phát triển mô hình mạng nơ-ron nhân tạo (ANN) cải tiến nhằm nâng cao hiệu quả chẩn đoán hư hỏng kết cấu khung thép, đáp ứng yêu cầu ứng dụng thực tế. Việc tích hợp kỹ thuật tối ưu giúp cải thiện độ chính xác, đặc biệt khi dữ liệu đầu vào hạn chế.

CHƯƠNG 1: NGHIÊN CỨU TỔNG QUAN VỀ GIÁM SÁT SỨC KHỎE CÔNG TRÌNH

1.1. Tổng quan về giám sát sức khỏe công trình


1.1.1. Tổng quan và vai trò của SHM:

Giám sát sức khỏe công trình (Structural Health Monitoring - SHM) là quá trình theo dõi và phân tích dữ liệu kết cấu nhằm phát hiện suy giảm chất lượng do môi trường, tải trọng hoặc thời gian sử dụng. SHM giúp kéo dài tuổi thọ, giảm rủi ro và bảo vệ hiệu quả giá trị đầu tư, đặc biệt với công trình quy mô lớn.



Hình 1.1: Mô hình làm việc của SHM

Trong kỷ nguyên công nghiệp 4.0, mạng nơ ron nhân tạo (ANN) và học sâu, đã nâng cao hiệu quả chẩn đoán hư hỏng kết cấu. Nhiều nghiên cứu trong và ngoài nước đã chứng minh tiềm năng của ANN cải tiến trong SHM, từ phát hiện vết nứt đến đánh giá vật liệu và xử lý dữ liệu nhằm xác định vị trí và mức độ hư hỏng.



Hình 1.2: Cấu trúc kết hợp giữa CNN và RNN trong SHM.

1.1.2. Các thành phần cơ bản của SHM

1.1.2.1. Cảm biến và thiết bị đo đạc

Đây là bộ phận nền tảng của SHM, thu thập các thông số dao động, biến dạng, nhiệt độ và dịch chuyển. Các cảm biến phổ biến gồm: accelerometers (Hình 1.3), strain gauges, displacement sensors (Hình 1.4) và thermal sensors (Hình 1.5). Chúng cung cấp dữ liệu định lượng liên tục, hỗ trợ phát hiện sớm hư hỏng và bảo trì kịp thời.



Hình 1.3: Cảm biến rung động




Hình 1.4: Cảm biến dịch chuyển



Hình 1.5: Cảm biến nhiệt độ

1.1.2.2. Hệ thống xử lý dữ liệu (phần mềm, thuật toán):

Hệ thống xử lý dữ liệu trong SHM sử dụng thuật toán học máy và học sâu (hình 1.6) tích hợp trong các phần mềm mô phỏng (ANSYS, SAP2000, ABAQUS) để phân tích dữ liệu cảm biến



Hình 1.6: Cấu trúc các thuật toán trong SHM

1.1.2.3. Hệ thống cảnh báo và quản lý theo thời gian thực:

Hệ thống cảnh báo thời gian thực phát hiện sớm bất thường, hỗ trợ kỹ sư xử lý nhanh. Mạng ANN còn giúp dự đoán xu hướng hư hỏng, tối ưu hóa bảo trì.

1.2. Nghiên cứu giám sát sức khỏe công trình trên thế giới

Nhiều quốc gia đã ứng dụng cảm biến sợi quang, WSN, AI và Big Data vào SHM để nâng cao độ chính xác và giảm chi phí bảo trì. Kết hợp SHM với BIM tạo giải pháp quản lý kết cấu toàn diện, trong khi Edge-AI giúp phát hiện hư hỏng ngay tại thiết bị. Dự án Tháp Thượng Hải sử dụng ANN thành công, mở ra tiềm năng áp dụng tại Việt Nam cho công trình dân dụng và công nghiệp.

1.3. Nghiên cứu giám sát sức khỏe công trình tại Việt Nam

1.3.1. Hiện trạng ứng dụng SHM tại Việt Nam:

Trước nhu cầu bảo trì công trình lớn, SHM ngày càng được quan tâm và đã được ban hành trong các bộ Luật Xây dựng 2014 và sửa đổi 2020 (Hình 1.7).



Hình 1.7: Biểu đồ phát triển SHM theo thời gian

1.3.2. Các nghiên cứu tiêu biểu về SHM trong nước:

Tại Việt Nam, ứng dụng SHM trong công trình dân dụng và công nghiệp còn hạn chế so với lĩnh vực giao thông. Một số nghiên cứu tiêu biểu như của Nguyễn Công Đức phát triển hệ thống SHM không dây tích hợp web và trí tuệ nhân tạo để dự đoán ảnh hưởng thời tiết; Trần Ngọc Thạch mô phỏng kết cấu tháp truyền hình Quảng Ngãi để đề xuất biện pháp gia cường. Những nghiên cứu này cho thấy tiềm năng ứng dụng công nghệ mới trong giám sát và bảo trì công trình.

1.4. Tổng quan các hư hỏng thường gặp của kết cấu khung thép

1.4.1. Tổng quan kết cấu khung thép:

Kết cấu khung thép là dạng kết cấu chịu lực phổ biến trong xây dựng hiện đại, đặc biệt ở công trình công nghiệp và nhà cao tầng. Thép có ưu điểm chịu lực tốt, nhẹ, dễ thi công và vận chuyển so với bê tông. Tuy nhiên, nó dễ bị ăn mòn, biến dạng khi cháy và cần bảo trì thường xuyên. Khả năng hấp thụ năng lượng dưới tải lặp kém.



Hình 1.8: Kết cấu khung thép điển hình

1.4.2. Các dạng hư hỏng thường gặp thường gặp:

Quá trình sử dụng kết cấu khung thép có thể gây ra các dạng hư hỏng như suy giảm độ cứng do ăn mòn hoặc nhiệt độ (Hình 1.9), mối vật liệu gây nứt, và sự cố liên kết như mối hàn hoặc bu lông bị lỏng, nứt (Hình 1.10), cùng các yếu tố khác như giãn nở nhiệt và ăn mòn cục bộ ảnh hưởng đến độ bền.



Hình 1.9: Kết cấu bị suy giảm độ cứng do ăn mòn



Hình 1.10: Hình ảnh hư hỏng tại liên kết bu lông

Một số sự cố thực tế cho thấy hư hỏng thường bắt nguồn từ thi công kém chất lượng hoặc tải trọng vượt thiết kế, dẫn đến sập đổ cục bộ (Hình 1.11, Hình 1.12). Điều này nhấn mạnh sự cần thiết của việc theo dõi liên tục và bảo trì kịp thời để đảm bảo an toàn và kéo dài tuổi thọ kết cấu.



Hình 1.11: Sập nhà xưởng Texhong - Hải Hà (Quảng Ninh)



Hình 1.12: Cột tháp truyền hình thị xã Kỳ Anh gãy gập

1.5. Kết luận chương 1

Chương 1 đã trình bày tổng quan về hệ thống SHM, làm rõ vai trò và tiềm năng ứng dụng trong việc nâng cao an toàn và kéo dài tuổi thọ công trình, đặc biệt với kết cấu khung thép trong xây dựng dân dụng và công nghiệp. Sự phát triển của công nghệ 4.0, nhất là trí tuệ nhân tạo và các thuật toán học máy như ANN cải tiến, đã mở ra hướng tiếp cận mới trong chẩn đoán hư hỏng. Từ nền tảng này, Chương 2 sẽ phân tích các phương pháp chẩn đoán truyền thống và học máy, làm rõ nguyên lý ANN, các thuật toán tối ưu PSO, GA và kỹ thuật Autoencoder, nhằm xây dựng mô hình chẩn đoán hư hỏng được đề xuất trong nghiên cứu.

CHƯƠNG 2: CÁC PHƯƠNG PHÁP CHẨN ĐOÁN HƯ HỎNG

2.1. Phương pháp chẩn đoán hư hỏng kết cấu truyền thống

2.1.1. Tổng quan các phương pháp kiểm tra truyền thống:

Trước khi có cảm biến thông minh và AI, kiểm tra kết cấu chủ yếu dựa vào ba phương pháp: quan sát bằng mắt thường, kiểm tra không phá hủy (siêu âm, dòng điện xoáy) và kiểm tra cơ học (thử tải, phá hủy).


2.1.2. Hiệu quả và hạn chế của phương pháp truyền thống:

Các phương pháp truyền thống dễ triển khai và chi phí thấp, phù hợp với nhiều công trình quy mô vừa và dân dụng. Tuy nhiên, chúng không cung cấp dữ liệu thời gian thực, khó tiếp cận vị trí khuất và phụ thuộc vào kinh nghiệm người kiểm tra, hạn chế khả năng phát hiện sớm hư hỏng tiềm ẩn, làm tăng rủi ro mất an toàn. Do đó, xu hướng chuyển sang giám sát hiện đại với cảm biến và trí tuệ nhân tạo nhằm nâng cao hiệu quả phát hiện và tối ưu bảo trì.

2.2. Phương pháp chẩn đoán hư hỏng kết cấu sử dụng mạng nơ ron nhân tạo

2.2.1. Tổng quan mạng nơ ron nhân tạo:


Mạng nơ ron nhân tạo (ANN) mô phỏng hoạt động của não người, gồm lớp đầu vào, lớp đầu ra và một hoặc nhiều lớp ẩn với các kết nối trọng số. ANN học từ dữ liệu để xây dựng mối quan hệ phi tuyến giữa đầu vào và đầu ra. Trong SHM, ANN xử lý tín hiệu từ cảm biến như rung động, nhiệt độ hay biến dạng để phát hiện bất thường mà phương pháp truyền thống khó nhận diện. Lớp ẩn chịu trách nhiệm trích xuất đặc trưng và học mẫu, lớp đầu ra dự đoán kết quả. Số lượng nơron lớp ẩn thường được tối ưu bằng phương pháp thử - sai.



Hình 2.1: Cấu trúc mạng ANN

2.2.2. Quy trình hoạt động của mạng ANN [1, 26, 27]:

Mạng ANN hoạt động dựa trên các liên kết giữa nơron thông qua trọng số và độ lệch, được cập nhật liên tục trong quá trình huấn luyện. Dữ liệu được truyền từ lớp đầu vào qua các lớp ẩn đến lớp đầu ra bằng cách tính tổng có trọng số, sau đó áp dụng hàm kích hoạt – phổ biến nhất là hàm sigmoid – để đưa giá trị về phạm vi xác định. Quá trình huấn luyện nhằm tối thiểu hóa sai số giữa đầu ra dự đoán và đầu ra mong muốn, sử dụng thuật toán lan truyền ngược kết hợp gradient descent để điều chỉnh các tham số. Quá trình này lặp lại cho đến khi sai số hội tụ về giá trị nhỏ nhất, đảm bảo mạng học được mối quan hệ giữa dữ liệu đầu vào và đầu ra. (Hình 2.2)



Hình 2.2: Sơ đồ thuật toán mạng ANN [1]

2.2.3. Chẩn đoán hư hỏng kết cấu công trình thông qua các mạng ANN:

Mô hình ANN được xây dựng để dự đoán vị trí và mức độ hư hỏng dựa trên 20 đặc trưng mode shape, sử dụng kiến trúc ba lớp với thuật toán Adam tối ưu. Mô hình đồng thời thực hiện phân loại và hồi quy, được đánh giá qua các chỉ số như hệ số tương quan R và MSE, cho thấy hiệu quả trong giám sát sức khỏe kết cấu khung thép..

Bảng 2.1. Các tiêu chí đánh giá khả năng chẩn đoán của mô hình học máy

Chỉ số đánh giá	Ý nghĩa trong chẩn đoán SHM	Giá trị
Hệ số hồi quy (R hoặc R ²)	Đánh giá mức độ mô hình tái hiện được mối quan hệ giữa tín hiệu đầu vào và trạng thái hư hỏng của kết cấu	R > 0.90 hoặc R ² > 0.81
Sai số bình phương trung bình (MSE)	Phản ánh tổng độ lệch bình phương giữa đầu ra mô hình và giá trị mục tiêu	Càng nhỏ càng tốt
Chênh lệch sai số Train/Test	Đánh giá khả năng khái quát hóa và độ ổn định mô hình khi áp dụng trên dữ liệu chưa biết	Sai số Train ≈ Test
Phân bố sai số (Histogram)	Cho thấy độ lệch phổ biến, phát hiện vùng sai số lớn, kiểm tra tính tập trung của sai số	Phân bố chuẩn hoặc đối xứng


2.3. Phương pháp chẩn đoán hư hỏng kết cấu sử dụng mạng nơ ron nhân tạo cải tiến

2.3.1. Mạng nơ ron nhân tạo với thuật toán tối ưu bầy đàn, di truyền (Artificial Neural Network–Particle Swarm Optimization – Genetic Algorithm-ANN-PSO-GA):

2.3.1.1. Tổng quan mạng ANN-PSO-GA:


Mạng ANN-PSO-GA là mô hình cải tiến dựa trên mạng nơ-ron truyền thống, kết hợp hai thuật toán tối ưu Particle Swarm Optimization (PSO) và Genetic Algorithm (GA). PSO tối ưu trọng số và bias ban đầu, giúp mạng khởi tạo gần giá trị tối ưu và tránh mắc kẹt tại cực trị cục bộ, giúp vận hành bằng cách các hạt di chuyển trong không

gian tìm kiếm, ghi nhớ và chia sẻ vị trí tốt nhất để tìm lời giải tối ưu nhanh chóng, nhưng có xu hướng hội tụ sớm và không có các toán tử biến đổi thể hệ. (Hình 2.3)



Hình 2.3: Sơ đồ thuật toán tối ưu hoá bầy đàn PSO


GA mô phỏng quá trình tiến hóa sinh học, sử dụng các phép chọn lọc, lai ghép và đột biến để tăng đa dạng và chất lượng giải pháp. GA rất phù hợp với các bài toán tối ưu phi tuyến phức tạp và giúp nâng cao khả năng tìm kiếm toàn cục. (Hình 2.4)



Hình 2.4: Sơ đồ thuật toán GA [1]

2.3.1.2. Quá trình xây dựng và huấn luyện mô hình ANN-PSO-GA [1]:

Quá trình xây dựng mô hình bắt đầu với việc thu thập và tiền xử lý dữ liệu dao động, biến dạng, ứng suất từ cảm biến trên kết cấu khung thép nhằm đảm bảo chất lượng đầu vào. Dữ liệu này được đưa vào mạng ANN, với các trọng số và độ lệch ban đầu được tối ưu bằng thuật toán PSO để tránh cực trị cục bộ và khởi tạo mạng gần giá trị tối ưu. Các trọng số và độ lệch được mã hóa thành vector làm biến thể cho các hạt trong PSO, với vị trí và vận tốc cập nhật theo các công thức di chuyển và chia sẻ thông tin giữa các hạt. Sau khi PSO tìm ra tập tham số tối ưu ban đầu, thuật toán GA được sử dụng để cải thiện thêm bằng các phép lai ghép và đột biến, tạo ra các thể hệ giải pháp mới nhằm tăng đa dạng và chất lượng tối ưu. Quá trình PSO và GA lặp lại liên tục đến khi mạng đạt hiệu suất tốt nhất, đảm bảo khả năng học và dự đoán chính xác trong chẩn đoán hư hỏng kết cấu. (Hình 2.5)



Hình 2.5: Sơ đồ hoạt động của ANN-PSO-GA [1]


2.3.1.3. Ưu điểm và hạn chế ứng dụng ANN-PSO-GA trong SHM:

Mô hình ANN-PSO-GA nâng cao hiệu quả chẩn đoán hư hỏng kết cấu, đặc biệt với hư hỏng nhỏ và biến dạng phi tuyến. Kết hợp ưu điểm của PSO và GA giúp mạng tự điều chỉnh trọng số, tránh cực trị cục bộ. Mô phỏng cho thấy độ chính xác tăng 15–20% so với ANN truyền thống, phù hợp với dữ liệu phức tạp và nhiễu. Ứng dụng hiệu quả trong kết cấu khung thép dân dụng, giúp phát hiện sớm, giảm chi phí bảo trì và kéo dài tuổi thọ công trình, đáp ứng nhu cầu thực tế tại Việt Nam..

2.3.2. Mạng nơ-ron tự mã hóa:


2.3.2.1. Tổng quan mạng Mạng nơ-ron tự mã hóa:

Mạng nơ-ron tự mã hóa (Autoencoder - AE) gồm bộ mã hóa chuyển đổi dữ liệu đầu vào thành biểu diễn ẩn và bộ giải mã tái tạo dữ liệu từ biểu diễn đó. Trong SHM, AE giúp phát hiện bất thường qua sai lệch giữa dữ liệu gốc và dữ liệu tái tạo, rất hiệu quả với dữ liệu phức tạp và nhiễu. (Hình 2.6).



Hình 2.6: Cấu trúc mạng Autoencoder [30]

Mô hình MIAE là phiên bản cải tiến của AE, tích hợp đặc tính cơ học của kết cấu vào quá trình học. MIAE sử dụng ma trận trọng số biểu diễn sự tương quan biến dạng giữa các phần tử trong kết cấu, giúp giảm lỗi tái tạo và tăng độ nhạy phát hiện hư hỏng tinh vi. Ma trận trọng số này được tính toán dựa trên dữ liệu cảm biến thực tế, phản ánh chính xác hiệu ứng cơ học như tập trung ứng suất (Hình 2.7).



Hình 2.7: Sơ đồ hoạt động của Autoencoder

2.3.2.2. Ưu điểm và hạn chế ứng dụng mô hình Autoencoder trong SHM:

Mô hình Autoencoder có ưu điểm tự động mã hóa, giải mã dữ liệu mà không cần gán nhãn, giúp trích xuất đặc trưng ẩn, khử nhiễu và phục hồi dữ liệu hiệu quả, đặc biệt phù hợp với dữ liệu đo giới hạn như 10 mode dao động đầu tiên. Trong nghiên cứu, AE tái tạo các mode thiếu và phát hiện bất thường, vượt trội hơn nội suy truyền thống. Tuy nhiên, khi hoạt động độc lập, độ chính xác giảm do sai số tích lũy và nhiễu, thể hiện hạn chế của mô hình.

2.3.3. Chẩn đoán hư hỏng kết cấu công trình thông qua các mạng ANN cải tiến:

Mô hình ANN cải tiến sử dụng dữ liệu dao động chuẩn hóa gồm 20 biên độ mode shape làm đầu vào, với đầu ra là mã số phân tử hư hỏng và tỷ lệ suy giảm độ cứng. Mô hình này kế thừa cấu trúc huấn luyện của mạng truyền thống nhưng được khởi tạo trọng số bằng thuật toán PSO-GA và có thể xử lý đầu vào thiếu nhờ Autoencoder tái tạo. Sau huấn luyện, mạng được kiểm thử trên dữ liệu mới, kết quả được so sánh chi tiết với dữ liệu thực, đánh giá qua các chỉ số thống kê như hệ số hồi quy (R), sai số bình phương trung bình (MSE), và phân bố sai số. Việc giữ nguyên định dạng dữ liệu và quy trình đánh giá giúp so sánh hiệu quả giữa các mô hình và chứng minh tính ứng dụng thực tế trong điều kiện dữ liệu đầu vào hạn chế, phổ biến trong công nghiệp và nhà xưởng..

2.4. Kết luận chương 2

Chương 2 giới thiệu tổng quan các phương pháp chẩn đoán hư hỏng kết cấu, từ kỹ thuật truyền thống đến ứng dụng trí tuệ nhân tạo. ANN được đánh giá cao nhờ khả năng mô hình hóa phi tuyến giữa tín hiệu dao động và trạng thái hư hỏng, giúp nâng cao hiệu quả định vị và định lượng hư hỏng. Tuy nhiên, hạn chế của ANN truyền thống khi gặp dữ liệu thiếu hụt, nhiễu hay không đồng nhất đòi hỏi tích hợp thêm các thuật toán PSO-GA và Autoencoder để cải thiện độ chính xác và ổn định. Nội dung chương tạo nền tảng cho Chương 3 xây dựng mô hình số kết cấu khung thép, triển khai các mô hình ANN, và đánh giá hiệu quả chẩn đoán qua các chỉ số định lượng phục vụ ứng dụng thực tiễn trong bảo trì và giám sát công trình.

CHƯƠNG 3: XÂY DỰNG MÔ HÌNH ANN CẢI TIẾN ĐỂ CHẨN ĐOÁN HƯ HỒNG THƯỜNG GẶP TRONG KẾT CẤU KHUNG THÉP


3.1. Xây dựng mô hình số cho kết cấu

3.1.1. Xây dựng mô hình kết cấu khung thép

Mô hình kết cấu số dựa trên nhà công nghiệp điển hình với khung thép 4 tầng gồm 5 trục dọc, cao tổng 14,02 m và dài 22,02 m, thiết kế phù hợp cho công trình dân dụng và nhà xưởng. Cột chính dùng thép hộp chữ nhật kích thước $140 \times 200 \times 8 \times 13$ mm, dầm chữ I tiết diện $I350 \times 175 \times 7 \times 11$ mm, liên kết dầm-cột bằng bản mã bu lông lắp ghép, chân cột liên kết ngàm cố định phản ánh điều kiện làm việc thực tế. Hệ khung chia thành phần tử dầm không gian 3D, tạo cơ sở cơ học chính xác phục vụ mô phỏng dao động và dữ liệu huấn luyện trí tuệ nhân tạo

3.1.2. Mô phỏng dao động kết cấu

Mô hình số kết cấu khung thép 4 tầng được xây dựng trong MATLAB, với hệ tọa độ nút 3D, các phần tử dầm tuyến tính kết nối tại nút. Liên kết dầm-cột giả định là khớp lý tưởng, chân cột ngàm cố định, vật liệu thép có mô đun đàn hồi $E = 210 \times 10^9$ N/m² (Hình 3.3). Phương pháp phần tử hữu hạn (FEM) được sử dụng để giải bài toán trị riêng, xác định tần số dao động của kết cấu. Ma trận độ cứng và khối lượng được thiết lập theo điều kiện biên và hình học, thay đổi khi có suy giảm độ cứng do hư hỏng, ảnh hưởng đến đặc trưng dao động.



Hình 3.3: Mô phỏng kết cấu khung thép nhà 4 tầng thông qua Matlab

Để đánh giá tác động của hư hỏng, mỗi phần tử trong kết cấu được giả định suy giảm độ cứng từ 1% đến 70% với bước tăng 1%, tạo thành bộ dữ liệu lớn phục vụ phân tích mối quan hệ giữa mức độ hư hỏng và sự biến đổi tần số dao động. Kết quả mô phỏng cho phần tử thứ 1 bị suy giảm độ cứng được trình bày chi tiết trong Bảng 3.1

Bảng 3.1. Tần số dao động của kết cấu khi phần tử thứ 1 bị suy giảm độ cứng

Mức độ hư hỏng(%)	Mode 1(Hz)	Mode 2(Hz)	Mode 19(Hz)	Mode 20(Hz)
1	0,843686523	1,283163027	11,29256456	11,56533792
5	0,843401030	1,282216412	11,29254327	11,56528278
10	0,843033286	1,280994066	11,29251420	11,56521018
20	0,842258943	1,278409577	11,29244590	11,56505049

Mức độ hư hỏng(%)	Mode 1(Hz)	Mode 2(Hz)	Mode 19(Hz)	Mode 20(Hz)
30	0,841427633	1,275619691	11,29235914	11,56486607
40	0,840532057	1,272597435	11,29224449	11,56464752
50	0,839563222	1,269309356	11,29208475	11,56437956
60	0,838509697	1,265712390	11,29184496	11,56403523
70	0,837356283	1,261748150	11,29144134	11,56356008

3.2. Mô hình mạng ANN cải tiến

3.2.1. Mô hình mạng ANN

3.2.1.1. Mã hóa dữ liệu

Mô hình trong nghiên cứu sử dụng kiến trúc feedforward để mô hình hóa quan hệ phi tuyến giữa đặc trưng dao động và trạng thái hư hỏng kết cấu. Đầu vào là vector mode shape gồm 20 phần tử, còn đầu ra gồm vị trí hư hỏng (ID_code) được mã hóa thành dãy số nguyên từ 1 đến 157 và mức độ hư hỏng (Damage Ratio) thể hiện tỷ lệ suy giảm độ cứng từ 1% đến 70%. Cách mã hóa này giúp mạng hội tụ nhanh, ổn định và nâng cao khả năng khái quát hóa, từ đó dự đoán chính xác, hỗ trợ hiệu quả công tác bảo trì và quản lý kết cấu khung thép.

3.2.1.2. Chia tập dữ liệu huấn luyện, thử sai, kiểm tra

Sau khi mã hóa, tập dữ liệu mô phỏng gồm 10.990 mẫu được tạo thành từ các tổ hợp hư hỏng của 157 phần tử với 70 mức độ suy giảm. Dữ liệu này được trộn ngẫu nhiên và chia thành ba tập với tỷ lệ và mục đích sử dụng như Bảng 3.3

Bảng 3.3. Chia tập dữ liệu mô phỏng để huấn luyện, kiểm tra, kiểm định

STT	Loại tập dữ liệu	Ký hiệu	Tỷ lệ	Số mẫu	Mục đích sử dụng
1	Tỷ lệ huấn luyện – Training ratio	trainRatio	70/100	7.694	dùng để cập nhật trọng số mạng qua các epoch lặp.
2	Tỷ lệ kiểm tra – Validation ratio	valRatio	15/100	1.648	dùng để giám sát quá trình huấn luyện, giúp mô hình tránh overfitting và quyết định điểm dừng sớm.
3	Tỷ lệ kiểm định – Test ratio	testRatio	15/100	1.648	dùng để đánh giá cuối cùng về khả năng tổng quát hóa, đảm bảo mô hình hoạt động tốt với dữ liệu mới chưa từng thấy.

3.2.1.3. Kiến trúc mạng và phương pháp huấn luyện.

Kiến trúc mạng ANN được cấu hình chi tiết trong MATLAB với các tham số chính thể hiện trong Bảng 3.4

Bảng 3.4. Thông số thiết kế mạng ANN

STT	Nội dung	Ký hiệu	Giá trị	Vai trò
1	Lớp đầu vào	inputs	20	Dữ liệu đầu vào giá trị huấn luyện
2	Lớp ẩn	Hidden number	20	Các lớp ẩn học các quan hệ phi tuyến giữa đầu vào và đầu ra

STT	Nội dung	Ký hiệu	Giá trị	Vai trò
3	Lớp đầu ra	targets	2	Tổng hợp kết quả, phản ánh giá trị cần dự đoán
4	Số vòng lặp – Number of epochs	net_f.trainParam. epochs	500	Số vòng lặp tối đa trong quá trình huấn luyện

Quá trình huấn luyện sử dụng thuật toán Levenberg–Marquardt với mục tiêu giảm thiểu sai số bình phương trung bình giữa giá trị dự đoán và giá trị thực tế.

3.2.2. Áp dụng thuật toán tối ưu PSO-GA vào ANN


3.2.2.1. Giai đoạn tối ưu bằng PSO.

Giai đoạn tối ưu bằng PSO tập trung tìm kiếm toàn cục các tham số quan trọng ảnh hưởng đến đặc trưng động học của kết cấu. Thuật toán như Bảng 3.6.

Bảng 3.6. Thông số thiết kế cho thuật toán PSO và quá trình cập nhật mô hình

STT	Nội dung	Ký hiệu	Giá trị	Vai trò
1	Số vòng lặp tối đa – Max iterations	MaxIt	200	Số thế hệ được phép trong quá trình tiến hóa
2	Kích thước quần thể – Population size	nPop	50	Số cá thể trong mỗi thế hệ
3	Hệ số học hỏi cá nhân – Personal Learning Coefficient	c1	1,5	Mức độ cá thể học từ kinh nghiệm bản thân
4	Hệ số học hỏi toàn cục – Global Learning Coefficient	c2	2,2	Mức độ cá thể học từ vị trí tốt nhất toàn quần thể
5	Hệ số quán tính – Inertia Weight	w	1	Ảnh hưởng của vận tốc cũ lên vận tốc hiện tại
6	Tỉ lệ giảm quán tính – Inertia Weight Damping Ratio	wdamp	0,99	Giảm dần ảnh hưởng của quán tính theo số vòng lặp

Hàm mục tiêu đánh giá sự sai lệch giữa tần số và mode shape của 20 mode đầu, giúp theo dõi quá trình hội tụ của thuật toán (Hình 3.5). Thuật toán thường dừng sớm sau khoảng 100 vòng khi hàm mục tiêu không cải thiện đủ, đồng thời giữ lại 30 cá thể tốt nhất để duy trì đa dạng và ổn định trong tìm kiếm.



Hình 3.5: Kết quả hội tụ sau khi cập nhật mô hình bằng PSO

3.2.2.2. Giai đoạn cải tiến bằng GA.

Giai đoạn cải tiến sử dụng GA nhằm khai thác chi tiết các vùng lời giải tiềm năng sau khi PSO hội tụ tương đối. GA áp dụng các phép lai ghép và đột biến trên tập cá thể tốt nhất để duy trì đa dạng di truyền, tránh hội tụ sớm và mở rộng không gian tìm kiếm, từ đó nâng cao độ chính xác dự báo trạng thái hư hỏng kết cấu. Thông số GA được trình bày trong Bảng 3.7.

Bảng 3.7. Thông số thiết kế cho thuật toán GA

STT	Nội dung	Ký hiệu	Giá trị	Vai trò
1	Tỉ lệ lai – Crossover percentage	Pc	0,7	Tỷ lệ quần thể tham gia quá trình lai chéo
2	Số cá thể lai – Number of offspring	nc	$2 * \text{round}(pc * nPop/2)$	Số lượng cá thể sinh ra từ phép lai
3	Biên độ mở rộng lai – Extra range factor for crossover	gamma	0,45	Điều chỉnh mức lan rộng trong phép lai để tạo ra con
4	Tỉ lệ đột biến – Mutation percentage	pm	0,3	Tỷ lệ quần thể được chọn ngẫu nhiên để đột biến
5	Số cá thể đột biến – Number of mutants	nm	$\text{round}(pm * nPop)$	Số lượng cá thể sẽ bị thay đổi do đột biến
6	Tỷ lệ đột biến – Mutation rate	mu	0,1	Cường độ thay đổi gen trong phép đột biến

3.2.3. Xây dựng mạng Autoencoder và kết hợp với ANN-PSO-GA

Mô hình ANN được cải tiến bằng Autoencoder để tái tạo 20 mode dao động từ 10 mode đầu tiên do giới hạn cảm biến. Autoencoder trích xuất biểu diễn tiềm ẩn và dùng phần giải mã để bổ sung các mode thiếu, tạo dữ liệu đầy đủ cho ANN-PSO-GA. Cấu trúc gồm 3 tầng: đầu vào 20 mode, mã hóa 10 chiều, giải mã 20 mode (Bảng 3.8).

Bảng 3.8. Cấu trúc mạng Autoencoder

STT	Nội dung	Ký hiệu	Giá trị	Vai trò
1	Tầng đầu vào – Input layer	input	20	Nhận 20 mode dao động đầu hoặc đo được thực tế
2	Tầng mã hóa – Encoder (latent layer)	encoder	10	Trích đặc trưng và nén xuống không gian tiềm ẩn 10 chiều
3	Tầng giải mã – Decoder	decoder	20	Dự đoán 10 mode dao động còn lại (mode chưa đo được)

3.3. Huấn luyện và so sánh các mô hình mạng nơron

Nghiên cứu đã huấn luyện ba mô hình mạng nơ-ron cùng kiến trúc trên tập dữ liệu chia theo tỷ lệ 70% huấn luyện, 15% kiểm định và 15% kiểm tra. Kết quả trong Bảng 3.9 – 3.11 mô hình ANN truyền thống có sai số lớn hơn với MAE khoảng 6.25%. Mô hình ANN-PSO-GA cải thiện đáng kể, đạt sai số MAE khoảng 5% và dự đoán vị trí hư

hồng gần như chính xác tuyệt đối. Đặc biệt, mô hình ANN-PSO-GA-Autoencoder, dù sử dụng 10 mode dao động thực tế và tái tạo 10 mode còn lại qua Autoencoder, vẫn duy trì khả năng chẩn đoán vị trí tốt và dự đoán mức độ hư hỏng với sai số chấp nhận được (MAE ~8.7%), thể hiện hiệu quả trong điều kiện dữ liệu thiếu hụt.

Bảng 3.9. Một số kết quả chẩn đoán hư hỏng mạng ANN

Vị trí hư hỏng			Mức độ hư hỏng (%)		
Thực	Dự đoán	Sai số	Thực	Dự đoán	Sai số
1	1	0	28	28,794	0,794
1	2	1	42	41,925	-0,075
1	1	0	61	56,022	-4,978
2	1	-1	51	52,288	1,288
2	1	-1	60	60,893	0,893
2	1	-1	67	67,109	0,109
2	1	-1	68	67,949	-0,051
2	1	-1	70	69,584	-0,416
4	4	0	50	50,105	0,105
5	2	-3	31	31,802	0,802
6	1	-5	8	6,511	-1,489
6	11	5	22	20,375	-1,625
8	8	0	42	44,720	2,720
9	9	0	44	47,624	3,624
9	9	0	49	51,993	2,993
17	17	0	52	52,634	0,634
19	19	0	58	59,543	1,543
22	22	0	14	14,848	0,848
34	34	0	38	36,311	-1,689
35	35	0	5	6,467	1,467
39	39	0	39	40,220	1,220
42	42	0	23	21,423	-1,577
50	50	0	64	63,423	-0,577
53	53	0	25	25,368	0,368
Giá trị sai số trung bình MAE		6,251	Giá trị sai số trung bình MAE		6,250

Bảng 3.10: Một số kết quả chẩn đoán hư hỏng mạng ANN-PSO-GA

Vị trí hư hỏng			Mức độ hư hỏng (%)		
Thực	Dự đoán	Sai số	Thực	Dự đoán	Sai số
1	1	0	39	40,413	1,413
2	5	3	15	15,295	0,295
2	1	-1	44	44,031	0,031
3	5	2	66	66,204	0,204
3	5	2	67	66,931	-0,069


Vị trí hư hỏng			Mức độ hư hỏng (%)		
Thực	Dự đoán	Sai số	Thực	Dự đoán	Sai số
4	4	0	12	13,594	1,594
4	4	0	50	50,623	0,623
7	7	0	50	50,522	0,522
9	9	0	19	22,667	3,667
13	13	0	49	48,700	-0,300
16	16	0	55	55,591	0,591
17	17	0	29	29,075	0,075
18	18	0	63	62,629	-0,371
44	44	0	42	42,665	0,665
44	44	0	47	47,438	0,438
48	48	0	27	26,764	-0,236
48	48	0	65	65,050	0,050
56	56	0	70	69,497	-0,503
73	73	0	34	34,447	0,447
80	80	0	41	40,498	-0,502
87	87	0	35	35,729	0,729
96	96	0	43	42,703	-0,297
104	104	0	63	62,513	-0,487
105	105	0	20	19,346	-0,654
Giá trị sai số trung bình MAE		4,97	Giá trị sai số trung bình MAE		5,314

Bảng 3.11. Một số kết quả chẩn đoán hư hỏng mạng ANN-PSO-GA-AE


Vị trí hư hỏng			Mức độ hư hỏng (%)		
Thực	Dự đoán	Sai số	Thực	Dự đoán	Sai số
2	2	0	63	62,804	-0,196
4	4	0	31	37,351	6,351
4	4	0	39	44,171	5,171
4	6	2	53	52,002	-0,998
6	4	-2	34	33,955	-0,045
6	3	-3	35	34,600	-0,400
7	1	-6	39	38,155	-0,845
9	9	0	43	43,031	0,031
19	19	0	65	73,484	8,484
20	20	0	27	35,660	8,660
20	20	0	61	60,367	-0,633
23	32	9	38	37,197	-0,803
23	23	0	56	50,620	-5,380
24	26	2	36	35,147	-0,853

Vị trí hư hỏng			Mức độ hư hỏng (%)		
Thực	Dự đoán	Sai số	Thực	Dự đoán	Sai số
26	28	2	36	35,179	-0,821
34	34	0	17	15,664	-1,336
38	38	0	30	30,048	0,048
38	38	0	32	31,439	-0,561
51	51	0	70	69,905	-0,095
53	53	0	50	49,568	-0,432
90	90	0	52	51,752	-0,248
94	94	0	52	51,016	-0,984
128	128	0	18	18,595	0,595
146	146	0	42	41,019	-0,981
Giá trị sai số trung bình MAE		10.328	Giá trị sai số trung bình MAE		8.698


Quá trình huấn luyện thể hiện qua Hình 3.9 cho thấy mô hình ANN-PSO-GA hội tụ nhanh và đạt giá trị MSE thấp nhất. Mô hình Autoencoder vẫn duy trì được sự ổn định trong giới hạn chấp nhận được. Biểu đồ hồi quy tổng thể (Hình 3.10) cùng biểu đồ phân bố sai số (Hình 3.11) củng cố kết quả, cho thấy ANN-PSO-GA có độ chính xác và ổn định cao nhất, trong khi ANN-PSO-GA-AE cũng thể hiện hiệu quả đáng kể trong việc xử lý dữ liệu thiếu hụt.



Hình 3.9: Biểu đồ huấn luyện sai số kiểm định




Hình 3.10: Biểu đồ hồi quy tổng thể.




Hình 3.11: Biểu đồ phân bố sai số.

Hình 3.12 minh họa chi tiết khả năng phân loại hư hỏng và vị trí của từng mô hình, trong đó mô hình tích hợp Autoencoder nổi bật khi dữ liệu đầu vào bị hạn chế. Quá trình hội tụ được theo dõi qua Hình 3.13, cho thấy ANN-PSO-GA có tốc độ và độ ổn định vượt trội, còn ANN-PSO-GA-Autoencoder gặp khó khăn nhưng vẫn đảm bảo quá trình huấn luyện.



Hình 3.12: Biểu đồ hồi quy chi tiết



Hình 3.13: Biểu đồ khả năng hội tụ

3.4. Đánh giá và phân tích kết quả

Sau khi huấn luyện và kiểm tra, các mô hình mạng nơ-ron trong nghiên cứu được đánh giá toàn diện qua các chỉ số như hệ số tương quan R, MSE, MAE, đồng thời so sánh với các phương pháp hiện có để xác định hiệu quả thực tế trong chẩn đoán hư

hông kết cấu khung thép. Bảng 3.13 trình bày so sánh các mô hình ANN cải tiến với một số nghiên cứu trước, cho thấy ANN-PSO-GA vượt trội về độ chính xác và tốc độ hội tụ, đồng thời duy trì khả năng khái quát hóa tốt. Mô hình tích hợp Autoencoder (ANN-PSO-GA-AE) tuy có sai số cao hơn do sử dụng dữ liệu tái tạo, nhưng vẫn giữ được hiệu quả chẩn đoán đáng tin cậy trong điều kiện dữ liệu hạn chế, mở rộng tính ứng dụng thực tế. Nghiên cứu cũng chỉ ra ANN-PSO-GA giảm hiệu suất khi dữ liệu đầu vào giảm, trong khi ANN-PSO-GA-AE duy trì sự ổn định tốt. Phân tích độ nhạy từng mode dao động khẳng định vai trò quan trọng của các mode trung bình và cao trong nhận diện hư hỏng, góp phần định hướng thiết kế hệ thống cảm biến SHM. Tổng thể, từng mô hình phù hợp với điều kiện dữ liệu và mục tiêu giám sát riêng: ANN truyền thống phù hợp dữ liệu đầy đủ nhưng hạn chế về độ khái quát, ANN-PSO-GA ưu việt khi dữ liệu đầy đủ, còn ANN-PSO-GA-AE hiệu quả khi dữ liệu bị thiếu hụt. Các cải tiến trong tối ưu thuật toán và xử lý dữ liệu thiếu hụt đã nâng cao rõ rệt độ chính xác và tính ổn định, đáp ứng tốt yêu cầu giám sát kết cấu thực tế.

Bảng 3.13. So sánh các mạng ANN cải tiến với một số phương pháp khác

STT	Hạng mục	ANN-PSO-GA	ANN-PSO-GA-AE	ANN	ANN-AE-DL
1	Kết cấu mô phỏng	Khung thép 4 tầng	Khung thép 4 tầng	Khung thép	Khung thép
2	Nguồn dữ liệu đầu vào	Mode shape từ mô phỏng FEM	Mode shape từ mô phỏng và tái tạo	Gia tốc dao động EEMD + Hilbert Transform	Gia tốc và đặc trưng giảm chiều từ AE
3	Mục tiêu dự đoán	Vị trí hư hỏng, mức độ hư hỏng	Vị trí hư hỏng, mức độ hư hỏng	Mức độ hư hỏng	Mức độ hư hỏng & độ cứng
4	Hệ số hồi quy R	0.98219	0.9493	0.99	0.794– 0.711
5	MSE	58,2285	151,9469	0.0016	3.6e-4 đến 5.2e-4

3.5. Kết luận chương 3

Chương 3 trình bày quy trình xây dựng và đánh giá mô hình số cho kết cấu khung thép 4 tầng, sử dụng dữ liệu dao động để huấn luyện ba mạng nơ-ron: ANN truyền thống, ANN-PSO-GA và ANN-PSO-GA-AE. Mô hình tối ưu PSO-GA cải thiện độ chính xác chẩn đoán vị trí và mức độ hư hỏng, trong khi Autoencoder giúp duy trì hiệu quả khi dữ liệu đầu vào bị thiếu hụt. Kết quả so sánh với các nghiên cứu trước cho thấy mô hình đề xuất có độ chính xác cao và phù hợp với điều kiện thực tế. Nghiên cứu cũng đề xuất mở rộng và cải tiến để nâng cao khả năng ứng dụng trong môi trường phức tạp hơn.

KẾT LUẬN VÀ KIẾN NGHỊ

1. Kết luận

Luận văn đã hoàn thành mục tiêu phát triển và kiểm nghiệm mô hình mạng nơ-ron cải tiến nhằm chẩn đoán hư hỏng kết cấu khung thép dân dụng, tập trung vào xác định vị trí phân tử hư hỏng và ước lượng mức độ suy giảm độ cứng ngay cả khi dữ liệu đầu vào bị giới hạn.

Ba đóng góp chính bao gồm:

- Xây dựng thành công mô hình ANN cải tiến tích hợp PSO-GA và Autoencoder, vừa tối ưu trọng số mạng vừa tái tạo đặc trưng mode shape khi dữ liệu đo không đầy đủ, phù hợp với hệ thống giám sát có cảm biến hạn chế.

- Đánh giá toàn diện ba mô hình (ANN, ANN-PSO-GA, ANN-PSO-GA-AE) qua các chỉ số R, MAE, MSE và tốc độ hội tụ, trong đó ANN-PSO-GA đạt độ chính xác cao nhất ($R \approx 0.982$).

- So sánh với các phương pháp khác, mô hình đề xuất thể hiện ưu thế về độ chính xác và khả năng ứng dụng trong kết cấu dân dụng nhiều tầng, với quy trình mô phỏng và huấn luyện đồng nhất trên MATLAB đảm bảo tính tin cậy.

Luận văn mở ra hướng phát triển mô hình mạng nơ-ron hiệu quả trong môi trường thực tế, đặc biệt khi dữ liệu đầu vào không đầy đủ, với tiềm năng áp dụng cho các công trình công nghiệp khung thép nhiều tầng.

Định hướng nghiên cứu tiếp theo:

- Mở rộng kiến trúc học sâu (CNN, LSTM, Attention) để xử lý dữ liệu phi tuyến phức tạp hơn.

- Tối ưu Autoencoder bằng mạng sâu hoặc kỹ thuật học tái tạo có điều kiện để nâng cao độ chính xác khi thiếu dữ liệu.

- Huấn luyện trên dữ liệu thực đo từ cảm biến để kiểm định và tinh chỉnh mô hình.

- Kết hợp với hệ thống quản lý bảo trì (CMMS) nhằm cảnh báo sớm và tối ưu hóa bảo trì định kỳ.

2. Kiến nghị

Dựa trên kết quả nghiên cứu, đề xuất một số kiến nghị ứng dụng nhằm hỗ trợ triển khai mô hình vào thực tế:

- Các cơ quan quản lý xây dựng nên xem xét áp dụng mạng nơ-ron cải tiến trong giám sát công trình dân dụng, đặc biệt tại vùng rủi ro cao, để hỗ trợ cảnh báo sớm và giảm chi phí kiểm tra thủ công.

- Các viện nghiên cứu và đơn vị kỹ thuật cần phối hợp thu thập, chuẩn hóa và công bố dữ liệu dao động kết cấu, thúc đẩy thử nghiệm thực địa nhằm kiểm chứng khả năng triển khai mô hình trong môi trường thực.

- Xây dựng cơ sở dữ liệu dao động kết cấu công khai, chia sẻ trong cộng đồng nghiên cứu và kỹ thuật để thúc đẩy phát triển các giải pháp học máy và mạng nơ-ron trong giám sát kết cấu.