■ Ngày nộp bài: 10/6/2026 ■ Ngày sửa bài: 19/6/2026 ■ Ngày chấp nhận đăng: 03/7/2026

Ứng dụng trí tuệ nhân tạo trong kỹ thuật kết cấu: Tổng quan định lượng về xu hướng nghiên cứu, phương pháp học máy và các thách thức hiện nay

Applications of artificial intelligence in structural engineering: A quantitative review of research trends, machine learning methods, and current challenges

> TS TRỊNH THỊ HOA*, THS.NCS MAI VĂN CHIẾN
Nhóm nghiên cứu Vật liệu tiên tiến và Hệ thống thông minh cho Hạ tầng và Đường sắt tốc độ cao (AMIS-HSR), Trường Đại học Công nghệ Giao thông vận tải.
*Email: hoatt85@utt.edu.vn

TÓM TẮT

Trí tuệ nhân tạo (AI) đang được ứng dụng rộng rãi trong phân tích, thiết kế và quản lý công trình, đặc biệt đối với các bài toán kết cấu phi tuyến, đa biến. Bài báo tổng quan các ứng dụng AI trong dự báo khả năng chịu lực, giám sát sức khỏe công trình, tối ưu hóa kết cấu và phát triển vật liệu; đồng thời phân tích xu hướng mô hình, dữ liệu, chiến lược kiểm chứng và định hướng nghiên cứu. Kết quả khảo sát cho thấy ANN/DNN xuất hiện phổ biến nhất với 39,0%; Random Forest và boosting cùng đạt 32,2%, trong khi SVM/SVR chiếm 28,8%. Nghiên cứu đang chuyển từ học máy truyền thống sang ensemble, boosting, học sâu, AI có khả năng giải thích (XAI) và học máy tích hợp vật lý (PIML). Tuy nhiên, phần lớn cơ sở dữ liệu có quy mô nhỏ hoặc trung bình; kiểm chứng độc lập và theo nguồn còn hạn chế, làm giảm khả năng đánh giá tính tổng quát của mô hình. Các thách thức chính gồm dữ liệu thiếu đồng nhất, hiệu ứng nguồn, tính chất hộp đen và nguy cơ dự đoán phi vật lý. Vì vậy, nghiên cứu đề xuất phát triển dữ liệu mở, đa nguồn và chuẩn hóa; tăng cường kiểm chứng độc lập, đồng thời thúc đẩy XAI, PIML và Digital Twin nhằm xây dựng các hệ thống AI đáng tin cậy và hỗ trợ quyết định kỹ thuật an toàn.

Từ khóa: Trí tuệ nhân tạo; học máy; kỹ thuật kết cấu; giám sát sức khỏe công trình; AI có khả năng giải thích; học máy tích hợp vật lý; bản sao số.

ABSTRACT

Artificial intelligence (AI) is increasingly being applied to structural analysis, design, and infrastructure management, particularly for nonlinear and multivariable structural engineering problems. This paper reviews AI applications in predicting structural capacity, structural health monitoring, structural optimization and construction material development. It also examines trends in model selection, data characteristics, validation strategies, and future research directions. The survey results show that artificial and deep neural networks (ANN/DNN) are the most frequently employed model group, appearing in 39.0% of the reviewed studies. Random Forest and boosting algorithms each account for 32.2%, while support vector machines and support vector regression (SVM/SVR) account for 28.8%. Current research is shifting from conventional machine learning towards ensemble learning, boosting, deep learning, explainable artificial intelligence (XAI), and physics-informed machine learning (PIML). However, most available datasets remain small or medium-sized, while independent and source-aware validation are still limited,

hindering a reliable assessment of model generalizability. The main challenges include data heterogeneity, source effects, black-box model behavior, and the risk of physically inconsistent predictions. Accordingly, this study recommends developing open, multi-source, and standardized databases; strengthening independent validation; and advancing XAI, PIML and Digital Twin technologies. These directions are essential for establishing trustworthy AI systems capable of supporting safe engineering decision-making.

Keywords: Artificial intelligence; machine learning; structural engineering; structural health monitoring; explainable artificial intelligence; physics-informed machine learning; digital twin.

1. ĐẶT VẤN ĐỀ

Cuộc Cách mạng công nghiệp lần thứ tư đang thúc đẩy chuyển đổi số trong ngành Xây dựng, trong đó trí tuệ nhân tạo (Artificial Intelligence - AI) có tiềm năng thay đổi phương thức phân tích, thiết kế và quản lý công trình [1, 2]. Sự phát triển của năng lực tính toán, công nghệ cảm biến, hệ thống thu thập dữ liệu và các nền tảng điện toán hiệu năng cao đã tạo điều kiện mở rộng ứng dụng AI trong kỹ thuật kết cấu. Dữ liệu thực nghiệm, mô phỏng số và quan trắc về đặc trưng vật liệu, ứng xử cơ học, quá trình hư hỏng và khả năng chịu lực của kết cấu ngày càng gia tăng. Tuy nhiên, các phương pháp truyền thống gặp khó khăn trong việc khai thác hiệu quả những nguồn dữ liệu này do tính phi tuyến, đa biến và mức độ phức tạp cao của các bài toán kết cấu [3]. Sự phát triển của học máy (Machine Learning - ML) và học sâu (Deep Learning - DL) đã mở ra cách tiếp cận mới, cho phép nhận diện các quy luật tiềm ẩn và xây dựng mô hình dự báo mà không cần xác lập trước quan hệ toán học tường minh [4, 5].

Trong hai thập kỷ gần đây, AI đã được ứng dụng trong dự báo tính chất vật liệu và khả năng chịu lực của cấu kiện, phân loại dạng phá hoại, tối ưu hóa thiết kế, giám sát sức khỏe công trình, phát hiện hư hỏng, đánh giá độ tin cậy và phát triển Digital Twin [6-8]. Tuy nhiên, khả năng ứng dụng thực tế vẫn bị hạn chế bởi dữ liệu nhỏ và thiếu đồng nhất, hiệu ứng nguồn, quy trình kiểm chứng chưa nghiêm ngặt, khả năng tổng quát hóa thấp, tính chất hộp đen và sự thiếu liên kết với cơ học kết cấu [9, 10]. Các hướng nghiên cứu như AI có khả năng giải thích (XAI), học máy tích hợp vật lý (PIML), Digital Twin và Foundation Models mở ra triển vọng nâng cao tính minh bạch, khả năng ngoại suy và mức độ tin cậy của mô hình.

Mặc dù đã có nhiều nghiên cứu tổng quan về các lĩnh vực chuyên biệt như dự báo cường độ bê tông, giám sát công trình và vật liệu thông minh, các nghiên cứu phân tích đồng thời hiện trạng ứng dụng, xu hướng thuật toán, đặc điểm dữ liệu, chiến lược kiểm chứng và những thách thức của AI trong kỹ thuật kết cấu vẫn còn hạn chế. Vì vậy, bài báo này hướng tới: (i) Tổng hợp và phân loại các ứng dụng tiêu biểu của AI trong dự báo khả năng chịu lực, giám sát sức khỏe công trình, tối ưu hóa kết cấu và phát triển vật liệu; (ii) phân tích xu hướng sử dụng các nhóm thuật toán trên cơ sở tập hợp nghiên cứu được lựa chọn; (iii) đánh giá đặc điểm dữ liệu, chiến lược kiểm chứng, khả năng tổng quát hóa và tính giải thích của mô hình; (iv) đề xuất các định hướng phát triển tập trung vào XAI, PIML, Digital Twin và các mô hình AI thế hệ mới và (v) cung cấp cơ sở tham khảo cho việc nghiên cứu và ứng dụng AI an toàn, đáng tin cậy trong kỹ thuật kết cấu.

2. HIỆN TRẠNG ỨNG DỤNG AI TRONG KỸ THUẬT KẾT CẤU

AI trong kỹ thuật kết cấu đã chuyển từ các mô hình tính toán thông minh riêng lẻ sang phương pháp phân tích dựa trên dữ liệu. Trong giai đoạn đầu, hệ chuyên gia, mạng nơ-ron, logic mờ và thuật toán tiến hóa được sử dụng để mô hình hóa quan hệ phi tuyến, dự báo tính chất vật liệu và hỗ trợ thiết kế. Mạng nơ-ron đã được nghiên cứu trong kỹ thuật xây dựng từ cuối thập niên 1980 và trở thành một trong những công cụ AI được ứng dụng sớm nhất [11]. Từ khoảng năm 2010, SVM, cây quyết định, Random Forest và boosting thúc đẩy việc so sánh thuật toán, lựa chọn đặc trưng và tối ưu hóa siêu tham số. Học máy và học sâu từ đó được mở rộng từ mô hình hóa vật liệu, dự báo ứng xử đến giám sát và tối ưu hóa kết cấu [12]. Ứng dụng phổ biến hiện nay là xây dựng mô hình thay thế để dự báo cường độ vật liệu, sức kháng cắt và uốn, tải trọng tới hạn, chuyển vị, dạng phá hoại và mức độ hư hỏng. Đối với kết cấu bê tông cốt thép, nghiên cứu tập trung vào sức kháng cắt của dầm, chọc thủng sàn phẳng và khả năng chịu lực của cột, tường. Trong kết cấu thép và liên hợp, các bài toán chính gồm ổn định, sức chịu tải và ứng xử động đất. Dữ liệu mô phỏng số cũng được sử dụng để mở rộng miền khảo sát và giảm chi phí phân tích. Tuy nhiên, độ tin cậy của mô hình học máy phụ thuộc vào giả thiết, quan hệ vật liệu, điều kiện biên và phạm vi hiệu chỉnh của mô hình số. Vì vậy, AI hiện chủ yếu đóng vai trò bổ trợ cho lý thuyết cơ học, mô phỏng số và công thức thiết kế [12]. Trong giám sát sức khỏe công trình, dữ liệu dao động, gia tốc, biến dạng, hình ảnh và tín hiệu cảm biến được khai thác để phát hiện, định vị và đánh giá mức độ hư hỏng. Các thuật toán truyền thống thường sử dụng đặc trưng đã được xử lý, trong khi CNN và LSTM có thể học trực tiếp từ hình ảnh hoặc chuỗi thời gian. Sự kết hợp giữa cảm biến, truyền dữ liệu không dây và phân tích dữ liệu đang thúc đẩy giám sát liên tục, gần thời gian thực [13]. Tuy nhiên, ứng dụng thực tế vẫn bị hạn chế bởi nhiễu đo, biến thiên môi trường, thiếu dữ liệu hư hỏng có nhãn và sự khác biệt giữa điều kiện phòng thí nghiệm với công trình thực.

Trong lĩnh vực vật liệu, AI được sử dụng để dự báo và tối ưu hóa tính chất của bê tông cường độ cao, UHPC, geopolymer, bê tông cốt liệu tái chế và composite gia cường sợi. Khả năng tổng quát hóa của mô hình chịu ảnh hưởng bởi tính không đồng nhất của nguyên liệu, quy trình chế tạo và phương pháp báo cáo dữ liệu. Trong tối ưu hóa kết cấu, AI được kết hợp với thuật toán tiến hóa và mô hình thay thế nhằm giảm khối lượng, chi phí, phát thải và số lần phân tích trực tiếp. Tuy nhiên, phương án tối ưu vẫn cần được kiểm chứng bằng tiêu chuẩn thiết kế, mô hình cơ học hoặc mô phỏng có độ trung thực cao. AI trong xây dựng vì vậy đang phát triển theo hướng tự động hóa, tích hợp thông tin, tối ưu hóa quy trình và hỗ trợ ra quyết định [14].

Các nghiên cứu tiêu biểu được tổng hợp và phân loại nhằm minh họa các xu hướng trên Hình 1 cho thấy tập hợp khảo sát tập trung chủ yếu vào dự báo ứng xử và sức chịu tải của cấu kiện bê tông cốt thép, đặc biệt là sàn phẳng, tường và cột; tiếp theo là UHPC và kết cấu gia cường FRP [19-26]. Số nghiên cứu về giám sát sức khỏe công trình thấp hơn, cho thấy dự báo dựa trên dữ liệu vẫn là hướng ứng dụng chủ đạo [12]. Tuy nhiên, sự phân bố này chỉ phản ánh phạm vi của tập hợp nghiên cứu được lựa chọn, không đại diện cho toàn bộ công bố quốc tế.

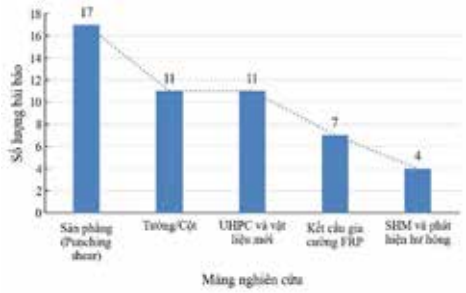

Hình 1. Phân bố bài báo về AI theo mảng nghiên cứu

Nghiên cứu gần đây đang chuyển từ mục tiêu tối ưu hóa độ chính xác sang nâng cao tính giải thích, độ tin cậy và khả năng tổng quát hóa. XAI, điển hình là SHAP, hỗ trợ lượng hóa đóng góp của biến và đối chiếu kết quả dự báo với hiểu biết cơ học [15]. Tuy nhiên, mức độ quan trọng thống kê không đồng nghĩa với quan hệ nhân quả hoặc cơ chế phá hoại thực sự. PIML tích hợp phương trình chi phối, điều kiện biên hoặc kết quả mô phỏng vào quá trình học, đặc biệt phù hợp với dữ liệu hạn chế và các bài toán đa vật lý [16]. Tri thức có trước cũng có thể được đưa vào mô hình dưới dạng phương trình, quy tắc, mô phỏng hoặc hiểu biết chuyên gia [17]. Ở cấp độ quản lý vòng đời, Digital Twin kết nối AI, cảm biến, Internet vạn vật và mô hình số nhằm hỗ trợ giám sát, chẩn đoán và dự báo trạng thái công trình. Tuy nhiên, việc triển khai vẫn gặp khó khăn về chất lượng, khả năng đồng bộ và kết nối dữ liệu theo thời gian thực [18]. Nhìn chung, AI đang phát triển từ các mô hình dự báo đầu vào-đầu ra sang hệ thống tích hợp dữ liệu, tri thức cơ học, cảm biến và mô hình số. Hiệu quả của AI vì vậy cần được đánh giá đồng thời thông qua độ chính xác, khả năng giải thích, tính tổng quát và sự phù hợp với các nguyên lý cơ học.

3. XU HƯỚNG PHÁT TRIỂN CỦA TRÍ TUỆ NHÂN TẠO TRONG KỸ THUẬT KẾT CẤU

3.1. Sự chuyển dịch của các mô hình trí tuệ nhân tạo

Sự chuyển dịch mô hình phản ánh tiến bộ về thuật toán, năng lực tính toán và sự đa dạng của dữ liệu, đồng thời đáp ứng yêu cầu ngày càng cao về độ chính xác, khả năng tổng quát hóa, tính giải thích và sự phù hợp cơ học. Hình 2a cho thấy ANN/DNN là nhóm xuất hiện phổ biến nhất, chiếm 39,0% với 23 nghiên cứu. Random Forest và boosting cùng đạt 32,2%, tương ứng 19 nghiên cứu; SVM/SVR chiếm 28,8% với 17 nghiên cứu. Decision Tree và các mô hình hồi quy lần lượt đạt 20,3% và 13,6%. Gaussian Process, KNN, thuật toán tiến hóa, Fuzzy/ANFIS, CNN, RNN/LSTM/GRU và XAI xuất hiện với tần suất thấp hơn. Kết quả cho thấy lĩnh vực kỹ thuật kết cấu đang sử dụng đồng thời nhiều họ mô hình thay vì phụ thuộc vào một thuật toán duy nhất. ANN/DNN có ưu thế trong biểu diễn quan hệ phi tuyến giữa hình học, vật liệu, tải trọng và đáp ứng kết cấu, nhưng nhạy cảm với kiến trúc mạng, siêu tham số và phân bố dữ liệu; đồng thời khó diễn giải về mặt cơ học. SVM/SVR và Random Forest phù hợp với các bộ dữ liệu nhỏ hoặc trung bình thường gặp trong nghiên cứu thực nghiệm. XGBoost, LightGBM và CatBoost ngày càng được ưu tiên cho dữ liệu dạng bảng nhờ khả năng xử lý quan hệ phi tuyến và tương tác biến. Tuy nhiên, hiệu suất cao trên một tập dữ liệu chưa bảo đảm khả năng tổng quát hóa nếu quy trình kiểm chứng không đủ nghiêm ngặt. Do một nghiên cứu có thể sử dụng nhiều thuật toán, tổng tỷ lệ trong Hình 3a có thể vượt quá 100%. Các tỷ lệ chỉ biểu thị tần suất xuất hiện, không phản ánh các nhóm loại trừ lẫn nhau hoặc mức độ ưu việt tuyệt đối. Việc lựa chọn mô hình cần dựa trên dạng dữ liệu, quy mô mẫu, đầu ra dự báo và chiến lược kiểm chứng. Hình 2b khái quát bốn giai đoạn phát triển tương đối: ANN và tính toán mềm giai đoạn 1995 - 2010; SVM và Random Forest giai đoạn 2010 - 2017; boosting và ensemble giai đoạn 2018 - 2023; XAI, PIML, Digital Twin và Foundation Models từ năm 2023 đến nay. Các phương pháp mới không thay thế hoàn toàn mô hình trước đó mà được sử dụng song song theo từng loại dữ liệu và mục tiêu. Nhìn chung, trọng tâm nghiên cứu đang chuyển từ tối ưu hóa độ chính xác sang nâng cao khả năng tổng quát hóa, giải thích kết quả và tích hợp tri thức cơ học.

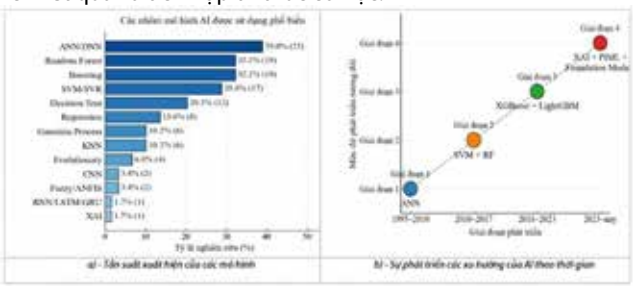

Hình 2. Sự chuyển dịch của các mô hình AI trong kỹ thuật kết cấu

3.2. Xu hướng dữ liệu và phương pháp kiểm chứng mô hình

Hiệu quả của mô hình AI phụ thuộc đồng thời vào thuật toán, chất lượng dữ liệu và quy trình kiểm chứng. Trong kỹ thuật kết cấu, dữ liệu chủ yếu được thu thập từ thí nghiệm, mô phỏng số và quan trắc hiện trường; mỗi nguồn có những ưu điểm và hạn chế riêng. Dữ liệu thí nghiệm phản ánh trực tiếp ứng xử vật lý nhưng thường có quy mô hạn chế do chi phí và thời gian thực hiện. Khi tổng hợp từ nhiều nghiên cứu, sự khác biệt về vật liệu, kích thước cấu kiện, điều kiện biên, thiết bị đo và quy trình gia tải có thể tạo ra hiệu ứng nguồn. Khi đó, mô hình có nguy cơ học các đặc điểm riêng của từng chương trình thí nghiệm thay vì các quy luật cơ học có khả năng áp dụng rộng hơn. Mô phỏng số, đặc biệt là phương pháp phần tử hữu hạn cho phép xây dựng dữ liệu có hệ thống và khảo sát miền tham số rộng. Tuy nhiên, độ tin cậy của dữ liệu phụ thuộc vào giả thiết mô hình, quan hệ vật liệu, điều kiện biên và quy trình hiệu chỉnh. Vì vậy, mô hình học máy đạt độ chính xác cao trên dữ liệu mô phỏng chưa chắc duy trì được hiệu suất khi áp dụng cho kết cấu thực. Dữ liệu hiện trường từ cảm biến, hệ thống SHM, hình ảnh và mạng IoT có giá trị đối với phát hiện hư hỏng và xây dựng Digital Twin, nhưng thường chịu ảnh hưởng của nhiễu, điều kiện môi trường và mất dữ liệu. Do đó, tiền xử lý, đồng bộ và kiểm soát chất lượng dữ liệu là những bước thiết yếu. Hình 3 cho thấy các bộ dữ liệu từ 101 - 300 mẫu và không quá 100 mẫu chiếm tỷ lệ cao nhất, lần lượt là 35,6% và 28,8%. Số nghiên cứu sử dụng trên 500 mẫu thấp hơn đáng kể và không ghi nhận bộ dữ liệu vượt quá 1.000 mẫu. Kết quả này phản ánh sự phụ thuộc của lĩnh vực vào các chương trình thí nghiệm và mô phỏng chuyên biệt, đồng thời cho thấy nhu cầu phát triển cơ sở dữ liệu mở, đa nguồn và được chuẩn hóa.

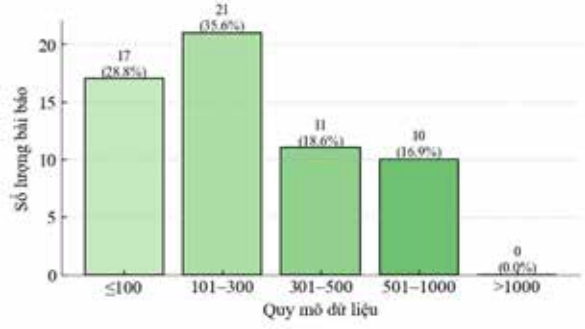

Hình 3. Phân bố quy mô bộ dữ liệu trong tập hợp các nghiên cứu được khảo sát

Chiến lược kiểm chứng quyết định mức độ tin cậy của hiệu suất mô hình. Phép chia ngẫu nhiên và k-fold phù hợp để đánh giá khả năng nội suy nhưng có thể cho kết quả lạc quan nếu các mẫu cùng

nguồn hoặc cùng họ cấu kiện xuất hiện trong cả tập huấn luyện và kiểm tra. Đối với dữ liệu đa nguồn, nên ưu tiên:

- Group k-fold theo nguồn hoặc chương trình thí nghiệm;
- Leave-one-source-out cho nguồn chưa quan sát;
- Kiểm chứng trên cơ sở dữ liệu độc lập;
- Chia theo thời gian đối với dữ liệu quan trắc;
- Kiểm chứng chéo giữa dữ liệu thí nghiệm, mô phỏng và hiện trường.

Hình 4. Các chiến lược chia dữ liệu và kiểm chứng mô hình được ghi nhận trong tập hợp nghiên cứu khảo sát

Hình 4 cho thấy chia dữ liệu ngẫu nhiên và k-fold cross-validation vẫn là các chiến lược kiểm chứng phổ biến, trong khi kiểm chứng theo nguồn, theo nhóm và trên tập dữ liệu độc lập còn hạn chế. Nhóm "không nêu rõ" chỉ phản ánh sự thiếu thông tin trong bài báo, không đồng nghĩa với việc nghiên cứu không thực hiện kiểm chứng. Chia ngẫu nhiên chủ yếu đánh giá khả năng nội suy và có thể cho kết quả lạc quan khi các mẫu cùng nguồn xuất hiện ở cả tập huấn luyện và kiểm tra. Vì vậy, nên báo cáo đồng thời kết quả chia ngẫu nhiên và kiểm chứng theo nguồn để đánh giá tin cậy khả năng tổng quát hóa của mô hình.

3.3. Xu hướng công bố và phát triển AI trong kỹ thuật kết cấu

Sự phát triển của AI trong kỹ thuật kết cấu được thể hiện qua sự gia tăng công bố, mở rộng phạm vi ứng dụng và thay đổi yêu cầu đối với mô hình. Từ các bài toán dự đoán cường độ vật liệu và sức chịu tải, AI đã được mở rộng sang phân loại dạng phá hoại, tối ưu hóa kết cấu, giám sát sức khỏe công trình và phát triển vật liệu mới. Đối tượng nghiên cứu ngày càng đa dạng, bao gồm kết cấu bê tông cốt thép, UHPC, bê tông geopolymer, bê tông cốt liệu tái chế và cấu kiện gia cường FRP. Các mô hình cây và boosting được sử dụng phổ biến với dữ liệu dạng bảng, trong khi CNN và LSTM phù hợp hơn với hình ảnh, tín hiệu và chuỗi thời gian. Hình 5 trình bày xu hướng công bố của các nghiên cứu được lựa chọn. Số lượng nghiên cứu còn hạn chế trước năm 2012, bắt đầu tăng trong giai đoạn 2013 - 2015 và phát triển rõ rệt từ năm 2021. Sự suy giảm trong giai đoạn 2025 - 2026 chủ yếu liên quan đến thời điểm và phạm vi thu thập tài liệu, do đó không nên được xem là bằng chứng về xu hướng suy giảm của lĩnh vực.

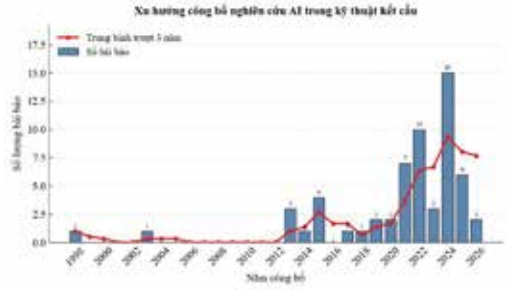

Hình 5. Xu hướng công bố của các nghiên cứu được lựa chọn trong tập hợp khảo sát

Bên cạnh sự mở rộng về số lượng, trọng tâm nghiên cứu đang chuyển từ tối ưu hóa độ chính xác sang nâng cao khả năng giải thích, tổng quát hóa và tích hợp tri thức cơ học. XAI hỗ trợ đối chiếu kết quả dự báo với lý thuyết và thực nghiệm; PIML đưa các phương trình, điều kiện biên hoặc tham số cơ học vào quá trình học nhằm hạn chế dự đoán phi vật lý; Digital Twin kết nối mô hình số với dữ liệu cảm biến để cập nhật trạng thái và hỗ trợ quản lý công trình theo vòng đời. Foundation Models và Generative AI cũng mở ra khả năng xử lý dữ liệu đa phương thức, nhưng cần được kiểm soát về độ chính xác, tính kiểm chứng và trách nhiệm kỹ thuật. Các kết quả thống kê trong Phần 3 chỉ cung cấp minh chứng định lượng trong phạm vi tập hợp nghiên cứu được lựa chọn, không thay thế một phân tích thư mục toàn diện. Nhìn chung, AI đang phát triển theo hướng đa mô hình, có khả năng giải thích và phù hợp cơ học hơn, tạo cơ sở cho việc phân tích các thách thức và định hướng nghiên cứu trong Phần 4.

4. THÁCH THỨC VÀ ĐỊNH HƯỚNG PHÁT TRIỂN

Mặc dù AI ngày càng đạt hiệu suất cao, việc ứng dụng trong kỹ thuật kết cấu vẫn gặp các thách thức về dữ liệu, kiểm chứng, khả năng giải thích và tính phù hợp cơ học. Phần lớn cơ sở dữ liệu có quy mô nhỏ hoặc trung bình và được tổng hợp từ nhiều chương trình thí nghiệm, mô phỏng khác nhau. Sự không đồng nhất về vật liệu, kích thước cấu kiện, điều kiện biên, quy trình gia tải và phương pháp đo có thể tạo ra hiệu ứng nguồn, làm giảm tính đại diện và khả năng tổng quát hóa. Trong khi đó, dữ liệu mở, đa nguồn và được chuẩn hóa vẫn còn hạn chế. Chiến lược kiểm chứng ảnh hưởng trực tiếp đến độ tin cậy của mô hình. Chia ngẫu nhiên hoặc k-fold thông thường có thể cho kết quả lạc quan khi các mẫu cùng nguồn hoặc cùng họ cấu kiện xuất hiện trong cả tập huấn luyện và kiểm tra. Khi đó, kết quả chủ yếu phản ánh khả năng nội suy giữa các mẫu tương tự thay vì dự báo cho điều kiện mới. Vì vậy, cần kết hợp chia ngẫu nhiên với Group k-fold, leave-one-source-out và kiểm chứng độc lập để đánh giá khả năng tổng quát hóa. Khả năng giải thích cũng là một yêu cầu quan trọng. SHAP, PDP và LIME giúp xác định đóng góp và xu hướng tác động của biến đầu vào, nhưng quan hệ thống kê không nhất thiết phản ánh quan hệ nhân quả hoặc cơ chế làm việc của kết cấu. Mô hình học từ tương quan dữ liệu có thể tạo ra dự đoán phi vật lý khi ngoại suy. Do đó, kết quả cần được đối chiếu với lý thuyết cơ học, thực nghiệm, mô phỏng số và tiêu chuẩn thiết kế trước khi sử dụng trong các quyết định liên quan đến an toàn.

Hình 4. Định hướng phát triển của trí tuệ nhân tạo trong kỹ thuật kết cấu

Để khắc phục các hạn chế trên, nghiên cứu cần chuyển từ tối ưu hóa độ chính xác sang phát triển các hệ thống AI đáng tin cậy. Như minh họa trong Hình 6, định hướng này dựa trên bốn nền tảng: Dữ liệu đại diện và có khả năng truy xuất; kiểm chứng nghiêm ngặt; mô hình có khả năng giải thích và tích hợp tri thức cơ học. XAI nâng cao tính minh bạch, hỗ trợ nhận diện các biến chi phối và kiểm tra sự phù hợp của xu hướng dự báo. PIML tích hợp phương trình cân bằng, điều kiện biên, quy luật vật liệu hoặc tham số không thứ nguyên vào quá trình học, qua đó hạn chế dự đoán phi vật lý và cải thiện khả năng ngoại suy. Ở cấp độ hệ thống, Digital Twin kết nối AI, cảm biến, Internet vạn vật và mô hình số để cập nhật trạng thái công trình theo thời gian thực, hỗ trợ phát hiện hư hỏng, dự báo suy

giảm và tối ưu hóa bảo trì. Generative AI và Foundation Models cho phép xử lý văn bản, hình ảnh, tín hiệu và mô hình số, phục vụ truy xuất tri thức, phân tích đa phương thức và hỗ trợ thiết kế. Tuy nhiên, các công nghệ này cần được kiểm chứng về độ chính xác, tính minh bạch, khả năng truy xuất và trách nhiệm kỹ thuật.

Nhìn chung, định hướng cốt lõi là xây dựng hệ thống AI dựa trên dữ liệu đại diện, được kiểm chứng theo nguồn và trên dữ liệu độc lập, có khả năng giải thích và tuân thủ quy luật cơ học. Sự kết hợp giữa XAI, PIML, Digital Twin và Foundation Models có thể chuyển AI từ công cụ dự báo riêng lẻ thành hệ thống hỗ trợ quyết định đáng tin cậy cho thiết kế, đánh giá và quản lý an toàn công trình.

5. KẾT LUẬN

Bài báo đã tổng quan các ứng dụng chính của AI trong kỹ thuật kết cấu và phân tích 60 nghiên cứu tiêu biểu. Kết quả cho thấy AI đang chuyển từ ANN và học máy truyền thống sang ensemble, boosting, học sâu và các phương pháp tích hợp vật lý. Việc lựa chọn mô hình phụ thuộc vào dạng dữ liệu và mục tiêu ứng dụng. Tuy nhiên, AI hiện chủ yếu bổ trợ cho mô hình cơ học, mô phỏng số và tiêu chuẩn thiết kế. Những hạn chế chính gồm dữ liệu nhỏ, thiếu đồng nhất, kiểm chứng chưa nghiêm ngặt, khả năng tổng quát hóa thấp, tính chất hộp đen và nguy cơ dự đoán phi vật lý. Vì vậy, nghiên cứu tương lai cần phát triển cơ sở dữ liệu mở, đa nguồn và chuẩn hóa; tăng cường kiểm chứng theo nguồn và trên dữ liệu độc lập; đồng thời thúc đẩy XAI, PIML và Digital Twin. Generative AI và Foundation Models có tiềm năng xử lý dữ liệu đa phương thức nhưng cần được kiểm soát về độ chính xác và trách nhiệm kỹ thuật. Mục tiêu cuối cùng là xây dựng các hệ thống AI đáng tin cậy, có khả năng giải thích, phù hợp cơ học và hỗ trợ an toàn cho các quyết định kỹ thuật.

TÀI LIỆU THAM KHẢO

[1] S. J. Russell and P. Norvig. Artificial Intelligence: A Modern Approach. Pearson, 4th ed., 2021.

[2] Y. Lu, F. Xue, X. Xu and C. J. Webster. From BIM to digital twins: A systematic review of the evolution of intelligent building representations and applications. Automation in Construction, vol. 114, article 103125, 2020, doi: 10.1016/j.autcon.2020.103125.

[3] H. Adeli. Neural networks in civil engineering: 1989-2000. Computer-Aided Civil and Infrastructure Engineering, vol. 16, no. 2, pp. 126-142, 2001, doi: 10.1111/0885-9507.00219.

[4] H. Salehi and R. Burgueño. Emerging artificial intelligence methods in structural engineering. Engineering Structures, vol. 171, pp. 170-189, 2018, doi: 10.1016/j.engstruct.2018.05.084.

[5] A. Y. Sun and B. R. Scanlon. How can Big Data and machine learning benefit environment and water management: A survey of methods, applications and future directions. Environmental Research Letters, vol. 14, no. 7, article 073001, 2019, doi: 10.1088/1748-9326/ab1a3f.

[6] M. H. Rafiei and H. Adeli. A novel machine learning model for estimation of sale prices of real estate units. Journal of Construction Engineering and Management, vol. 142, no. 2, article 04015066, 2016, doi: 10.1061/(ASCE)CO.1943-7862.0001047.

[7] X. W. Ye, Y. H. Su and J. P. Han. Structural health monitoring of civil infrastructure using optical fiber sensing technology: A comprehensive review. The Scientific World Journal, vol. 2014, article 652329, 2014, doi: 10.1155/2014/652329.

[8] L. von Rueden et al. Informed machine learning-A taxonomy and survey of integrating prior knowledge into learning systems. IEEE Transactions on Knowledge and Data Engineering, vol. 35, no. 1, pp. 614-633, 2023, doi: 10.1109/TKDE.2021.3079836.

[9] G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang and L. Yang. Physics-informed machine learning. Nature Reviews Physics, vol. 3, pp. 422-440, 2021, doi: 10.1038/s42254-021-00314-5.

[10] S. Sony, S. Laventure and A. Sadhu. A literature review of next-generation smart sensing technology in structural health monitoring. Structural Control and Health Monitoring, vol. 26, no. 3, article e2321, 2019, doi: 10.1002/stc.2321.

[11] Y. Pan and L. Zhang. Roles of artificial intelligence in construction engineering and management: A critical review and future trends. Automation in Construction, vol. 122, article 103517, 2021, doi: 10.1016/j.autcon.2020.103517.

[12] S. M. Lundberg and S. I. Lee. A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems, vol. 30, pp. 4765-4774, 2017.

[13] A. Fuller, Z. Fan, C. Day and C. Barlow. Digital Twin: Enabling technologies, challenges and open research. IEEE Access, vol. 8, pp. 108952-108971, 2020, doi: 10.1109/ACCESS.2020.2998358.

[14] I. C. Yeh. Modeling of strength of high-performance concrete using artificial neural networks. Cement and Concrete Research, vol. 28, no. 12, pp. 1797-1808, 1998, doi: 10.1016/S0008-8846(98)00165-3.

[15] A. Çevik, A. E. Kurtoğlu, M. Bilgehan, M. E. Gülşan and H. M. Albegmprli. Support vector machines in structural engineering: A review. Journal of Civil Engineering and Management, vol. 21, no. 3, pp. 261-281, 2015, doi: 10.3846/13923730.2015.1005021.

[16] M. Nikoo, F. T. Moghadam and Ł. Sadowski. Prediction of concrete compressive strength by evolutionary artificial neural networks. Advances in Materials Science and Engineering, vol. 2015, article 849126, 2015, doi: 10.1155/2015/849126.

[17] Y. J. Cha and O. Büyüköztürk. Structural damage detection using modal strain energy and hybrid multiobjective optimization. Computer-Aided Civil and Infrastructure Engineering, vol. 30, no. 5, pp. 347-358, 2015.

[18] B. Tekwani and A. B. Gupta. Machine learning classification techniques to predict in situ compressive strength of reinforced concrete using NDT data. Nigerian Journal of Technology, vol. 44, no. 4, pp. 533-546, 2025, doi: 10.4314/njt.v44i4.2.

[19] I. C. Yeh. Prediction of strength of fly ash and slag concrete by the use of artificial neural networks. Chung Hua Journal of Science and Engineering, 2003.

[20] L. V. P. Meesaraganda, N. Sarkar and N. Tarafder. Adaptive neuro-fuzzy inference system for predicting strength of high-performance concrete. In Advances in Structural Engineering, Springer, 2020.

[21] H. T. Trinh, T. A. Pham, V. D. Tho and D. H. Nguyen. Prediction of shear strength of reinforced concrete walls with different cross-sectional shapes using an XGBoost model. PLOS ONE, vol. 19, no. 11, article e0312531, 2024, doi: 10.1371/journal.pone.0312531.

[22] K. L. Nguyen, H. T. Trinh, T. T. Nguyen and H. D. Nguyen. Comparative performance of machine-learning techniques for predicting shear strength of reinforced concrete deep beams. Expert Systems with Applications, vol. 230, article 120649, 2023, doi: 10.1016/j.eswa.2023.120649.

[23] R. Yong, S. Mangalathu, P. Ni and C. Wang. Machine-learning-based prediction of tunnel-boring-machine performance. Geomechanics and Geophysics for Geo-Energy and Geo-Resources, vol. 12, article 47, 2026.

[24] H. T. Trinh, K. L. Nguyen, S. Banihashemi and A. Ahmad. Machine-learning prediction and inverse design of circular concrete-filled steel tubular columns. Buildings, vol. 16, no. 1, article 150, 2026.

[25] K. L. Nguyen, H. T. Trinh, S. Banihashemi and T. M. Pham. Machine-learning approaches for predicting the lateral strength of squat reinforced concrete shear walls. Expert Systems with Applications, vol. 239, article 122458, 2024, doi: 10.1016/j.eswa.2023.122458.

[26] K. L. Nguyen, H. T. Trinh and T. M. Pham. Prediction of punching shear strength in flat slabs: Ensemble-learning models and practical implementation. Neural Computing and Applications, vol. 36, pp. 4207-4228, 2024.