■Ngày nhận bài: 02/6/2023 ■Ngày sửa bài: 24/7/2023 ■Ngày chấp nhận đăng: 18/8/2023

Xây dựng mô hình máy học để dự báo lực bám dính giữa bê tông cốt thép và vật liệu FRP gia cường

Building a machine learning model to predict adhesion force between reinforced concrete and FRP material

> KS LÊ MINH THANH[1], TS TRƯƠNG ĐÌNH NHẬT[2*], THS LÊ THỊ THÙY LINH [3], THS TRẦN NGUYỄN THANH TÂM[4]

[1] HVCH Ngành Kỹ thuật xây dựng, Trường Đại học Kiến trúc TP.HCM, Email: thanhleminh0512@gmail.com

[2]GV Khoa Xây dựng, Trường Đại học Kiến trúc TP.HCM, Email: nhat.truongdinh@uah.edu.vn

[3]GV Khoa Sư phạm Công nghiệp, Trường ĐH Sư phạm Kỹ thuật, Đại học Đà Nẵng, Email: lttlinh@ute.udn.vn

[4]Sở Xây dựng tỉnh Bạc Liêu, Email: ttamsxd@gmail.com *Corresponding author

TÓM TẮT

Việc sử dụng tấm polyme cốt sợi (FRP) lên mặt ngoài của kết cấu bê tông cốt thép là một trong những phương pháp phổ biến và hiệu quả nhất để gia cường kết cấu bê tông. Bài báo tập trung nghiên cứu vào xây dựng và so sánh các mô hình học máy khác nhau để dự báo lực bám dính giữa vật liệu bê tông cốt thép và vật liệu FRP gia cường. Các mô hình đơn (single model) và mô hình kết hợp (ensemble model) được sử dụng để giải quyết vấn đề này. Kết quả phân tích cho thấy rằng mô hình kết hợp đóng gói cây phân loại hồi quy - mô hình bagging (CART) cho hiệu suất cao nhất trong tất cả các mô hình đơn và mô hình kết hợp được sử dụng trong nghiên cứu này.

Từ khóa: Lực bám dính giữa FRP và bê tông cốt thép; vật liệu FRP; mô hình máy học.

ABSTRACT

Fiber-reinforced polymers (FRP) laminate to the external face of reinforced concrete structures is currently one of the most popular and effective methods for strengthening concrete structures. This study aims to compare different machine learning models to predict the adhesion force between reinforced concrete and FRP materials. Single model and ensemble model are used to solve this problem. The analysis results show that the model incorporates packing the regression classification tree - Bagging model (CART) gives the results with the most superior criteria of all the single models and the ensemble models.

Keywords: Adhesion between FRP and concrete; FRP materials; machine learning model.

1. GIỚI THIỆU

Bê tông cốt thép là vật liệu phổ biến nhất hiện nay trong việc xây dựng cơ sở hạ tầng. Do đặc điểm các công trình bê tông cốt thép chi phí đầu tư ban đầu rất lớn, thời hạn sử dụng dài nên nhu cầu về tìm kiếm các loại vật liệu và kỹ thuật xây dựng mới ngày càng tăng, đặc biệt để nhằm phục vụ cho công tác gia cố sửa chữa các công trình xuống cấp. Vật liệu polyme cốt sợi (FRP) đã nổi lên như một sự lựa chọn hàng đầu của các doanh nghiệp xây dựng trong việc sửa chữa, gia cường cho các cấu kiện bê tông nhờ các đặc tính ưu việt về độ bền cao, khả năng chống ăn mòn và dễ sử dụng của nó (hình 1).

Đã có khá nhiều nghiên cứu và phân tích đánh giá về độ bền liên kết giữa FRP và cấu kiện bê tông cốt thép [1-4]. FRP rất dễ sử dụng và phù hợp với nhiều hình dạng cấu trúc khác nhau, một ưu điểm khác là FRP có chi phí lắp đặt và chi phí vật liệu tương đối thấp nhưng hiệu quả mang lại rất cao [5-7]. Khả năng bám dính giữa FRP và cấu kiện bê tông rất được các nhà khoa học và doanh nghiệp quan tâm.

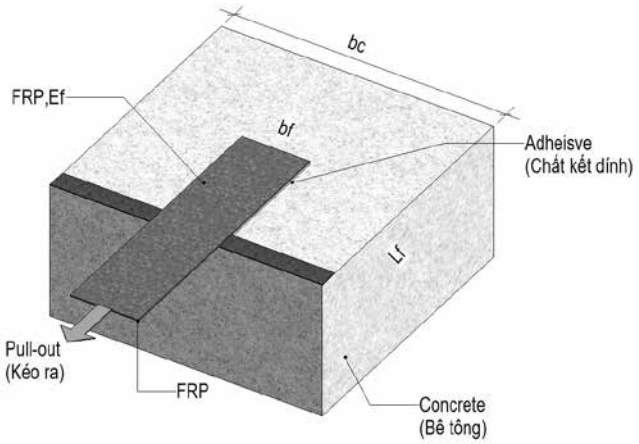

Hình 1. Các thành phần trong thí nghiệm kiểm tra lực bám dính của một tấm FRP.

Zhou và cộng sự (2018) phân tích các thực nghiệm giữa cấu kiện bê tông và tấm gia cường [6]. Zhou và Wu (2011) trình bày

một mô hình toán học để xây dựng mối quan hệ giữa cấu kiện bê tông và FRP [7]. Việc tính toán và đưa ra các mô hình này là phức tạp vì phải tính đến ảnh hưởng của các thông số khác nhau như kích thước của dầm BTCT và tính chất vật liệu của bê tông và tấm FRP.

Chính vì vậy, việc so sánh và xây dựng một mô hình dự báo dựa trên phương pháp học máy nhằm dự đoán khả năng liên kết giữa FRP và cấu kiện bê tông để tìm ra một mô hình có hiệu suất cao, đáp ứng nhu cầu sử dụng của doanh nghiệp là điều cần thiết.

2. TỔNG QUAN NGHIÊN CỨU

2.1 Cấu tạo của FRP

Nhựa gia cố bằng sợi (Fiber Reinforced Plastic hay Fiber Reinforced Polymer - FRP) hay nhựa composite gia cường là một loại vật liệu gia cố gồm 2 thành phần chính là sợi gia cường và vật liệu liên kết các sợi hay còn gọi là nhựa nhiệt rắn.

Carbon, Glass và Aramid là ba loại sợi chính được sử dụng trong xây dựng [8]. Hỗn hợp thường được đặt tên theo sợi gia cường, ví dụ: nhựa gia cố sợi thủy tinh (GFRP), nhựa gia cố sợi carbon (CFRP), nhựa gia cố sợi aramid (AFRP). Các tính chất quan trọng nhất khác nhau giữa các loại sợi là độ cứng và độ căng kéo. Các chất liên kết sẽ truyền lực giữa các sợi và bảo vệ các sợi khỏi các tác động bất lợi, các chất liên kết thường được sử dụng để chế tạo FRP là vinylester và epoxy (hình 2).

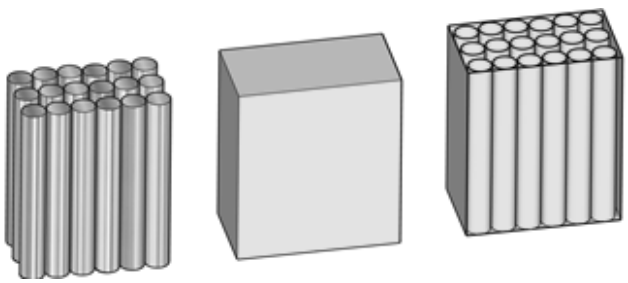

Hình 2. Cấu tạo của FRP [8].

2.2 Tính chất của FRP

FRP là một giải pháp hữu ích cho các cấu kiện bê tông cốt thép gia tăng độ bền nén, cắt, uốn và kéo đối với các điều kiện môi trường và tải trọng khắc nghiệt. FRP cũng có chức năng như cốt thép liên kết bên ngoài để tăng cường lực cho các kết cấu thép, gỗ, bê tông và khối xây [9].

Tính chất cơ học của vật liệu tổng hợp FRP phụ thuộc vào tỷ lệ sợi và vật liệu liên kết, phương pháp sản xuất, đặc tính cơ học của vật liệu cấu thành và hướng của sợi phân bổ trên nền, bao gồm:

- Cường độ nén: FRP có khả năng chịu nén tốt. Theo một nghiên cứu năm 2014 của giáo sư Sahu và các cộng sự [10], độ bền nén của sợi gốc epoxy lớn hơn sợi gốc polyeste. Độ bền này phụ thuộc khá nhiều vào độ dày của tấm FRP và ma trận sợi gia cường, độ bền của nó sẽ được gia tăng đáng kể nếu ma trận đó được đặt trong nền liên kết dạng bánh sanwich.

- Sức chống cắt: Mối liên kết bền vững giữa nhựa nhiệt rắn và sợi gia cường tạo nên một khả năng chống cắt tuyệt vời cho FRP. Đây là lý do nó được sử dụng khá nhiều để giảm độ võng dài hạn giảm bề rộng vết nứt của các cấu kiện bê tông cốt thép.

- Độ bền chịu uốn: Nhiều nghiên cứu đã kiểm tra các tham số và biến số ảnh hưởng đến độ bền uốn của vật liệu tổng hợp FRP, chẳng hạn như chiều dài sợi, hàm lượng chất kết dính, xử lý nhiệt các sợi gia cường trước khi chế tạo. Để tăng cường độ uốn, FRP được sử dụng để liên kết các mặt chịu lực của gỗ, bê tông và khối xây. Cường độ chịu tải đã được tăng cường tới 40% bằng cách tăng cường các thành phần chịu uốn [11].

- Độ bền kéo: FRP được ứng dụng để gia cố bên trong và gia cường bên ngoài cho các cấu trúc bê tông cốt thép sử dụng sợi tổng hợp. Các sợi được sắp xếp thẳng, song song và liên tục thông qua một ma trận để tạo ra một độ bền kéo khá lớn song song với hướng sợi gia cường [12]. Giá trị độ bền kéo của FRP thường được xác định dựa trên loại sợi, hướng sợi, nền, mặt cắt, độ hút ẩm [13].

2.3 Tình hình nghiên cứu trong và ngoài nước

Trong thời gian gần đây đã có khá nhiều nghiên cứu về khả năng chịu lực của bám dính của FRP đã được thực hiện. Năm 2008, Wu và các cộng sự đã nghiên cứu một mô hình cường độ liên kết ba tham số đơn giản nhưng hợp lý và chính xác hơn cho FRP dựa trên phân tích thống kê, trong đó các tham số chính của ứng xử cường độ liên kết được xem xét [14]. Năm 2013, Wu và Jiang đã nghiên cứu về các tham số liên kết giao thoa được định lượng và mô hình hóa nó trong công trình này thông qua các nghiên cứu thực nghiệm và phân tích [15].

Năm 2014, Lee và Lee đã nghiên cứu một phương pháp mới để tính toán cường độ chịu nén giới hạn của bê tông FRP bằng cách sử dụng một số lượng lớn dữ liệu thực nghiệm và xử lý nó bằng mô hình mạng thần kinh nhân tạo (ANN)[16]. Năm 2015, EM Golafshani và các cộng sự đã nghiên cứu dữ liệu thực nghiệm của 159 mẫu sử dụng mạng thần kinh nhân tạo và lập trình di truyền để dự đoán cường độ liên kết của thanh GFRP [17]. Năm 2020, Yingwu Zhou và các cộng sự đã nghiên cứu mô hình mạng lưới thần kinh rõ ràng để dự đoán cường độ liên kết bề mặt bê tông FRP dựa trên cơ sở dữ liệu lớn [18]. Năm 2022, Wei-Chih Wang và các cộng sự đã nghiên cứu mô hình máy học với siêu tham số tự do để dự đoán khả năng kết dính của giao diện FRP-to-bê tông sử dụng dữ liệu đa quốc gia [19].

Tuy nhiên, nghiên cứu về độ bám dính của vật liệu FRP gia cường lên bề mặt cấu kiện bê tông chưa được chú trọng ở Việt Nam. Độ bám dính đóng vai trò rất quan trọng để tạo sự liên kết giữa vật liệu, giúp phân tán các lực các dụng lên cấu kiện cũng như gia tăng tính thẩm mỹ của công trình. Trong nghiên cứu này, nhóm tác giả xây dựng các mô hình máy học và so sánh sự kết hợp giữa chúng nhằm xây dựng một mô hình phù hợp, có độ chính xác cao để dự báo lực bám dính giữa bê tông cốt thép và vật liệu FRP gia cường.

3. THU THẬP VÀ XỬ LÝ SỐ LIỆU

Nghiên cứu này phân tích dựa trên bộ dữ liệu đã được công bố năm 2022 của Wei-Chih Wang và các cộng sự [19]. Bộ dữ liệu bao gồm 855 mẫu về khả năng chịu lực của vật liệu bê tông cốt thép và vật liệu FRP gia cường. Bảng 1 và hình 3 thống kê các biến số trong bộ dữ liệu này.

Việc xây dựng mô hình học máy phụ thuộc vào dữ liệu huấn luyện. Tất cả các giá trị thuộc tính trước tiên được chuyển đổi thành một phạm vi [0, 1] để giảm thiểu tác động của các phạm vi số lớn hơn đối với các phạm vi nhỏ hơn và giảm thiểu khó khăn về số trong quá trình tính toán:

$$x_{i,j}^{trans} = \frac{x_{i,j} - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Trong đó: $x_{i,j}$ là giá trị thực của dữ liệu thứ i,j, x_{min} và x_{max} lần lượt là giá trị nhỏ nhất và lớn nhất của tập hợp đại lượng đó.

Bảng 1: Các mô tả thống kê liên quan đến từng biến số trong bộ dữ liệu

STT	Diễn giải nội dung	Biến số	Ký hiệu	Đơn vị	Giá trị nhỏ nhất	Giá trị lớn nhất	Giá trị trung bình	Độ lệch chuẩn
1	Chiều rộng của mặt bê tông	X1	b_c	mm	80	500	144,3	57,638
2	Cường độ chịu nén của bê tông	X2	f'_c	MPa	8	75,5	39,54	15,216
3	Mô đun đàn hồi của tấm FRP	X3	E_f	GPa	22,5	425,1	204,8	78,141
4	Chiều dày của tấm FRP	X4	t_f	mm	0,083	4	0,51	0,572
5	Chiều rộng của tấm FRP	X5	b_f	mm	10	150	57,52	26,392
6	Chiều dài của tấm FRP	X6	L_f	mm	20	400	172,97	101,021
7	Khả năng chịu lực	Y	P_u	kN	2,4	56,5	17,8	10,4

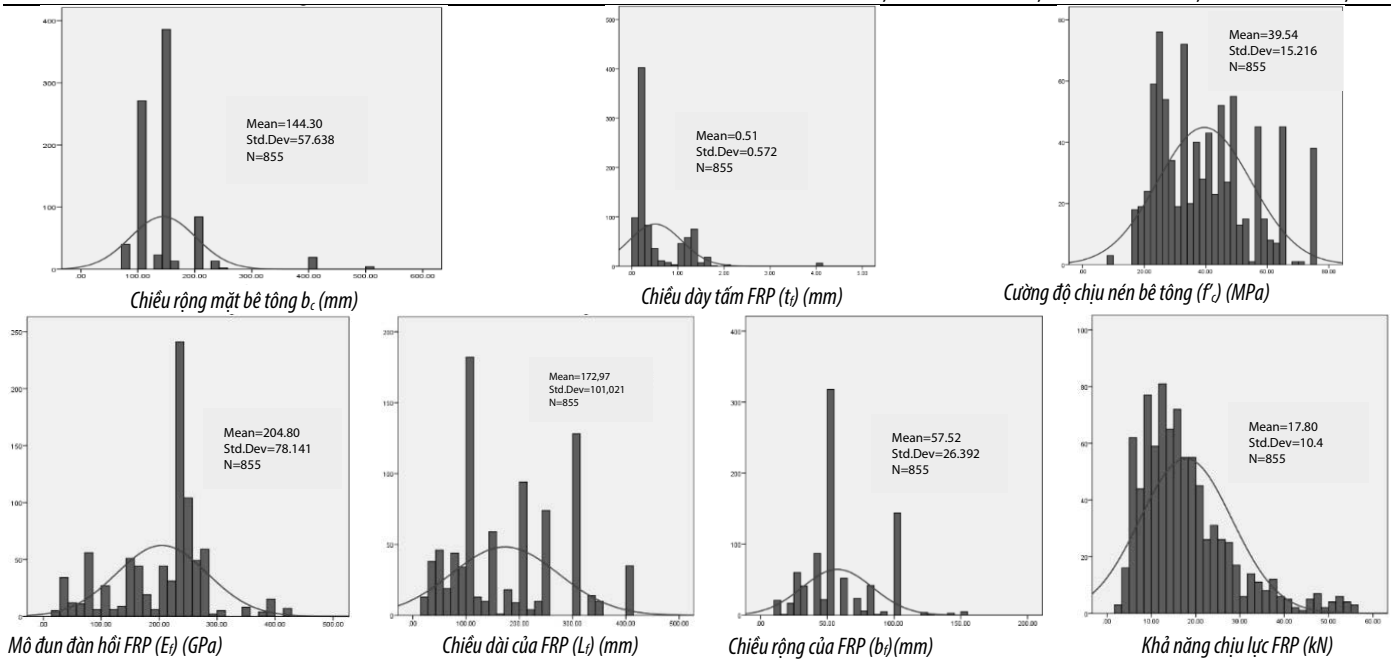

Hình 3. Phân phối thống kê của các biến đầu vào và đầu ra trong bộ dữ liệu.

4. PHƯƠNG PHÁP NGHIÊN CỨU

4.1 Phương pháp máy học

4.1.1 Mô hình đơn

4.1.1.1 Mô hình mạng thần kinh nhân tạo (Artificial Neural Network)

Mạng thần kinh nhân tạo (ANN) là các chương trình máy tính lấy cảm hứng từ sinh học được thiết kế để mô phỏng cách thức bộ não con người xử lý thông tin, ANN thu thập dữ liệu bằng cách phát hiện các mẫu và mối quan hệ trong dữ liệu và học (hoặc được đào tạo) thông qua kinh nghiệm chứ không phải từ lập trình. Có hai loại cấu trúc ANN là mạng truyền thẳng và mạng có hồi tiếp.

Mạng đa tầng truyền thẳng (Multi-layer Perceptron - MLP) thường được sử dụng phổ biến để giải quyết các bài toàn phi tuyến và phức tạp, khi mà mối quan hệ giữa các quá trình không dễ thiết lập một cách tường minh để tiến hành xây dựng mô hình. Đối với mạng thần kinh đa tầng truyền thẳng, các nơron nhân tạo được sắp xếp thành các lớp: lớp vào, các lớp ẩn và lớp đầu ra.

Đối với mạng thần kinh truyền thẳng, các nơ-ron nhân tạo được sắp xếp thành các lớp bao gồm lớp vào, các lớp ẩn và lớp đầu ra. Trong đó, lớp vào là nơi đưa vào các giá trị đầu vào, các lớp ẩn được sử dụng để xử lý thông tin và tính toán, và lớp đầu ra là nơi xuất ra các giá trị đầu ra của mô hình.

Mạng lan truyền ngược (Backpropagation in Neural Network) được sử dụng rộng rãi và được biết đến là mô hình mạng hiệu quả nhất [20, 21]. Mạng lan truyền ngược là một thuật toán điều chỉnh trọng số được sử dụng rất phổ biến để tìm kiếm các giá trị tối ưu hóa. Thuật ngữ truyền ngược để cập đến chiều truyền của sai số, phương pháp lan truyền ngược sử dụng một tập hợp các giá trị đầu vào và đầu ra để tìm ra mạng nơ-ron thần kinh mong muốn.

Hàm sigmoid được sử dụng để kích hoạt mỗi nơ-ron trong một lớp đầu ra và thuật toán chuyển đổi liên hợp theo quy mô được sử dụng để tính toán trọng số của mạng:

$$net_k = \sum w_{kj} O_j \quad \text{và} \quad y_k = f(net_k) = \frac{1}{1+e^{-net}} \qquad (2)$$

Trong đó: net_k là sự kích hoạt của nơ-ron thứ k^{th}, j là tập hợp các nơ-ron ở lớp trước, w_{kj} là bộ trọng số của kết nối giữa nơ-ron k và nơ-ron j, O_j là đầu ra của nơ-ron j, y_k là hàm chuyển sigmoid hoặc hàm kích hoạt.

4.1.1.2 Mô hình véc-tơ hỗ trợ hồi quy SVR (Support Vector Regression)

Mô hình véc-tơ hỗ trợ hồi quy (SVM) lần đầu tiên được biết đến vào năm 1992, được giới thiệu bởi Boser, Guyon và Vapnik trong COLT-92. Máy vectơ hỗ trợ (SVM) là một tập hợp các phương pháp học có giám sát có liên quan đến các phương pháp được sử dụng để phân loại và hồi quy. Công thức xác định mô hình chung của SVR được mô tả như hình 4 và công thức sau:

$$f(x) = w^T \times \varphi(x) + b \qquad (3)$$

Trong đó : f(x) là hàm hồi quy, φ(x) là hàm ánh xạ dữ liệu đầu vào lên không gian đa chiều, w^T là vectơ trọng số, b là hệ số thiên lệch.

4.1.1.3 Mô hình hồi quy tuyến tính LR (Linear Regression)

Một mô hình thống kê là sự đơn giản hóa của thực tế được thể hiện bằng ngôn ngữ toán học. Để đạt được sự đơn giản hóa này, tất cả các mô hình thống kê đều đưa ra các giả định. Hồi quy tuyến tính (LR- Linear Regression) cũng không ngoại lệ. Mô hình LR theo Neter và các cộng sự (1996) [2] là phiên bản nâng cao của mô hình hồi quy đơn giản, mô hình này xác định mối quan hệ giữa một biến phụ thuộc vô hướng (biến phản hồi) và hai hoặc nhiều biến độc lập (biến giải thích) bằng cách sử dụng hồi quy tuyến tính.

Mô hình này chỉ rõ rằng một hàm thích hợp của xác suất phù hợp của sự kiện là một hàm tuyến tính với các giá trị quan sát của các biến giải thích có sẵn. Công thức chung cho các mô hình hồi quy nhiều lần như sau:

$$y=f(x)=\beta_0+\sum_{j=1}^{n}\beta_j x_j+\varepsilon_1 \quad (4)$$

Trong đó: y là biến phụ thuộc (biến phản hồi), β_0 là một hằng số, β_j là hệ số hồi quy (j = 1,2,...,n), ε_1 là một thuật ngữ lỗi, x_j là biến độc lập (biến giải thích) (j = 1,2,...,n).

4.1.1.4 Mô hình cây phân loại và hồi quy CART (Classification and Regression Tree)

Mô hình cây phân loại và hồi quy (CART) được giới thiệu bởi Breiman và các cộng sự [22]. Mô hình này được sử dụng cho các bài toán mô hình dự báo phân loại hoặc hồi quy.

Mô hình CART được xây dựng thông qua hệ số Gini và các công thức như sau:

$$g(t)=\sum_{j\neq i} p(j|t)\,p(i|t) \quad (5)$$

$$p(j|t)=\frac{p(j,t)}{p(t)} \;\; ; \;\; p(j,t)=\frac{p(j)\times N_j(t)}{N_j} \quad (6)$$

$$p(t)=\sum_j p(j|t) \;\; \text{và} \;\; \text{Gini index}=1-\sum_j p(j|t)$$

Trong đó: i và j là các biến phân loại theo mỗi mục, $N_j(t)$ là số lượng nút t được ghi lại trong danh mục j, N_j là số lượng nút gốc được ghi lại trong danh mục j, p(j) là giá trị xác suất trước cho danh mục j.

4.1.2 Mô hình kết hợp - (Ensemble model)

4.1.2.1 Mô hình kết hợp Voting (bỏ phiếu)

Mô hình voting (hình 4) là phương pháp kết hợp nhiều mô hình phân loại độc lập kết hợp các kết quả đầu ra của các mô hình đơn bằng cách sử dụng quy tắc meta [23].

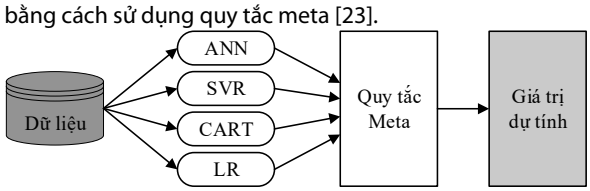

Hình 4. Cơ chế tổng quát của mô hình voting.

Các mô hình voting được xây dựng trong nghiên cứu này, bao gồm: ANN+SVR, ANN+CART, ANN+LRR, SVR+CART, SVR+LRR, CART+LRR, ANN+SVR+CART, ANN+CART+LRR, ANN+CART+LRR, SVR+CART+LRR, ANN+SVR+CART+LRR.

4.1.2.2 Mô hình kết hợp Bagging (đóng gói)

Các mô hình bagging (hình 5) sao chép các mẫu dữ liệu một cách ngẫu nhiên thay thế tập dữ liệu ban đầu và mỗi mô hình hồi quy dự đoán các giá trị từ các mẫu dữ liệu một cách độc lập [24]. Như vậy, mỗi mẫu dữ liệu có thể xuất hiện lặp lại hoặc không xuất hiện trong bất kỳ tập dữ liệu huấn luyện cụ thể nào.

Quy tắc meta được áp dụng cho tất cả các kết quả đầu ra trong nghiên cứu này.

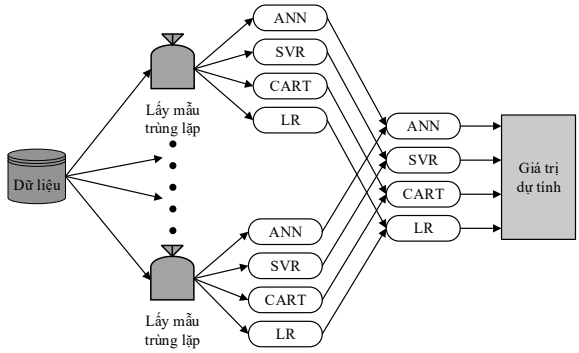

Hình 5. Cơ chế tổng quát của mô hình bagging.

4.1.2.3 Mô hình kết hợp stacking (xếp chồng)

Các mô hình tổ hợp stacking (hình 6) là một mô hình hai giai đoạn và mô tả nguyên lý của mô hình tổ hợp stacking [25]. Trong giai đoạn 1, mỗi mô hình đơn lẻ dự đoán một giá trị đầu ra. Sau đó, các kết quả đầu ra này được sử dụng làm đầu vào để đào tạo lại mô hình bằng các kỹ thuật máy học này nhằm đưa ra siêu dự đoán trong giai đoạn 2. Có bốn mô hình xếp chồng bao gồm: ANN (ANN, SVR, CART, LRR), SVR (ANN, SVR, CART, LRR), CART (ANN, SVR, CART, LRR), LRR (ANN, SVR, CART, LRR).

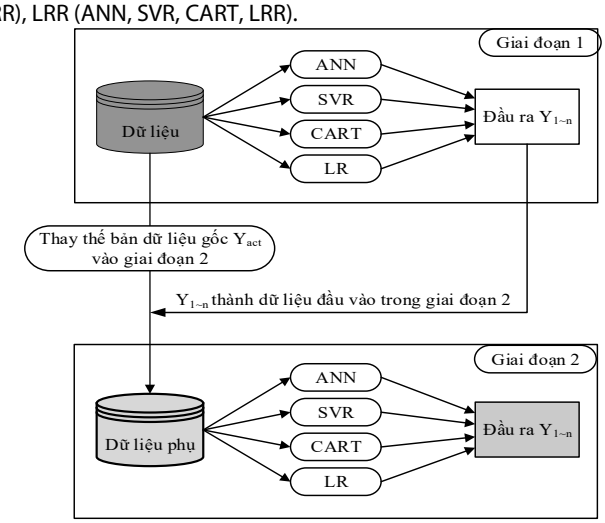

Hình 6. Cơ chế tổng quát của mô hình Bagging.

4.2 Đánh giá mô hình

4.2.1 Xác thực chéo K-fold

Để giảm thiểu sai lệch liên quan đến dữ liệu đào tạo và thử nghiệm được lấy mẫu ngẫu nhiên, hiệu suất dự đoán thường được xác nhận bằng cách sử dụng phương pháp xác nhận chéo k -lần. Vì xác nhận chéo chỉ định ngẫu nhiên các trường hợp riêng lẻ cho các nếp gấp riêng biệt, nên bản thân các nếp gấp này thường được phân tầng. Vì 10 được coi là số lần gấp tối ưu [26], xác nhận chéo mười lần được sử dụng ở đây để đánh giá tính nhất quán dự đoán của hệ thống (hình 7).

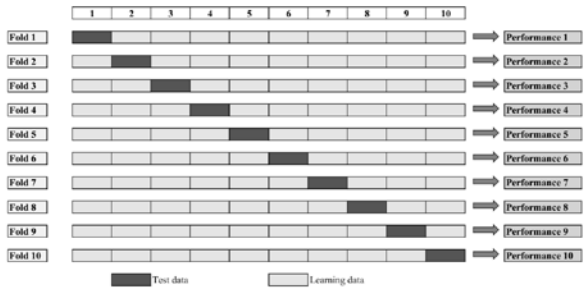

Hình 7. Phương pháp xác thực chéo 10 lần.

4.2.2 Các chỉ số hiệu suất đánh giá mô hình

Trong nghiên cứu này, năm thước đo hiệu suất nổi tiếng được sử dụng để đánh giá khả năng dự đoán của hệ thống được đề xuất [27, 28] sử dụng để đánh giá độ chính xác của dự đoán.

Chúng là hệ số tương quan tuyến tính (R), căn bậc hai của bình phương trung bình sai số (RMSE), sai số trung bình tuyệt đối (MAE) và phần trăm sai số trung bình tuyệt đối (MAPE) được thể hiện từ công thức (7) đến (10). Chỉ số tổng hợp (SI) theo công thức (11) [29].

$$R=\frac{n\sum y.y'-\left(\sum y\right)\left(\sum y'\right)}{\sqrt{n\left(\sum y^2\right)\left(\sum y\right)^2}\sqrt{n\left(\sum y'^2\right)\left(\sum y'\right)^2}} \quad (7)$$

$$RMSE=\sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y'-y\right)^2} \quad (8)$$

$$MAE=\frac{1}{n}\sum_{i=1}^{n}\left|y-y'\right| \quad (9)$$

$$MAPE=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{y-y'}{y}\right| \quad (10)$$

$$SI=\frac{1}{m}\sum_{i=1}^{m}\left(\frac{P_i-P_{min,i}}{P_{max,i}-P_{min,i}}\right) \quad (11)$$

Trong đó y là giá trị thực tế, y' là giá trị dự đoán, n là số mẫu của bộ dữ liệu, m là số lượng các biện pháp thực hiện, P_i là thước đo hiệu suất thứ i, $P_{min,i}$ và $P_{max,i}$ lần lượt là thước đo hiệu suất nhỏ nhất và lớn nhất thứ i.

5. KẾT QUẢ VÀ THẢO LUẬN

5.1 Kết quả và phân tích đánh giá các mô hình đơn

Kết quả đào tạo và kiểm tra của các mô hình được thể hiện trong bảng 2 và hình 8. Trong các mô hình đơn thì mô hình cây phân loại và hồi quy (CART) là vượt trội nhất trong các mô hình đơn tương tự (SI=0). Các chỉ tiêu đánh giá kết quả kiểm tra phản ánh khả năng của mô hình CART chênh lệch rất lớn với: R (0.924), MAE (2.73 kN), RMSE (3.98 kN), MAPE (34.85%).

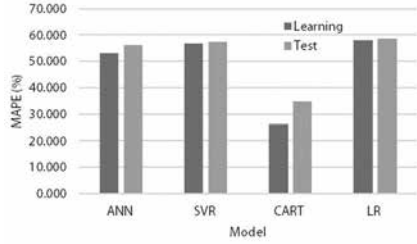

Hình 8. Biểu đồ so sánh chỉ số hiệu suất MAPE (%) của các mô hình đơn.

Bảng 2: Tổng hợp các chỉ số đánh giá hiệu suất và xếp hạng các mô hình đơn.

STT	MÔ HÌNH	LEARNING				TEST				SI (Rank)
		R	MAE (kN)	RMSE (kN)	MAPE (%)	R	MAE (kN)	RMSE (kN)	MAPE (%)	
1	ANN	0.894	4.138	5.329	53.037	0.837	4.40	5.78	56.19	0.811 (2)
2	SVR	0.803	4.439	6.203	56.873	0.798	4.49	6.27	57.41	0.979 (3)
3	**CART**	**0.953**	**2.052**	**3.113**	**26.284**	**0.924**	**2.73**	**3.98**	**34.85**	**0.000 (1)**
4	LR	0.807	4.535	6.137	58.104	0.799	4.59	6.25	58.64	1.000 (4)

Bảng 3: Tổng hợp các chỉ số đánh giá hiệu suất và xếp hạng các mô hình kết hợp.

STT	MÔ HÌNH	LEARNING				TEST				SI (Rank)
		R	MAE (kN)	RMSE (kN)	MAPE (%)	R	MAE (kN)	RMSE (kN)	MAPE (%)	
A	**MÔ HÌNH VOTING**									
1	ANN - SVR	0.878	3.869	5.196	49.569	0.848	4.09	5.51	52.35	0.747 (14)
2	**ANN - CART**	**0.948**	**2.641**	**3.483**	**33.841**	**0.917**	**3.07**	**4.15**	**39.22**	**0.293 (5)**
3	ANN - LR	0.878	3.883	5.167	49.753	0.848	4.13	5.51	52.85	0.756 (15)
4	SVR - CART	0.930	2.811	3.961	36.013	0.912	3.08	4.35	39.40	0.319 (6)
5	SVR - LR	0.806	4.470	6.149	57.271	0.800	4.52	6.24	57.81	0.991 (18)
6	CART - LR	0.930	2.855	3.927	36.793	0.911	3.13	4.35	40.02	0.330 (7)
7	ANN - SVR - CART	0.931	2.932	4.014	37.574	0.906	3.24	4.44	41.41	0.370 (8)
8	ANN - SVR - LR	0.861	3.987	5.389	51.089	0.840	4.15	5.65	53.11	0.786 (16)
9	ANN - CART - LR	0.930	2.947	3.993	37.757	0.906	3.27	4.44	41.76	0.377 (9)
10	SVR - CART - LR	0.902	3.323	4.593	42.576	0.887	3.51	4.86	44.85	0.497 (11)
11	ANN - SVR - CART - LR	0.912	3.259	4.415	41.734	0.891	3.48	4.77	44.50	0.476 (10)
B	**MÔ HÌNH BAGGING**									
1	ANN	0.903	3.420	4.535	43.806	0.881	3.71	4.94	47.46	0.558 (12)
2	SVR	0.803	4.442	6.198	56.919	0.800	4.49	6.26	57.41	0.984 (17)
3	**CART**	**0.971**	**1.733**	**2.531**	**22.199**	**0.948**	**2.25**	**3.34**	**28.72**	**0.000 (1)**
4	LR	0.807	4.527	6.137	57.999	0.801	4.58	6.23	58.52	1.000 (19)
C	**MÔ HÌNH STACKING**									
1	ANN - (ANN, SVR, CART, LR)	0.955	3.730	4.579	47.694	0.878	3.99	5.14	50.99	0.635 (13)
2	**SVR - (ANN, SVR, CART, LR)**	**0.958**	**2.072**	**3.028**	**26.542**	**0.922**	**2.75**	**4.06**	**35.14**	**0.208 (2)**
3	CART - (ANN, SVR, CART, LR)	0.942	2.396	3.521	30.709	0.911	2.93	4.30	37.50	0.287 (4)
4	LR - (ANN, SVR, CART, LR)	0.956	2.220	3.023	28.448	0.923	2.79	4.01	35.64	0.211 (3)

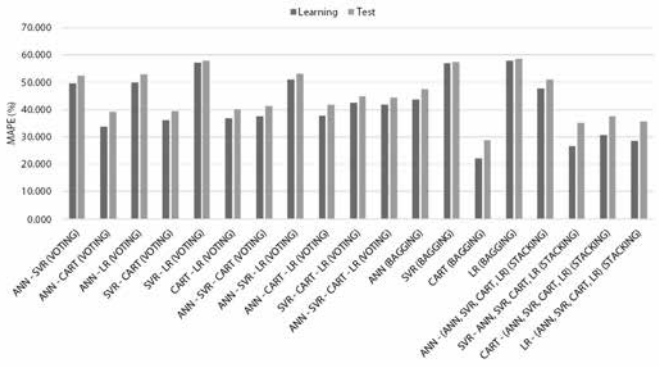

Hình 9. Biểu đồ so sánh chỉ số hiệu suất MAPE (%) của tất cả các mô hình đơn và kết hợp.

5.2 Kết quả và phân tích đánh giá các mô hình kết hợp

Kết quả đánh giá mô hình được trình bày tại bảng 3 và hình 9, trong đó Mô hình Bagging (CART) được trình bày cho kết quả các tiêu chí vượt trội nhất trong tất cả các mô hình kết hợp (SI=0) với R (0.948), MAE (2.25 kN), RMSE (3.34 kN), MAPE (28.72%). Kế đến là mô hình Stacking: SVR-(ANN, SVR, CART, LR) cho kết quả tốt thứ hai với R (0.922), MAE (2.75 kN), RMSE (4.06 kN), MAPE (35.14%). Mô hình ANN - CART là mô hình cho kết quả đào tạo tốt nhất trong nhóm các mô hình Voting với R (0.917), MAE (3.07 kN), RMSE (4.15 kN) và MAPE (39.22%).

Từ đó cho thấy các mô hình đóng gói và xếp chồng được sử dụng để giảm lỗi tổng quát hóa của dự đoán. Kết quả này cũng chỉ ra rằng mô hình kết hợp đóng gói và xếp chồng là mô hình tốt nhất trong dự đoán khả năng chịu lực bám dính giữa vật liệu bê tông cốt thép và vật liệu FRP gia cường với chỉ số SI đứng đầu (bảng 3).

6. KẾT LUẬN

Nghiên cứu này tập trung vào xây dựng và so sánh các mô hình máy học khác nhau để dự báo lực bám dính giữa vật liệu bê tông cốt thép và vật liệu FRP gia cường. Các mô hình được so sánh với phạm vi đầu vào lớn bao gồm 855 dữ liệu được thu thập từ nghiên cứu của tác giả Wei-Chih Wang và các cộng sự.

Nghiên cứu này dựa trên cơ sở bộ dữ liệu đủ lớn và đã được công bố quốc tế để đảm bảo tính khách quan và tính tổng quát cũng như cung cấp những thông tin quan trọng để nghiên cứu về khả năng liên kết của FRP và bê tông.

Một so sánh tổng quan giữa cá mô hình đơn và mô hình kết hợp được trình bày trong nghiên cứu giúp người đọc có thể khái quát và đánh giá được khả năng dự báo giữa các mô hình.

Các kết quả đánh giá khách quan đã chỉ ra rằng mô hình Bagging (CART) là mô hình tốt nhất trong tất cả các mô hình đơn và kết hợp để dự báo lực bám dính giữa vật liệu bê tông cốt thép và vật liệu FRP gia cường. Từ đó có thể áp dụng nghiên cứu cho nhiều bài toán, nhiều lĩnh vực khác nhau trong việc dự đoán và tối ưu hóa trong tương lai.

TÀI LIỆU THAM KHẢO

[1]. Cao, M.S., et al., *Neural network ensemble-based parameter sensitivity analysis in civil engineering systems.* Neural Computing and Applications, 2017. **28**(7): p. 1583-1590.

[2]. Neter, J., et al., *Applied linear statistical models.* 1996.

[3]. JCI., *Technical report of technical committee on retrofit technology.* Proc Int Symp on Latest Achievement of Technology and Research on Retrofitting Concr Struct, 2003.

[4]. Hiroyuki Y, W.Z., *Analysis of debonding fracture properties of CFS strengthened member subject to tension. Proc. 3rd Int Symp on Non-Metallic (FRP) reinforcement for Concr Struct.* 1997.

[5]. Lin, X., Y.X. Zhang, and P. Pathak, *7 - Finite element analysis of FRP-strengthened reinforced concrete beams under static and cyclic loads*, in *Nonlinear Finite Element Analysis of Composite and Reinforced Concrete Beams*, X. Lin, Y.X. Zhang, and P. Pathak, Editors. 2020, Woodhead Publishing. p. 101-118.

[6]. Zhou, Y., et al., *Shear strength components of adjustable hybrid bonded CFRP shear-strengthened RC beams.* Composites Part B: Engineering, 2019. **163**: p. 36-51.

[7]. Zhou, Y.-W. and Y.-F. Wu, *General model for constitutive relationships of concrete and its composite structures.* Composite Structures, 2012. **94**(2): p. 580-592.

[8]. Contractor, T. *Fibre Reinforced Polymer (FRP) in Construction, Types and Uses*. 2022; Available from: https://theconstructor.org/concrete/fibre-reinforced-polymer/1583/.

[9]. Abbood, I.S., et al., *Properties evaluation of fiber reinforced polymers and their constituent materials used in structures–A review.* Materials Today: Proceedings, 2021. **43**: p. 1003-1008.

[10]. N.P. Sahu, D.K.K., G.C. Patel, S. Bohidar, P. Sen, *Study on aramid fibre and comparison with other composite materials.* Int. J. Innov. Res. Sci. Technol. 1, 2014. **7**: p. 303–306.

[11]. Amran, Y.M., et al. *Properties and applications of FRP in strengthening RC structures: A review*. in *Structures*. 2018. Elsevier.

[12]. Jiao, H. and X.L. Zhao, *CFRP strengthened butt-welded very high strength (VHS) circular steel tubes.* Thin-Walled Structures, 2004. **42**(7): p. 963-978.

[13]. Selzer, R., K.J.C.P.A.A.S. Friedrich, and Manufacturing, *Mechanical properties and failure behaviour of carbon fibre-reinforced polymer composites under the influence of moisture.* 1997. **28**(6): p. 595-604.

[14]. Wu, Z., S.M. Islam, and H. Said, *A Three-Parameter Bond Strength Model for FRP—Concrete Interface.* Journal of Reinforced Plastics and Composites, 2008. **28**(19): p. 2309-2323.

[15]. Wu, Y.-F. and C. Jiang, *Quantification of bond-slip relationship for externally bonded FRP-to-concrete joints.* Journal of Composites for Construction, 2013. **17**(5): p. 673-686.

[16]. Lee, S. and C. Lee, *Prediction of shear strength of FRP-reinforced concrete flexural members without stirrups using artificial neural networks.* Engineering Structures, 2014. **61**: p. 99-112.

[17]. Golafshani, E., et al., *Artificial neural network and genetic programming for predicting the bond strength of GFRP bars in concrete.* Materials, 2015. **48**(5): p. 1581-1602.

[18]. Zhou, Y., et al., *Explicit neural network model for predicting FRP-concrete interfacial bond strength based on a large database.* Composite Structures, 2020. **240**: p. 111998.

[19]. Wang, W.-C., N.-M. Nguyen, and M.-T. Cao, *Smart ensemble machine learner with hyperparameter-free for predicting bond capacity of FRP-to-concrete interface: Multi-national data.* Construction and Building Materials, 2022. **345**: p. 128158.

[20]. Yi, T., et al., *Intelligent prediction of transmission line project cost based on least squares support vector machine optimized by particle swarm optimization.* Mathematical Problems in Engineering, 2018. **2018**.

[21]. Faramarzi, A., et al., *Equilibrium optimizer: A novel optimization algorithm.* 2020. **191**: p. 105190.

[22]. Breiman, L., et al., *Classification and Regression Trees. 1st Editio*. 1984, Routledge.

[23]. Kittler, J., et al., *On combining classifiers.* IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998. **20**(3): p. 226-239.

[24]. Breiman, L.J.M.l., *Bagging predictors.* 1996. **24**(2): p. 123-140.

[25]. Wolpert, D.H., *Stacked generalization.* Neural Networks, 1992. **5**(2): p. 241-259.

[26]. Kohavi, R., *A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection.* 2001. **14**.

[27]. Chou, J.-S., K.-H. Yang, and J.-Y. Lin, *Peak Shear Strength of Discrete Fiber-Reinforced Soils Computed by Machine Learning and Metaensemble Methods.* 2016. **30**(6): p. 04016036.

[28]. De O. Santos Júnior, D.S., J.F.L. de Oliveira, and P.S.G. de Mattos Neto, *An intelligent hybridization of ARIMA with machine learning models for time series forecasting.* Knowledge-Based Systems, 2019. **175**: p. 72-86.

[29]. Chou, J.-S., et al., *Evolutionary metaheuristic intelligence to simulate tensile loads in reinforcement for geosynthetic-reinforced soil structures.* Computers and Geotechnics, 2015. **66**: p. 1-15.