

Xây dựng và so sánh các mô hình học máy để dự đoán khả năng chịu cắt của vách bê tông cốt thép

Comparison of machine learning models to forecast shear strength of reinforced concrete walls

KS CAO THÀNH NHÂN¹, TS TRƯƠNG ĐÌNH NHẬT^{2*}, THS LÊ THỊ THÙY LINH³, THS TRẦN NGUYỄN THANH TÂM⁴

¹ HVCH Ngành Kỹ thuật xây dựng, Trường Đại học Kiến trúc TP. HCM; Email: caothanhnhanksxd23@gmail.com

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

³ GV Khoa SP Công nghiệp, Đại học SP Kỹ thuật, Đại học Đà Nẵng; Email: ttlinh@ute.udn.vn

⁴ Sở Xây dựng tỉnh Bạc Liêu; Email: ttamsxd@gmail.com

*Corresponding author

TÓM TẮT

Nghiên cứu này tập trung vào xây dựng và so sánh các mô hình học máy đơn và hỗn hợp để dự báo khả năng chịu cắt của vách bê tông cốt thép. Bốn mô hình đơn ANN, SVR, LR, CART và ba mô hình hỗn hợp Voting, Bagging, Stacking được đề xuất để giải quyết vấn đề này. Kết quả phân tích cho thấy rằng mô hình ANN trong mô hình hỗn hợp Bagging có độ chính xác cao hơn so với các phương pháp khác được đề cập trong tài liệu.

Từ khóa: Vách bê tông cốt thép; khả năng chịu cắt; mô hình học máy; tối ưu hóa; trình tối ưu hóa tìm kiếm sứa.

ABSTRACT

This research focuses on developing and comparing single and ensemble machine learning models to predict the shear strength of reinforced concrete walls. Four single models ANN, SVR, LR, CART and three ensemble models Voting, Bagging, Stacking are built to solve this issue. The analysis results show that the ANN model in the ensemble Bagging model has higher accuracy than other methods mentioned in the literature.

Keywords: Reinforced concrete, shear capacity; machine learning model; optimization; Jellyfish search optimizer.


1. GIỚI THIỆU

Vách bê tông cốt thép (BTCT) chịu cắt (hình 1) được sử dụng rộng rãi trong nhiều hệ thống kết cấu nhằm đảm bảo tính an toàn trước tải trọng động đất [1].

Một phương pháp hợp lý và đơn giản để dự đoán khả năng chịu cắt của vách BTCT là cần thiết để giảm tỉ lệ tính toán. Đã có nhiều phương pháp được đề xuất, tuy nhiên việc sử dụng các phương pháp này vẫn còn khá nhiều hạn chế. Mô hình giàn [3] và

thanh chống, thanh giằng mềm [4] là một ví dụ, các phương pháp này đòi hỏi tính toán tương đối phức tạp và lặp đi lặp lại để xác định cường độ chịu cắt lớn nhất của vách BTCT. Do đó, cần phải có một phương pháp hiệu quả hơn vừa có thể cung cấp các giá trị chính xác về khả năng chịu cắt vừa đủ đơn giản để sử dụng.

Trong những năm gần đây, có rất nhiều nghiên cứu đã khẳng định việc sử dụng các mô hình trí tuệ nhân tạo (AI) là một phương pháp hiệu quả để dự đoán khả năng chịu cắt của các cấu kiện như kết cấu [5], địa kỹ thuật [6]. Việc sử dụng mô hình AI là cần thiết vì tính đơn giản và dễ phát triển, đặc biệt là khi so sánh với các mô hình dựa trên quy tắc cơ học và tính hợp lý [7]. Bên cạnh đó, việc sử dụng mô hình AI cũng giảm thiểu sự phụ thuộc vào tính toán phức tạp cho các kỹ sư, thậm chí người dùng không cần phải có kiến thức chuyên môn sâu về các phép tính phức tạp.



Hình 1. Các thành phần kết cấu cơ bản của nhà cao tầng

2. TỔNG QUAN NGHIÊN CỨU

2.1 Phân loại vách BTCT

Vách BTCT chịu cắt thường được sử dụng trong các tòa nhà cao tầng để chịu tải trọng ngang do gió hoặc tải trọng động đất. Vách BTCT chịu cắt có thể được phân thành ba loại sau [8]:

- **Vách thấp:** là vách có tỉ lệ chiều cao trên chiều dài nhỏ hơn hoặc bằng hai. Đây là loại vách có khả năng chịu cắt tốt nhất và

khó bị uốn.

• **Vách trung bình:** là vách có tỉ lệ chiều cao trên chiều dài nằm trong khoảng từ hai đến ba. Loại vách này dễ bị phá hoại khi chịu uốn và chịu cắt.

• **Vách cao:** là vách có tỉ lệ chiều cao trên chiều dài lớn hơn hoặc bằng ba đây là loại vách có khả năng chịu uốn tốt nhất và phá hoại chủ yếu là do chịu uốn.

Nghiên cứu này tập trung chủ yếu vào các vách BTCT thấp.

2.2 Các nghiên cứu tương tự về khả năng chịu cắt của vách BTCT

Năm 2019, A.Siam và cộng sự [9] đã áp dụng các kỹ thuật ML để phân loại hiệu suất và dự đoán độ trôi của các bức vách chịu cắt bằng gạch xây. S.Mangalathu và cộng sự [10] năm 2020 đã phát triển một phương pháp dựa trên máy học (ML) để dự đoán các dạng phá hủy của vách BTCT chịu cắt dựa trên dữ liệu thực nghiệm liên quan đến vách chịu cắt. Cũng trong năm 2020, A.Gondia và cộng sự [11] đã đề xuất một mô hình lập trình di truyền để dự đoán độ bền cắt của các bức vách BTCT chịu cắt. Năm 2021, D-C. Feng và cộng sự [12] đã nghiên cứu xác định một số thuộc tính rất quan trọng của vách BTCT trong ước tính sức bền chịu cắt. Đặc biệt gắn đây nhất vào năm 2022, J-S. Chou và cộng sự [13] đã nghiên cứu áp dụng các kỹ thuật ML nhằm để xuất ba trường hợp liên quan đến các biến đầu vào khác nhau để dự đoán khả năng chịu cắt của vách BTCT.

3. THU THẬP VÀ XỬ LÝ SỐ LIỆU

Hình 2 mô tả các thành phần của vách BTCT, các thành phần này được thu thập từ các nghiên cứu trước đây giúp cho việc tính toán khả năng chịu lực (lực cắt, mô men và lực dọc của vách BTCT) [14].

Bộ dữ liệu vách BTCT chịu cắt được thu thập từ cơ sở dữ liệu trong các nghiên cứu trước đây và được xử lý trước với các bước như sau:


i.Sử dụng dữ liệu gốc từ D-C Feng và các cộng sự [12] nghiên cứu năm 2021. Dữ liệu liên quan đến 534 vách BTCT chịu cắt;

ii.Khi đó bộ dữ liệu của D-C Feng và các cộng sự [12] được lấy từ nghiên cứu của C-L Ning và B. Li [15] năm 2017 và L-M. Massone và F. Melo [16] năm 2018. Sự kết hợp bộ dữ liệu của hai nghiên cứu này đã tạo ra 100 dữ liệu bị trùng lặp nên đã bị xóa bỏ. Do đó còn lại 434 bộ dữ liệu;

iii.Bộ dữ liệu từ J. Chandra và các cộng sự [4] năm 2018 có 84 bộ dữ liệu, nhưng khi kết hợp với 434 bộ dữ liệu đã thu thập thì có 26 mẫu bị trùng lặp nên đã bị xóa đi, còn lại tổng cộng 492 bộ dữ liệu.

Bảng 1 trình bày các mô tả thống kê liên quan đến từng biến và hình 3 hiển thị hình ảnh trực quan về các phân phối thống kê liên quan đến các biến này.

Nhìn chung, các biến không tuân theo phân phối chuẩn và không đồng đều. Do đó, để xác định mối quan hệ giữa các biến đầu vào và đầu ra, ta cần thực hiện phân tích dữ liệu nâng cao hơn.



Hình 2. Các đại lượng đầu vào cần thiết cho thiết kế vách BTCT chịu cắt [13]

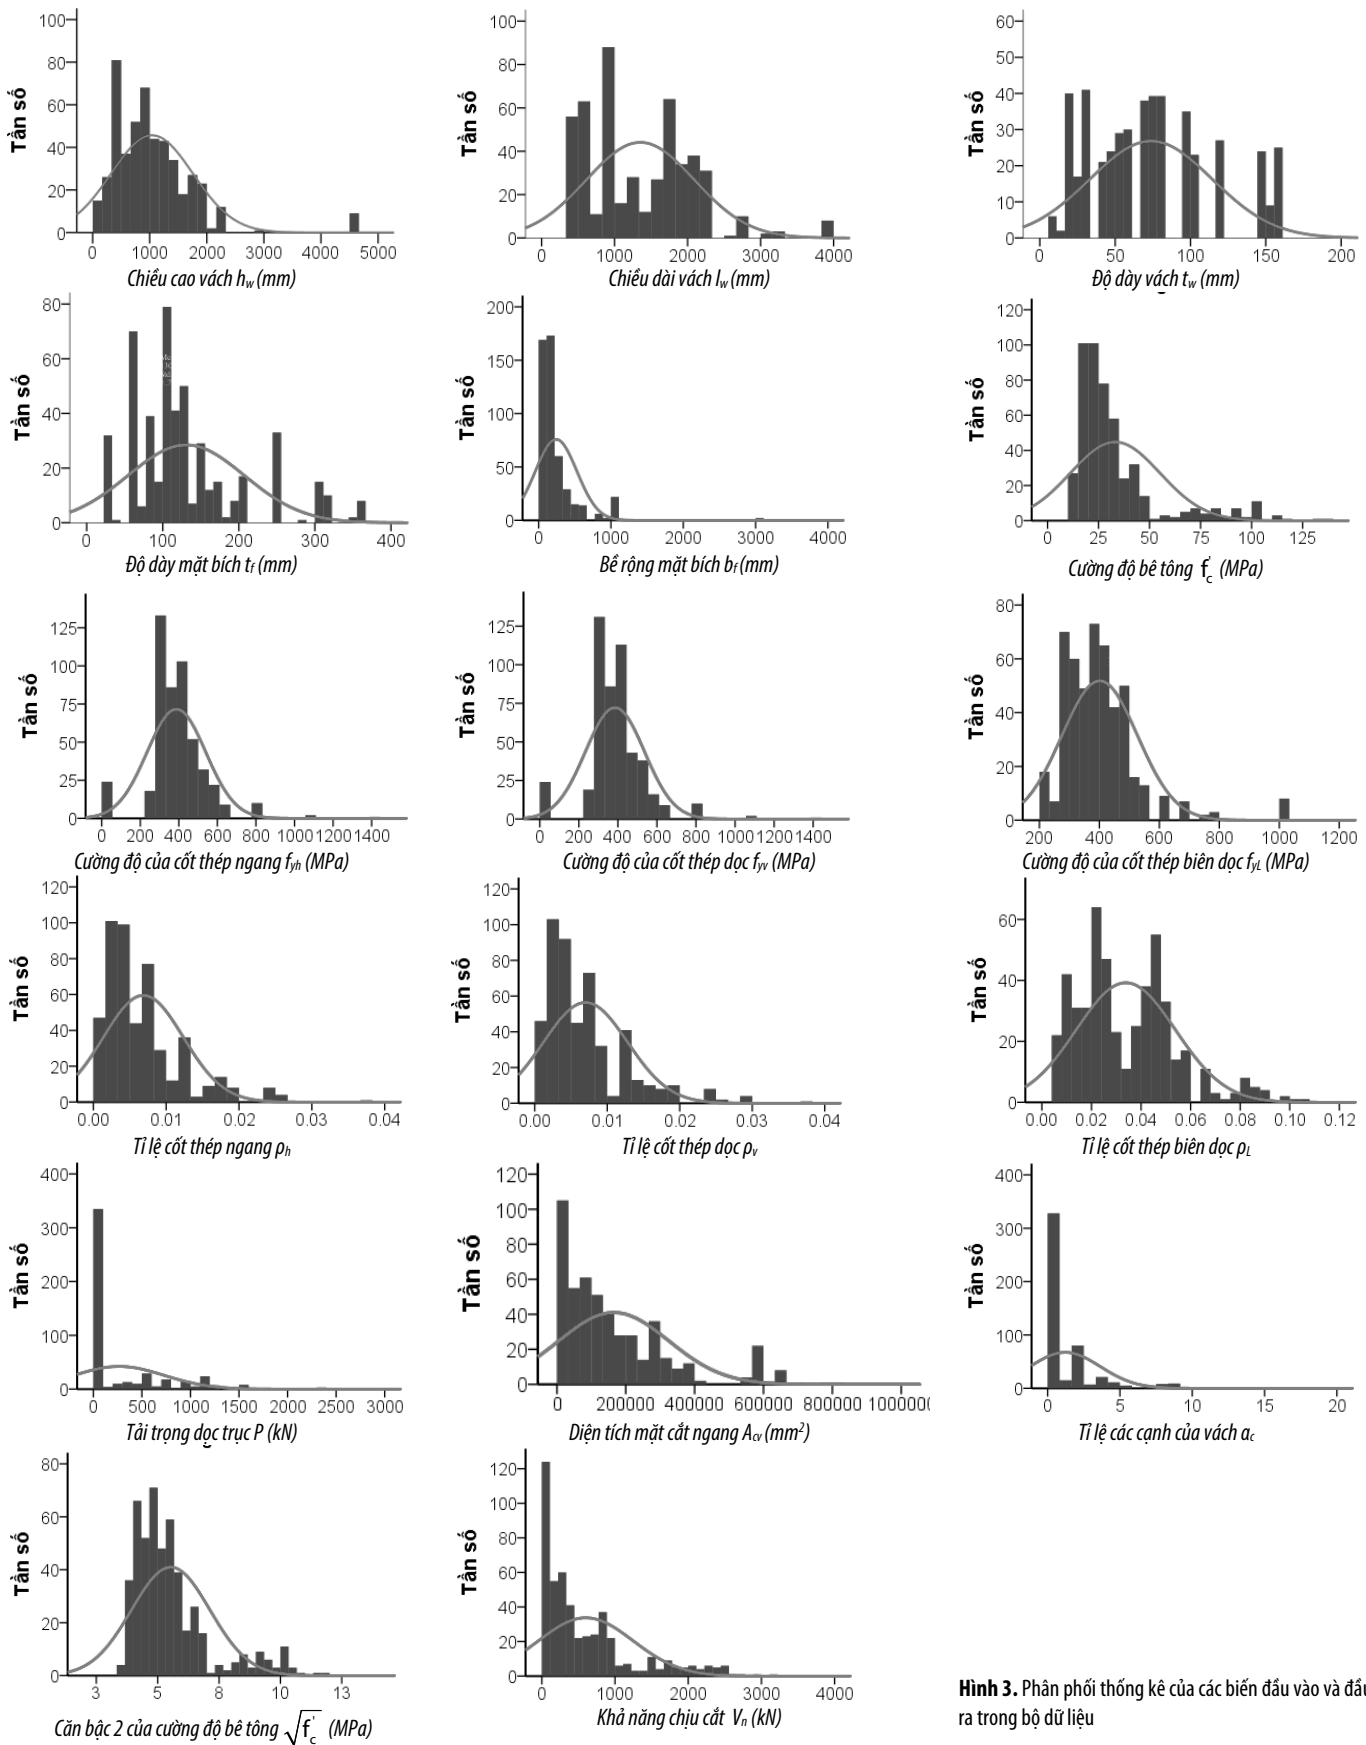
Do phạm vi giá trị của dữ liệu thô khá rộng, các hàm mục tiêu sẽ không hoạt động hiệu quả nếu không được chuẩn hóa trong một số thuật toán học máy [17]. Do đó, việc chuẩn hóa dữ liệu là một bước quan trọng giúp chuyển đổi các giá trị thuộc tính của bộ dữ liệu thành các giá trị nằm trong phạm vi [0, 1] theo công thức sau:

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

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 cao vách	X ₁	h _w	mm	150	4572	1039.641	716.2902
2	Chiều dài vách	X ₂	l _w	mm	420	3960	1352.025	741.9087
3	Độ dày vách	X ₃	t _w	mm	10	160	73.79238	40.66748
4	Độ dày mặt bích	X ₄	t _f	mm	30	360	130.7381	76.58449
5	Bề rộng mặt bích	X ₅	b _f	mm	30	3045	241.1210	287.2892
6	Cường độ bê tông	X ₆	f _c	MPa	12.3	138	33.12080	21.92864
7	Cường độ của cốt thép ngang	X ₇	f _{yh}	MPa	0	1420	387.3421	152.2247
8	Cường độ của cốt thép dọc	X ₈	f _{yv}	MPa	0	1420	384.8493	150.9224
9	Cường độ của cốt thép biên dọc	X ₉	f _{yL}	MPa	208.9	1009	401.0812	126.1964
10	Tỉ lệ cốt thép ngang	X ₁₀	rho _h	-	0	0.03667	0.006865	0.005496
11	Tỉ lệ cốt thép dọc	X ₁₁	rho _v	-	0	0.03667	0.007003	0.005798
12	Tỉ lệ cốt thép biên dọc	X ₁₂	rho _L	-	0.004	0.10583	0.033842	0.020022
13	Tải trọng dọc trục	X ₁₃	P	kN	0	2617	264.8215	465.4279
14	Diện tích mặt cắt ngang	X ₁₄	A _{cv}	mm ²	10800	825450	165018.4	159520.1
15	Tỉ lệ các cạnh của vách	X ₁₅	alpha _c	-	0	19.72066	1.206469	2.425641
16	Căn bậc 2 của cường độ bê tông	X ₁₆	sqrt(f _c)	MPa	3.50714	11.74734	5.529621	1.596655
17	Khả năng chịu cắt của vách BTCT	Y	V _n	kN	16.377	3138.128	599.9185	646.3667



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 học máy

4.1.1 Mô hình đơn

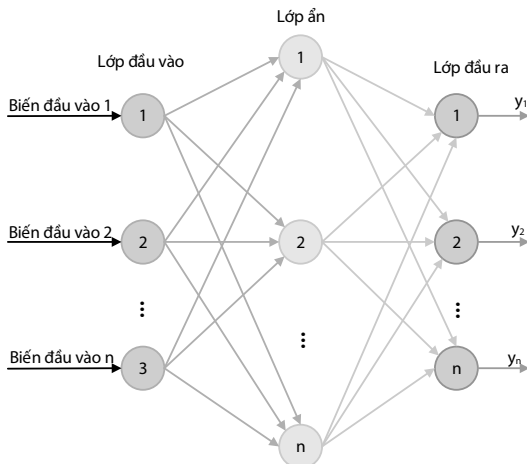
4.1.1.1 Mô hình mạng thần kinh nhân tạo ANN

Mạng ANN là một hệ thống gồm các đơn vị xử lý thông tin, tương tự như các nơ-ron trong não người, được giới thiệu lần đầu tiên vào năm 1943 bởi hai nhà nghiên cứu McCulloch và Pitts [18]. Trong mạng ANN, các nơ-ron nhân tạo được sắp xếp thành ba lớp bao gồm lớp vào, các lớp ẩn và lớp đầu ra (hình 4).

Công thức (2) sử dụng hàm sigmoid để kích hoạt mỗi nơ-ron trong một lớp đầu ra và thuật toán chuyển đổi liên hợp theo quy mô được sử dụng tính toán trọng số của mạng.

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


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.



Hình 4. Mô hình mạng thần kinh nhân tạo ANN

4.1.1.2 Mô hình véc-tơ hỗ trợ hồi quy SVR

Thuật toán SVR là thuật toán học với cơ chế hồi quy của mô hình học máy véc-tơ hỗ trợ (Support Vector Machine - SVM) - một thuật toán học máy có giám sát được Vapnik và các cộng sự [19] giới thiệu năm 1995 (hình 5).



Hình 5. Mô hình SVR

SVR là mô hình dựa trên lý thuyết học thống kê và là một kỹ thuật được đề nghị để giải quyết cho các bài toán phân lớp và được sử dụng rộng rãi trong việc giải quyết các bài toán phi tuyến tính. Công thức (3) xác định mô hình chung của SVR.

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

Trong đó: $f(x)$ là hàm hồi quy; $\varphi(x)$ 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.

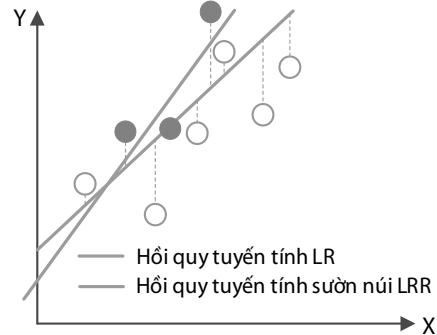
4.1.1.3 Mô hình hồi quy tuyến tính LR

Mô hình LR (Linear Regression) theo J. Neter và các cộng sự [20] 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 (hình 6).

Mô hình này chỉ rõ rằng một hàm thích hợp cho xác suất phù hợp của vấn đề cần giải quyết 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:

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

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




Hình 6. Mô hình LR

4.1.1.4 Mô hình cây phân loại và hồi quy CART

Mô hình CART (Classification and Regression Tree) được giới thiệu bởi Breiman và các cộng sự [21], là một trong những phương pháp học máy phổ biến để giải quyết cả bài toán phân loại và hồi quy. Mô hình này xây dựng một cây quyết định để phân loại hoặc dự đoán giá trị đầu ra dựa trên các thuộc tính của dữ liệu đầu vào.

Mô hình cây phân loại và hồi quy được mô tả như một cây mà trên đó mỗi nút bên trong (không phải lá) đại diện cho một phép thử của một thuộc tính, mỗi nhánh đại diện cho kết quả thử nghiệm và mỗi nút lá (hoặc đầu cuối) có một loại nhãn và loại kết quả (hình 7).



Hình 7. Mô hình CART

Cây sẽ được "cắt tỉa" cho đến khi tổng sai số được giảm thiểu để tối ưu hóa độ chính xác dự đoán của cây bằng cách giảm thiểu số lượng cành. Mô hình CART được xây dựng thông qua hệ số Gini và các công thức như sau:

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

Trong đó i và j là các biến phân loại theo mỗi mục.

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


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

Trong đó $N_j(t)$ 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 hỗn hợp - (Ensemble model)

4.1.2.1 Mô hình hỗn hợp bỏ phiếu

Mô hình bỏ phiếu (Voting) là phương pháp đơn giản nhất để kết hợp nhiều mô hình phân loại độc lập và các kết quả đầu ra của các mô hình đơn bằng cách sử dụng quy tắc meta [22]. Ý tưởng của mô hình này là sử dụng sức mạnh của nhiều mô hình để tạo ra một kết quả dự đoán tốt hơn. Hình 8 trình bày cơ chế của mô hình Voting.



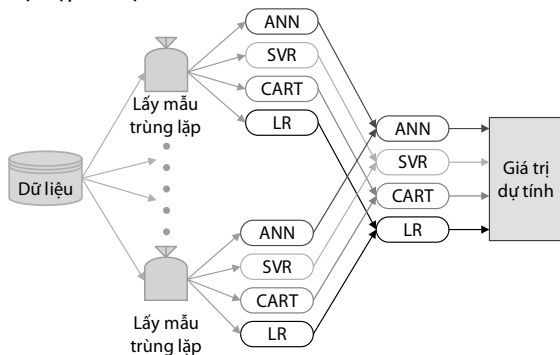
Hình 8. Cơ chế tổng quát của mô hình Voting

Giá trị trung bình các giá trị đầu ra của các mô hình đơn được sử dụng trong nghiên cứu này. Theo các mô hình học máy được thông qua, 11 mô hình voting được xây dựng trong nghiên cứu này, bao gồm: (1) ANN+SVR, (2) ANN+CART, (3) ANN+LRR, (4) SVR+CART, (5) SVR+LRR, (6) CART+LRR, (7) ANN+SVR+CART, (8) ANN+CART+LRR, (9) ANN+CART+LRR, (10) SVR+CART+LRR, (11) ANN+SVR+CART+LRR.

4.1.2.2 Mô hình hỗn hợp đóng gói

Mô hình đóng gói (Bagging) 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 (hình 9) [23].

Kỹ thuật này được sử dụng để xây dựng nhiều mô hình độc lập trên các tập dữ liệu con được chọn ngẫu nhiên từ tập dữ liệu gốc. Mỗi mô hình được xây dựng trên một tập dữ liệu khác nhau, do đó các mô hình có thể đưa ra dự đoán khác nhau cho cùng một tập dữ liệu đầu vào.

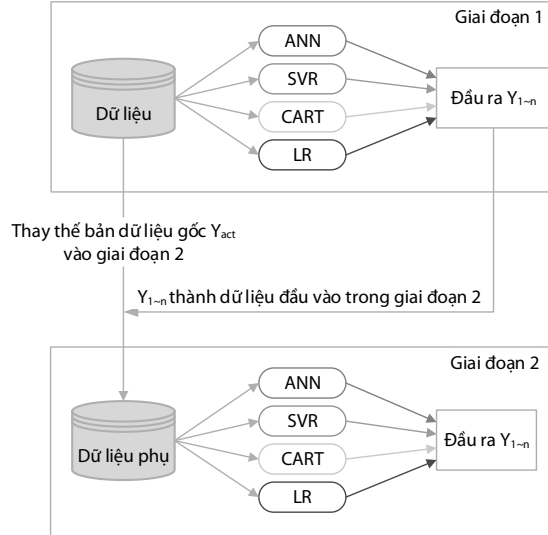


Hình 9. Cơ chế tổng quát của mô hình Bagging.

4.1.2.3 Mô hình hỗn hợp xếp chồng

Mô hình xếp chồng (Stacking) là mô hình hai giai đoạn và hình 10 mô tả nguyên tắc của mô hình. 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 học máy nhằm đưa ra siêu dự đoán trong giai đoạn 2. Có bốn mô hình xếp chồng bao gồm: ANN (ANN, SVR, CART, LR); SVR (ANN,

SVR, CART, LR); CART (ANN, SVR, CART, LR); LR (ANN, SVR, CART, LR).



Hình 10. Cơ chế tổng quát của mô hình Voting

4.1.3 Đánh giá mô hình

4.1.4 Xác thực chéo k-fold

Để giảm thiểu sai số liên quan đến việc sử dụng dữ liệu đào tạo và thử nghiệm, người ta thường sử dụng phương pháp xác nhận chéo k-lần để xác nhận hiệu suất dự đoán. Quá trình này sử dụng việc lấy mẫu ngẫu nhiên để đảm bảo tính ngẫu nhiên của các trường hợp riêng lẻ trong các nếp gấp khác nhau. Các nếp gấp này thường được phân tầng để đảm bảo tính khách quan của các kết quả. Trong lĩnh vực này, số lần gấp tối ưu thường được chọn là 10 [24].

4.1.5 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 [25, 26] sử dụng để đánh giá độ chính xác của dự đoán.

Chúng là hệ số tương quan tuyến tính (R), sai số bình phương trung bình (RMSE), sai số trung bình tuyệt đối (MAE) và phần trăm sai số trung bình tuyệt đối (MAPE) được thể hiện từ công thức (8) đến (11). Chỉ số tổng hợp (SI) theo công thức (11) [27] định lượng độ chính xác dự đoán tổng thể của hệ thống được đề xuất bằng cách lấy trung bình của bốn thước đo (1-R, RMSE, MAE và MAPE). Giá trị SI là từ 0 đến 1 vì vậy giá trị SI gần bằng 0 cho biết mô hình dự đoán có độ chính xác cao và hiệu quả [27].

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

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

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

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

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

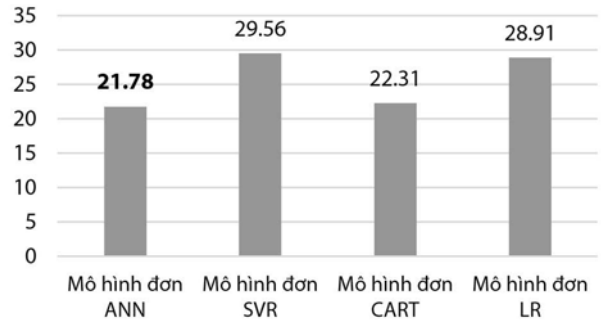
Trong đó y là giá trị thực tế; y' là giá trị dự đoán; n là số mẫu của bộ dữ liệu; m là số lượng các biện pháp thực hiện; P_i là thước đo hiệu suất thứ i ; $P_{\min,i}$ và $P_{\max,i}$ lần lượt là thước đo hiệu suất nhỏ nhất và lớn nhất thứ i .

5. PHÂN TÍCH VÀ SO SÁNH

5.1 So sánh và đánh giá mô hình các mô hình đơn

Theo bảng 2, ta thấy rằng mô hình đơn ANN đạt được kết quả tốt nhất khi xếp hạng nhất trong số các mô hình được đánh giá với các chỉ số hiệu suất như R = 0.974, MAE = 105.01 kN, RMSE = 150.02 kN, MAPE = 21.78%. Trong khi đó, mô hình đơn SVR đạt được kết quả kém nhất khi xếp hạng cuối cùng với các chỉ số hiệu suất như R = 0.919, MAE = 146.55 kN, RMSE = 277.45 kN, MAPE = 29.56%. Từ những kết quả này, chúng ta kết luận rằng mô hình ANN là mô hình đơn tốt nhất trong số các mô hình đơn được đánh giá trong việc dự đoán khả năng chịu cắt của vách BTCT với chỉ số SI xếp hạng nhất.

Để có cái nhìn trực quan hóa hơn hình 11 thể hiện biểu đồ của chỉ số hiệu suất MAPE của kết quả test cho các mô hình đơn.



Hình 11. Biểu đồ chỉ số hiệu suất MAPE (%) của các mô hình đơn ở giai đoạn test

Bảng 2: Chỉ số đánh giá hiệu suất và xếp hạng của các mô hình đơn.

Mô hình	Learning				Test				Chỉ số SI (Rank)
	R	MAE (kN)	RMSE (kN)	MAPE (%)	R	MAE (kN)	RMSE (kN)	MAPE (%)	
Mô hình đơn - single model									
ANN	0.989	77.214	104.74	15.61	0.974	105.01	150.02	21.78	0.000 (1)
SVR	0.930	116.09	240.34	23.48	0.919	146.55	277.45	29.56	1.000 (4)
CART	0.974	81.050	146.34	16.40	0.955	110.60	191.84	22.31	0.220 (2)
LR	0.948	136.01	205.64	27.51	0.939	143.34	222.26	28.91	0.761 (3)

Bảng 3: Chỉ số đánh giá hiệu suất và xếp hạng của các mô hình hỗn hợp.


Mô hình	Learning				Test				Chỉ số SI (Rank)
	R	MAE (kN)	RMSE (kN)	MAPE (%)	R	MAE (kN)	RMSE (kN)	MAPE (%)	
Mô hình Voting									
ANN - SVR	0.973	182.10	257.02	36.82	0.969	189.29	267.34	38.18	0.715 (19)
ANN - CART	0.988	173.35	236.39	35.07	0.978	181.07	251.48	36.52	0.619 (16)
ANN - LR	0.980	184.40	252.34	37.30	0.973	186.68	257.16	37.65	0.672 (17)
SVR - CART	0.968	191.63	275.94	38.76	0.956	200.28	291.48	40.39	0.852 (22)
SVR - LR	0.944	205.46	298.76	41.56	0.934	208.90	305.39	42.13	1.000 (23)
CART - LR	0.973	189.28	265.24	38.28	0.962	197.55	280.66	39.84	0.797 (21)
ANN - SVR - CART	0.982	146.92	212.41	29.72	0.974	153.91	225.99	31.04	0.491 (11)
ANN - SVR - LR	0.970	157.73	230.23	31.90	0.964	161.00	236.58	32.47	0.577 (12)
ANN - CART - LR	0.984	144.75	204.53	29.28	0.976	151.80	218.00	30.62	0.458 (10)
SVR - CART - LR	0.966	160.82	239.90	32.53	0.955	169.17	254.74	34.12	0.675 (18)
ANN - SVR - CART - LR	0.977	132.08	197.27	26.72	0.970	139.04	210.46	28.04	0.423 (9)
Mô hình bagging									
ANN	0.991	58.678	89.110	11.87	0.981	76.543	127.35	15.44	0.000 (1)
SVR	0.930	114.17	238.64	23.09	0.925	120.14	246.68	24.23	0.597 (15)
CART	0.982	70.142	123.08	14.19	0.939	140.18	223.36	28.27	0.582 (13)
LR	0.947	132.81	208.14	26.86	0.968	92.121	162.77	18.58	0.171 (5)
Mô hình stacking									
ANN - (ANN, SVR, CART, LR)	0.989	89.07	122.66	18.00	0.968	138.98	187.86	28.03	0.396 (8)
SVR - (ANN, SVR, CART, LR)	0.988	69.12	104.62	13.98	0.978	90.197	137.78	18.19	0.083 (3)
CART - (ANN, SVR, CART, LR)	0.983	75.36	120.63	15.24	0.977	86.835	141.65	17.51	0.081 (2)
LR - (ANN, SVR, CART, LR)	0.989	67.88	98.77	13.73	0.978	94.928	140.01	19.15	0.106 (4)

Bảng 4: Tổng hợp các chỉ số đánh giá hiệu suất và xếp hạng của các mô hình tốt nhất trong từng nhóm mô hình.

Mô hình	Learning				Test				Chỉ số SI (Rank)
	R	MAE (kN)	RMSE (kN)	MAPE (%)	R	MAE (kN)	RMSE (kN)	MAPE (%)	
Mô hình đơn									
ANN	0.989	77.214	104.74	15.61	0.974	105.01	150.02	21.78	0.467 (3)
Mô hình voting									
ANN - SVR - CART - LR	0.977	132.08	197.27	26.72	0.970	139.04	210.46	28.04	1.000 (4)
Mô hình bagging									
ANN	0.991	58.678	89.110	11.87	0.981	76.543	127.35	15.44	0.000 (1)
Mô hình stacking									
CART - (ANN, SVR, CART, LR)	0.983	75.36	120.63	15.24	0.977	86.835	141.65	17.51	0.216 (2)

5.2 So sánh và đánh giá mô hình các mô hình hỗn hợp

Trong lĩnh vực học máy, các mô hình hỗn hợp như Voting, Bagging và Stacking đã được sử dụng để cải thiện độ chính xác và hiệu suất của dự đoán so với các mô hình đơn. Để đánh giá hiệu suất của các mô hình hỗn hợp, chúng ta cần sử dụng các chỉ số hiệu suất trong bảng 3.



Hình 12. Biểu đồ chỉ số hiệu suất MAPE (%) của từng mô hình tốt nhất ở giai đoạn test trong từng nhóm mô hình (theo bảng 4)

Trong các mô hình hỗn hợp Voting, mô hình ANN - SVR - CART - LR cho kết quả tốt nhất với các giá trị hiệu suất là $R = 0.970$, $MAE = 139.04$ kN, $RMSE = 210.46$ kN và $MAPE = 28.04\%$. Mặt khác, mô hình ANN đạt kết quả tốt nhất trong số các mô hình hỗn hợp Bagging với $R = 0.981$, $MAE = 76.54$ kN, $RMSE = 127.35$ kN và $MAPE = 15.44\%$. Trong khi đó, trong mô hình hỗn hợp Stacking, mô hình CART - (ANN, SVR, CART, LR) đạt kết quả tốt nhất với các giá trị R , MAE , $RMSE$ và $MAPE$ lần lượt là 0.977, 86.83 kN, 141.65 kN và 7.51%.

Dựa trên các giá trị đã được liệt kê ở trên và bảng 4, chúng ta có thể kết luận rằng mô hình ANN trong mô hình hỗn hợp Bagging cho kết quả tốt nhất ở hầu hết các chỉ số đánh giá hiệu suất với xếp hạng 1 về chỉ số tổng hợp SI (0.000).

6. KẾT LUẬN

Nghiên cứu này trình bày bốn mô hình đơn ANN, SVR, LR, CART và ba mô hình hỗn hợp Voting, Bagging, Stacking để dự đoán khả năng chịu cắt của vách BTCT với tổng cộng 492 bộ dữ liệu liên quan đến vách BTCT chịu cắt được thu thập từ nghiên cứu của J-S Chou và các cộng sự [13] năm 2022.

Xác thực chéo 10 lần và năm chỉ số hiệu suất được sử dụng để đánh giá hiệu suất của các mô hình đã phát triển và cho thấy rằng mô hình ANN trong mô hình hỗn hợp Bagging đạt được các giá trị MAPE, MAE, RMSE cực kỳ nhỏ cho cả quá trình học (learning) và thử nghiệm (test). Cụ thể, trong giai đoạn học, các giá trị MAPE, MAE và RMSE lần lượt là 11.87%, 58.678 kN và 89.110 kN. Trong giai đoạn thử nghiệm, các giá trị tương ứng lần lượt là 15.44%, 76.543 kN và 127.35 kN.

Mô hình ANN trong mô hình hỗn hợp Bagging đã chứng minh được sự ổn định do các giá trị hiệu suất của nó được đánh giá là tốt nhất (đứng đầu với chỉ số SI = 0.000) so với các mô hình đơn và hỗn hợp, điều này có nghĩa mô hình ANN trong mô hình hỗn hợp Bagging là một mô hình đáng tin cậy trong việc dự đoán khả năng chịu cắt của vách BTCT.

Các nhà nghiên cứu khác có thể sử dụng bộ dữ liệu để phát triển mô hình lai tối ưu hóa bằng các thuật toán khác nhau nhằm cải thiện và nâng cao độ chính xác của mô hình để dự đoán khả năng chịu cắt của vách BTCT.

TÀI LIỆU THAM KHẢO

- [1] AYDIN, A.C. and B. BAYRAK, *Design and Performance Parameters of Shear Walls: A Review* // *Architecture, Civil Engineering, Environment*. 2021. **14**(4): p. 69-94.
- [2] Gallardo, J.A., et al., *Damage and sensitivity analysis of a reinforced concrete wall building during the 2010, Chile earthquake*. *Engineering Structures*, 2021. **240**: p. 112093.
- [3] Chandra, J., K. Chanthabouala, and S. Teng, *Truss Model for Shear Strength of Structural Concrete Walls*. *ACI Structural Journal*, 2018. **115**: p. 323-335.
- [4] Hwang, S.-J., et al., *Analytical Model for Predicting Shear Strength of Squat Walls*. 2001. **127**(1): p. 43-50.
- [5] Chou, J.-S., N.-T. Ngo, and A.-D. Pham, *Shear Strength Prediction in Reinforced Concrete Deep Beams Using Nature-Inspired Metaheuristic Support Vector Regression*. 2016. **30**(1): p. 04015002.
- [6] Kiran, S., B. Lal, and S. Tripathy, *Shear Strength Prediction of Soil based on Probabilistic Neural Network*. *Indian Journal of Science and Technology*, 2016. **9**.
- [7] Halevy, A., P. Norvig, and F. Pereira, *The Unreasonable Effectiveness of Data*. *IEEE Intelligent Systems*, 2009. **24**(2): p. 8-12.
- [8] Jimmy Chandra, K.C. and T. Susanto, *Truss Model for Shear Strength of Structural Concrete Walls*. *ACI Structural Journal*. **115**(2).
- [9] Siam, A., M. Ezeldin, and W. El-Dakhkhni, *Machine learning algorithms for structural performance classifications and predictions: Application to reinforced masonry shear walls*. *Structures*, 2019. **22**: p. 252-265.
- [10] Mangalathu, S., et al., *Data-driven machine-learning-based seismic failure mode identification of reinforced concrete shear walls*. *Engineering Structures*, 2020. **208**: p. 110331.
- [11] Gondia, A., M. Ezeldin, and W. El-Dakhkhni, *Mechanics-Guided Genetic Programming Expression for Shear-Strength Prediction of Squat Reinforced Concrete Walls with Boundary Elements*. 2020. **146**(11): p. 04020223.
- [12] Feng, D.-C., et al., *Interpretable XGBoost-SHAP Machine-Learning Model for Shear Strength Prediction of Squat RC Walls*. 2021. **147**(11): p. 04021173.
- [13] Chou, J.-S., et al., *Predicting nominal shear capacity of reinforced concrete wall in building by metaheuristic-optimized machine learning*. *J. of Building Engineering*, 2022. **61**: p. 105046.
- [14] Committee, A.C.I., 318-19: *Building Code Requirements for Structural Concrete and Commentary*. *Technical Documents*.
- [15] Ning, C.-L. and B. Li, *Probabilistic development of shear strength model for reinforced concrete squat walls*. 2017. **46**(6): p. 877-897.
- [16] Massone, L.M. and F. Melo, *General solution for shear strength estimate of RC elements based on panel response*. *Engineering Structures*, 2018. **172**: p. 239-252.
- [17] Geuurickx, E., et al., *Recombinant extracellular vesicles as biological reference material for method development, data normalization and assessment of (pre-)analytical variables*. *Nature Protocols*, 2021. **16**(2): p. 603-633.
- [18] McCulloch, W.S. and W. Pitts, *A logical calculus of the ideas immanent in nervous activity*. *The bulletin of mathematical biophysics*, 1943. **5**(4): p. 115-133.
- [19] Cortes, C. and V. Vapnik, *Support-vector networks*. *Machine Learning*, 1995. **20**(3): p. 273-297.
- [20] Neter, J., et al., *Applied linear statistical models*. 1996.
- [21] Breiman, L., et al., *Classification and Regression Trees*. 1st Editio. 1984, Routledge
- [22] Kittler, J., et al., *On combining classifiers*. *IEEE Transactions on Pattern Analysis and Machine Intelli*. 1998. **20**(3): p. 226-239.
- [23] Breiman, L., *Bagging predictors*. *Machine learning*, 1996. **24**(2): p. 123-140.
- [24] Kohavi, R. *A study of cross-validation and bootstrap for accuracy estimation and model selection*. in *Ijcai*. 1995. Montreal, Canada.
- [25] 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.
- [26] 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.
- [27] 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.