

# Xây dựng mô hình máy học lai nhân trọng số để dự báo lực bám dính giữa BTCT và FRP

Enhancing the machine learning model with weighted features to predict the adhesion force between reinforced concrete and FRP materials.

> THS LÊ MINH THANH<sup>1</sup>, TS TRƯƠNG ĐÌNH NHẬT<sup>2\*</sup>, THS CAO THÀNH NHÂN<sup>3</sup>, THS LÊ THỊ THÙY LINH<sup>4</sup>

<sup>1</sup>CV Phòng Quản lý đô thị, UBND quận Tân Bình TP.HCM; Email: thanhleminh0512@gmail.com

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

<sup>3</sup>CV Phòng Quản lý dự án, Công ty TNHH Xây dựng và Thương mại C&T; Email: caothanhnhanksxd23@gmail.com

<sup>4</sup>GV Khoa Sư phạm Công nghiệp, Đại học SP Kỹ thuật, Đại học Đà Nẵng; Email: lttlinh@ute.udn.vn

\*Corresponding author

## TÓM TẮT

Bài báo nghiên cứu tập trung vào xây dựng một mô hình học máy có trọng số để dự báo lực bám dính giữa vật liệu bê tông cốt thép và vật liệu FRP gia cường. Mô hình lai JS-WFSS (*Jellyfish search optimized - weighted feature stacking system*) được xây dựng dựa trên hệ thống xếp chồng có trọng số tối ưu hóa bằng tìm kiếm sứa. Kết quả phân tích cho thấy rằng mô hình lai được tối ưu hóa JS-WFSS có độ chính xác dự đoán tốt hơn so với các nghiên cứu trước đây. Bên cạnh việc xây dựng mô hình, bằng cách so sánh đối trọng của các biến trong mô hình dự báo, nghiên cứu này xác định mức độ quan trọng của các biến đầu vào trong xác định khả năng chịu lực bám dính giữa bê tông cốt thép và vật liệu FRP gia cường.

**Từ khóa:** Lực bám dính giữa FRP và bê tông cốt thép; vật liệu FRP; mô hình máy học; tối ưu hóa; trình tối ưu hóa tìm kiếm sứa.

## ABSTRACT


This study is dedicated to developing a learning model for predicting the adhesion force between reinforced concrete and Fiber Reinforced Polymer (FRP) materials. The hybrid model, named Jellyfish Search Optimized Weighted Feature Stacking System (JS-WFSS), is constructed using a weighted stacking system optimized through jellyfish search. The analysis results clearly indicate that the JS-WFSS optimized hybrid model demonstrates a higher level of prediction accuracy compared to previous studies. Beyond model construction, this study assesses the significance of input variables in determining the bearing capacity between concrete materials and reinforced FRP material by scrutinizing the variable counterweights within the predictive model.

**Keywords:** Adhesion between FRP and concrete; FRP materials; machine learning model; optimization; jellyfish search optimizer.

## 1. GIỚI THIỆU

Trong thời gian qua ở Việt Nam và trên thế giới đã có nhiều mô hình dự báo khả năng liên kết giữa các mặt của FRP với bê tông (Hình 1). Năm 2023, Lê và các cộng sự đã công bố nghiên cứu về xây dựng mô hình học máy mới để tạo ra hiệu suất tốt hơn và chính xác hơn để tìm ra mô hình tối ưu để dự đoán khả năng liên kết của vật liệu FRP [1].

Tuy nhiên, các mô hình được sử dụng là các mô hình học máy (ML) đơn lẻ không được đánh giá cao như các mô hình lai hay mô hình hỗn hợp. Có nhiều phương pháp học máy, chẳng hạn như mạng nơ ron hàm cơ sở xuyên tâm (RBFNN) hay phương pháp hồi quy vectơ hỗ trợ bình phương nhỏ nhất (LSSVR), có thể được kết hợp để tạo ra một mô hình tổng thể mới mang lại hiệu suất tốt hơn đáng kể so với các mô hình cạnh tranh. Tính ưu việt của các mô hình ML tổng hợp so với các mô hình ML đơn lẻ đã được chứng minh trong việc giải quyết nhiều vấn đề thực tế trong công trình dân dụng, chẳng hạn như ước tính cường độ nén bê tông [2], ước tính cường độ cắt của đất [3], và các ứng dụng khác nhau trong các lĩnh vực khác.



**Hình 1.** Các thành phần trong thí nghiệm kiểm tra lực bám dính của một tấm FRP [1]. Do đó, việc tạo ra một mô hình tổng hợp sử dụng tập dữ liệu thử nghiệm, các mô hình ML có thể được đào tạo để tạo ra các công cụ tính toán có dung lượng liên kết nhanh hơn, đáng tin cậy hơn và ít tốn kém hơn so với các công cụ liên kết. Hơn nữa, với việc sử dụng

hiều dữ liệu hơn cho quá trình đào tạo, các mô hình ML có thể đạt được mức độ tổng quát hóa cao hơn, hiệu suất tốt hơn nhằm tăng cường độ chính xác để dự đoán khả năng liên kết của vật liệu FRP và bê tông cốt thép là mục tiêu của nghiên cứu này.

## 2. TỔNG QUAN NGHIÊN CỨU

### 2.1 Cấu tạo của FRP

Composite Polyme cốt sợi (FRP) được định nghĩa là một loại polyme được gia cố bằng sợi. Nó đại diện cho một loại vật liệu thuộc danh mục được gọi là vật liệu composite. Vật liệu tổng hợp được tạo ra bằng cách phân tán các hạt của một hoặc nhiều vật liệu trong một vật liệu khác, tạo thành một mạng lưới liên tục xung quanh chúng.

Vật liệu tổng hợp FRP khác với các vật liệu xây dựng truyền thống như Thép và Nhôm. Vật liệu tổng hợp FRP là dị hướng trong khi Thép và Nhôm là đẳng hướng. Do đó, tính chất của chúng là có hướng, nghĩa là các tính chất cơ học tốt nhất là theo hướng đặt sợi.

FRP được cấu tạo từ 2 thành phần chính là sợi và vật liệu liên kết các sợi.

- Sợi: Carbon, Glass và Aramid là ba loại sợi chính được sử dụng trong xây dựng [4]. Hỗn hợp thường được đặt tên theo sợi gia cường, ví dụ, CFRP cho Polyme cốt sợi carbon. Các tính chất quan trọng nhất khác nhau giữa các loại sợi là độ cứng và độ căng kéo.

- Liên kết: Liên kết sẽ truyền lực giữa các sợi và bảo vệ các sợi khỏi các tác động bất lợi. Nhựa nhiệt rắn (thermoset) hầu như được sử dụng. Vinylester và epoxy là những chất liên kết phổ biến nhất [4].

### 2.2 Tính chất của FRP

FRP như một giải pháp thay thế cho cốt thép trong các cấu kiện kết cấu bê tông về 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 [5].

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 qua nền.

Cường độ nén: CFRP (Polyme sợi Carbon) và AFRP (Polyme sợi

**Bảng 1:** Các mô tả thống kê liên quan đến từng biến số trong bộ dữ liệu [1, 11].

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

## 4. LÝ THUYẾT CƠ SỞ

### 4.1 Phương pháp học máy

#### 4.1.1 Mạng thần kinh cơ sở xuyên tâm RBFNN (Radial basis function neural network)

Mạng thần kinh cơ sở xuyên tâm (RBFNN) là một loại mạng thần kinh nhân tạo (neural network) được sử dụng trong các bài toán học máy. RBFNN có khả năng học nhanh, có khả năng xử lý các mô hình phi tuyến tính (nonlinear), tương đối độc lập với các tập dữ liệu lớn và khả năng giải quyết các tác vụ phức tạp trong

Aramid) có cường độ nén cao nhất và thấp nhất hoàn toàn độc lập so với các hợp chất FRP điển hình khác [6]. Tuy nhiên, độ bền sẽ tăng cao nếu các sợi bazan được đặt trên mặt hoặc được cung cấp bằng cách thay thế các lớp thông qua vật liệu tổng hợp tạo thành hình bánh sandwich. Độ bền nén của sợi gốc epoxy lớn hơn sợi gốc polyester, cho thấy độ bền của composite nền polyester dưới dạng ma trận không có hoặc có chất độn thấp hơn so với sợi gốc epoxy. Độ dày lớp FRP tăng cường hiệu quả cường độ chịu nén của các vùng cấu kiện bê tông tăng cường [7].

Sức chống cắt: Cốt thép chịu cắt cho các cấu kiện bê tông cốt thép có thể được tạo ra thông qua liên kết epoxy với các sợi song song hầu như có thể chịu được các ứng suất kéo chính. Phần lớn các thanh cốt thép FRP có độ cứng hoặc mô đun đàn hồi thấp. Độ cứng thấp cho thấy sự cần thiết của các phần tử sâu hoặc gia cố thêm để giảm độ võng dài hạn và giảm bề rộng vết nứt.

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 và kích hoạt sợi trước khi tạo. Để tăng cường độ uốn, các thanh cốt thép và tấm 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.

Sức căng: FRP được ứng dụng làm chất gia cố bên trong và gia cường bên ngoài cho các cấu trúc bê tông cốt thép (BTCT) sử dụng sợi tổng hợp trong ma trận polyme, để cung cấp độ bền kéo lớn theo hướng song song với hướng sợi [8]. Các sợi được sắp xếp thẳng, song song và liên tục thông qua một ma trận [9]. Tuy nhiên, nếu ứng suất xuyên tâm bắt đầu lớn hơn cường độ chịu kéo trong cấu kiện bê tông, các vết nứt sẽ phát triển và liên kết giữa bê tông và cốt thép bị ảnh hưởng nghiêm trọng [10].

## 3. THU THẬP VÀ XỬ LÝ SỐ LIỆU

Dữ liệu được thu thập sử dụng từ hai nghiên cứu trước bao gồm nghiên cứu của Lê và các cộng sự (2023) [1] và nghiên cứu của Wang và các cộng sự năm 2022 [11]. Dữ liệu bao gồm 855 mẫu về khả năng chịu lực của vật liệu bê tông cốt thép và vật liệu FRP gia cường (Hình 1 và Bảng 1).

mô hình hoá dữ liệu.

$$y = \sum_{j=1}^{N_n} w_j \times \varphi_j \times (\|x - v_j\|) + b \quad (1)$$

$$\varphi_j(x) = \exp\left(-\frac{\|x - v_j\|^2}{2 \times \sigma_n^2}\right) \quad (2)$$

Số lượng tế bào thần kinh ẩn ( $N_n$ ) và độ rộng của nút RBF ( $\sigma_n$ )

đều ảnh hưởng đáng kể đến hiệu suất của RBFNN.  $N_n$  và  $\sigma_n$  được tối ưu hóa bằng thuật toán tối ưu hóa hiệu quả (dùng lý thuyết tối ưu hóa JS) để tạo mô hình RBFNN tốt nhất.

**4.1.2 Mô hình hồi quy vector hỗ trợ bình phương nhỏ nhất LSSVR (Least squares support vector regression)**

Mô hình hồi quy vector hỗ trợ bình phương nhỏ nhất (LSSVR) là mô hình tìm kiếm một siêu mặt phẳng tốt nhất phân tách các điểm dữ liệu trong không gian đặc trưng.

Kết quả mô hình LSSVR để ước lượng hàm:

$$f(x) = \sum_{k=1}^n \alpha_k K(x, x_k) + b \tag{3}$$

Trong đó  $\alpha_k$  ( $k = 1, 2, \dots, n$ ) biểu thị các hệ số nhân Lagrange,  $K(x, x_k)$  biểu thị hàm nhân và  $x$  là một vectơ đầu vào để dự đoán [12].

$$K(x_i + x_k) = \exp\left(-\frac{\|x_i - x_k\|^2}{2 \times \gamma^2}\right) \tag{4}$$

trong đó  $\|x - x_k\|^2$  biểu thị khoảng cách Euclide bình phương giữa các vectơ và  $\sigma$  là chiều rộng hạt nhân, là tham số miễn phí.

**4.1.3 Mô hình hỗn hợp stacking (xếp chồng)**

Các mô hình tổ hợp stacking (xếp chồng) là một mô hình hai giai đoạn và mô tả nguyên lý của mô hình tổ hợp stacking [13]. 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, LRR); SVR (ANN, SVR, CART, LRR); CART (ANN, SVR, CART, LRR); LRR (ANN, SVR, CART, LRR).

Nó có thể được mô tả bằng toán học là  $M_c: R^d \rightarrow R$ , và mỗi quy trình sử dụng mô hình đối tượng học cơ sở để tạo ra mô hình ước tính  $M_c(\cdot)$ . Một ước tính bằng cách sử dụng mô hình cơ sở tập hợp  $M_c(\cdot)$  có được bằng mô hình siêu đối tượng học của các mô hình riêng lẻ.

$$\hat{Y} = M_c \left[ \hat{Y}_1(X), \hat{Y}_2(X), \dots, \hat{Y}_{k-1}(X), \hat{Y}_k(X) \right] \tag{5}$$

**4.1.4 Mô hình hỗn hợp stacking gắn đối trọng (xếp chồng)**

Bằng cách gắn đối trọng vào các biến, mô hình này vừa áp dụng để dự báo vừa thông qua đối trọng để biết được mức độ quan trọng của các biến cấu thành mô hình. Nguyên lý của mô hình xếp chồng gắn đối trọng được trình bày dưới đây.

$$\hat{Y} = M_c \left[ \hat{Y}_1(W.X), \hat{Y}_2(W.X), \dots, \hat{Y}_{k-1}(W.X), \hat{Y}_k(W.X) \right]$$

$$X = \begin{bmatrix} w_1 \cdot x_{11} & w_2 \cdot x_{12} & \dots & w_d \cdot x_{1d} \\ w_1 \cdot x_{21} & w_2 \cdot x_{22} & \dots & w_d \cdot x_{2d} \\ \vdots & \vdots & \vdots & \vdots \\ w_1 \cdot x_{n1} & w_2 \cdot x_{n2} & \dots & w_d \cdot x_{nd} \end{bmatrix} \quad \text{và} \quad Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \tag{6}$$

**4.2 Lý thuyết tối ưu hóa tìm kiếm sứa (Jellyfish Search - JS)**

Trình tối ưu hóa tìm kiếm sứa nhân tạo (JS), là một thuật toán tối ưu hóa siêu mô phỏng mới được lấy cảm hứng từ hành vi của sứa biển khi chúng tìm kiếm thức ăn trong đại dương được phát triển bởi J-S Chou và D-N Truong (2021) [14]. Thuật toán này được thiết kế để giải quyết các bài toán tối ưu hóa phức tạp, nơi mà các phương pháp tối ưu hóa truyền thống không thể hoạt động hiệu quả. Tìm kiếm sứa dựa trên ba quy tắc lý tưởng hóa [14]: thăm dò, khai thác và tối ưu hóa.

**4.2.1 Dòng hải lưu - Ocean current**

Hướng của dòng hải lưu (xu hướng – trend) được xác định bằng

cách lấy trung bình tất cả các vectơ từ mỗi con sứa trong đại dương đến những con sứa hiện đang ở vị trí tốt nhất [14].

$$\overline{trend} = X^* - \beta \times rand(0,1) \times \mu \tag{7}$$

$$X_i(t+1) = X_i(t) + rand(0,1) \times \overline{trend} \tag{8}$$

Trong đó  $\overline{trend}$ : Xu hướng hoặc khuynh hướng;  $X^*$ : Là vị trí của con sứa có vị trí tốt nhất trong bầy;  $\mu$ : Là vị trí trung bình của tất cả các con sứa;  $\beta > 0$ : Là hệ số phân phối có liên quan đến độ dài của xu hướng (trend). Từ kết quả phân tích độ nhạy dựa trên các thí nghiệm số thu được  $\beta = 3$  [14]

Bây giờ, vị trí mới của mỗi con sứa được xác định bởi

$$X_i(t+1) = X_i(t) + rand(0,1) \times \overline{trend} = X_i(t) + rand(0,1) \times (X^* - \beta \times rand(0,1) \times \mu) \tag{9}$$

Trong đó:  $X_i(t+1)$ : Là vị trí mới của con sứa;  $X_i(t)$ : Là vị trí của con sứa thứ  $i$  tại thời điểm  $t$ ;  $rand(0,1)$ : Là hằng số ngẫu nhiên tăng từ 0 đến 1.

**4.2.2 Đàn sứa - Jellyfish swarm**

Trong một đàn, sứa thể hiện chuyển động thụ động (loại A) và chủ động (loại B). Ban đầu, khi đàn mới hình thành, hầu hết sứa biểu hiện chuyển động loại A. Theo thời gian, chúng ngày càng thể hiện chuyển động loại B. [14].

$$X_i(t+1) = X_i(t) + \gamma \times rand(0,1) \times (U_b - L_b) \tag{10}$$

Trong đó  $U_b$  và  $L_b$  lần lượt là giới hạn trên và dưới của không gian tìm kiếm;  $\gamma > 0$  là hệ số chuyển động liên quan đến độ dài chuyển động xung quanh vị trí của sứa  $\gamma=0,1$ ; và  $rand(0,1)$  là hằng số ngẫu nhiên tăng từ 0 đến 1.

Công thức (11) và công thức (12) mô phỏng hướng chuyển động và vị trí cập nhật của một con sứa. Sự di chuyển này được coi là một cách khai thác hiệu quả không gian tìm kiếm cục bộ [14].

$$X_i(t+1) = X_i(t) + rand(0,1) \times \overline{direction} \tag{11}$$

$$\overline{direction} = \begin{cases} X_j(t) - X_i(t) \text{ khi } f(X_i) \geq f(X_j) \\ X_i(t) - X_j(t) \text{ khi } f(X_i) < f(X_j) \end{cases} \tag{12}$$

**4.2.3 Cơ chế kiểm soát thời gian**

Cơ chế kiểm soát thời gian được giới thiệu để mô phỏng và kiểm soát chuyển động của sứa giữa việc đi theo dòng hải lưu và di chuyển bên trong bầy sứa.

$$c(t) = \left[ \left( 1 - \frac{t}{Max_{iter}} \right) \times [2 \times rand(0,1) - 1] \right] \tag{13}$$

Trong đó biến  $t$  là thời gian được chỉ định là số lần lặp. Số lần lặp tối đa  $Max_{iter}$  là một tham số được khởi tạo. Tương tự như hàm  $c(t)$ , hàm  $[1 - c(t)]$  được sử dụng để mô phỏng chuyển động bên trong bầy đàn (loại A hoặc B).

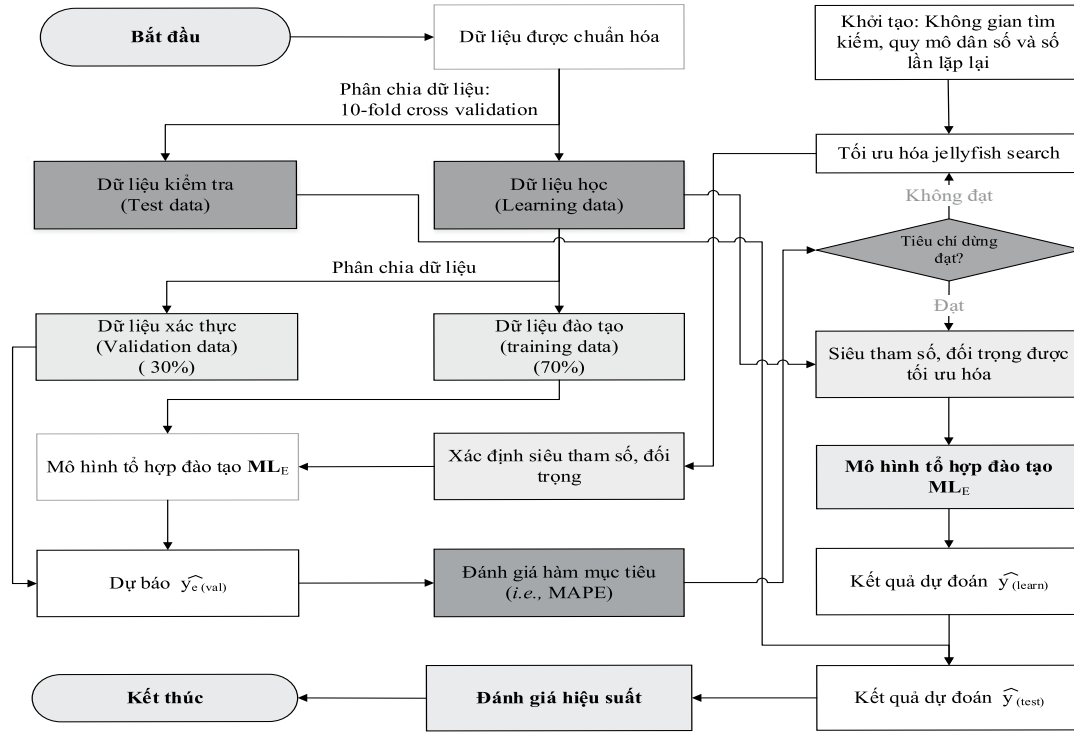
**4.3 Mô hình lai tối ưu hóa WFSS (Jellyfish search optimized - weighted feature stacking system)**

Sơ đồ học máy dựa trên xếp chồng (Stacking) có thể được sử dụng trong nhiều bài toán khác nhau, đem lại kết quả tốt hơn so với việc sử dụng một mô hình đơn lẻ để giải quyết bài toán. Tuy nhiên, việc xây dựng sơ đồ học máy Stacking cũng đòi hỏi sự kết hợp linh hoạt và tinh tế của các mô hình học máy khác nhau để đạt được hiệu quả tối ưu.

Thuật toán Jellyfish là một thuật toán học máy mới được phát triển gần đây, có khả năng xử lý các bộ dữ liệu lớn và phức tạp. Việc tích hợp Jellyfish vào trong mô hình Stacking sẽ giúp đạt được độ chính xác và độ tin cậy cao hơn trong việc dự đoán khả

năng chịu lực bám dính của vật liệu FRP gia cường bê tông. Tuy nhiên, việc điều chỉnh các tham số của các bộ phân loại cơ bản và meta-bằng cách sử dụng một kỹ thuật tối ưu hóa thông số cố định có thể dẫn đến việc khó khăn trong việc cân bằng hiệu suất của chúng, gây ảnh hưởng đến hiệu suất tổng thể của hệ thống Stacking [15]. Vì vậy, nghiên cứu này đề xuất một hệ thống Stacking mới có trọng số, kết hợp với bộ tối ưu hóa JS để điều

chỉnh siêu tham số của mô hình Stacking nhằm cải thiện hiệu suất dự đoán. Các siêu tham số của một hệ thống tập hợp Stacking bao gồm  $C, \gamma$  của mô hình học máy LSSVR;  $N_n, \sigma_n$  của mô hình học máy RBFNN dưới dạng base-learner; trọng số  $W$  là sự ảnh hưởng của các yếu tố đầu vào và  $C_c, \gamma_c$  của mô hình LSSVR dưới dạng meta-learner. Độ chính xác dự đoán của hệ thống được đề xuất phụ thuộc rất nhiều vào các siêu tham số này.



Hình 2. Cấu trúc của mô hình lai JS-WFSS.

Xác định chính xác các giá trị của  $(C, \gamma, N_n, \sigma_n, C_c, \gamma_c, W)$  là một vấn đề của tối ưu hóa được giải quyết hiệu quả và tốt nhất bằng thuật toán JS. Do đó để giải quyết vấn đề này, nghiên cứu này đề xuất hệ thống được tích hợp gọi là Jellyfish search optimized-weighted feature stacking system (JS-WFSS) là hệ thống xếp chồng nhân trọng số được tối ưu hóa bằng thuật toán tìm kiếm sứa. Quá trình xây dựng và đánh giá của mô hình này được thể hiện qua Hình 2.

Đầu vào của hệ thống là các tham số điều khiển của trình tối ưu hóa JS, đây là kích thước của tập dữ liệu và số lần lặp tối đa, các giới hạn dưới và giới hạn trên của siêu tham số của mô hình lai JS-WFSS và dữ liệu mà được sử dụng để xây dựng mô hình dự đoán được trình bày trong Bảng 2.

Hàm mục tiêu của JS-WFSS được đề xuất xác định như sau:

$$f(\text{hyperparameters}, W) = MAPE_{\text{Validation process}}^{\text{Training process}} \quad (14)$$

Bảng 2: Các mô tả thống kê liên quan đến từng biến số trong bộ dữ liệu

Tham số	Miêu tả nội dung	Giới hạn dưới	Giới hạn trên
$N_{pop}$	Quy mô của đàn sứa		50
$Max_{iter}$	Số lần lặp hoặc tiêu chí dừng		20
$C$	Hằng số chuẩn hóa trong base-learner	$10^{-12}$	$10^{14}$
$\gamma$	Tham số RBF trong base-learner	$10^{-2}$	$10^8$
$N_n$	Số lượng tế bào thần kinh ẩn trong base-learner	1	400
$\sigma_n$	Tham số RBFNN trong base-learner	$10^{-2}$	200
$C_c$	Hằng số chuẩn hóa trong meta-learner	$10^2$	$10^{10}$
$\gamma_c$	Tham số RBF trong meta-learner	$10^{-3}$	$10^8$
$W$	Đối trọng	$10^{-4}$	$10^3$

**4.4 Đánh giá mô hình**

**4.4.1 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 [16], xác nhận chéo mười lần được sử dụng ở đây để đánh giá tính nhất quán dự đoán của hệ thống.

**4.4.2 Các chỉ số hiệu suất đánh giá mô hình**

Trong nghiên cứu này, năm chỉ số hiệu suất nổi tiếng được sử dụng để đánh giá khả năng dự đoán của hệ thống được đề xuất [17, 18] sử dụng để đánh giá độ chính xác của dự đoán.

Các chỉ số này bao gồm: hệ số tương quan tuyến tính (R), căn bậc hai của sai số bình phương trung bình (RMSE), sai số trung bình tuyệt đối (MAE) và phần trăm sai số trung bình tuyệt đối (MAPE) [19].

**Bảng 3:** Tổng hợp các chỉ số đánh giá hiệu suất và xếp hạng của tất cả mô hình.

Mô hình	Learning				Test				SI (Rank)
	R	MAE (kN)	RMSE (kN)	MAPE (%)	R	MAE (kN)	RMSE (kN)	MAPE (%)	
<b>Mô hình đơn</b>									
CART [1]	0,953	2,052	3,113	26,284	0,924	2,73	3,98	34,85	0,8202 (3)
<b>Mô hình hỗn hợp</b>									
Voting ANN – CART [1]	0,948	2,641	3,483	33,841	0,917	3,07	4,15	39,22	1,000 (5)
Bagging CART [1]	0,971	1,733	2,531	22,199	0,948	2,25	3,34	28,72	0,445 (2)
stacking SVR - (ANN, SVR, CART, LR) [1]	0,958	2,072	3,028	26,542	0,922	2,75	4,06	35,14	0,851 (4)
<b>Mô hình lai (mô hình đề xuất)</b>									
<b>JS-WFSS</b>	<b>0,971</b>	<b>1,707</b>	<b>0,000</b>	<b>11,0</b>	<b>0,951</b>	<b>2,092</b>	<b>0,264</b>	<b>12,8</b>	<b>0,000 (1)</b>

**Bảng 4:** Bảng so sánh tiêu chí đánh giá hiệu suất RMSE.

Tác giả	RMSE (kN)
Holzenkämpfer, (1994) [11]	7,96
Tanaka, (1996) [11]	13,48
Maeda (1997) [11]	5,28
Neubauer and Rostasy, (1997) [11]	6,17
Khalifa, et al., (1998) [11]	6,94
Niedermeier, (2000) [11]	8,79
Nakaba, et al., (2001) [11]	5,57
Yang, et al., (2001) [11]	6,18
Teng, et al., (2002) [11]	5,61
Monti, et al., (2003) [11]	6,91
Japan Concrete Institute, (2003) [11]	6,34
Lu, (2004) [11]	5,56
Dai, et al., (2005) [11]	9,79
Wu, et al., (2009) [11]	5,46
Wu and Jiang, (2013) [11]	5,06
Zhou, (2020) [11]	6,36
Wei, et al, (2022) [11]	3,99
<b>JS-WFSS (mô hình đề xuất)</b>	<b>0,264</b>

**5.2 Đánh giá về trọng số**

Nghiên cứu này ngoài việc tập trung vào xây dựng mô hình học

**5. KẾT QUẢ VÀ THẢO LUẬN**

**5.1 Kết quả và đánh giá mô hình**

Kết quả đào tạo và kiểm tra của các mô hình được thể hiện trong Bảng 3. Mô hình lai JS-WFSS được xây dựng cho kết quả hiệu suất đánh giá tốt nhất so với mô hình đơn và mô hình hỗn hợp với R (0,951), MAE (2,092 kN), RMSE (0,264 kN) và MAPE (12,8%).

Các kết quả dự đoán của mô hình JS-WFSS đề xuất cũng được so sánh cho kết quả tốt hơn các nghiên cứu trước, như thể hiện trong Bảng 4. Kết quả ở Bảng 4 có giá trị RMSE cải thiện 93% chỉ số RMSE và tốt hơn 18% ở chỉ số MAPE so với nghiên cứu đã công bố trước.

Nghiên cứu này giảm thiểu dự đoán lỗi ít hơn các nghiên cứu trước, cụ thể ở tiêu chí MAPE đối với phương pháp JS-WFSS là 12,8% so với phương pháp nghiên cứu tối ưu khả năng liên kết giữa các bề mặt FRP với bê tông gần nhất là 15,56% của tác giả Wei-Chih Wang và các cộng sự [11]. Các kết quả thống kê cho thấy mô hình JS-WFSS có nhiều ưu điểm nổi trội hơn so với các phương pháp tiếp cận toán học trong dự đoán khả năng liên kết giữa FRP và bê tông.

máy dự báo khả năng chịu lực bám dính của vật liệu FRP gia cường bê tông mà còn xác định mức độ quan trọng của các yếu tố đầu vào.

Các trọng số từ  $W_1$  đến  $W_6$  được áp dụng để tìm ra mối liên hệ và độ ảnh hưởng giữa các yếu tố đầu vào với yếu tố đầu ra là khả năng chịu lực bám dính của vật liệu FRP gia cường bê tông.

Bảng 5 thể hiện kết quả thực tế của các trọng số được tìm thấy trong 10 lần chạy, các kết quả thể hiện thứ hạng của các trọng số khi đã được chuẩn hóa để tìm ra độ ảnh hưởng của các yếu tố đầu vào. Theo kết quả xếp hạng của các trọng số ta có thể thấy năm biến số quan trọng nhất khi xây dựng mô hình dự báo khả năng chịu lực bám dính giữa vật liệu bê tông cốt thép và vật liệu FRP gia cường. Cụ thể: Mô đun đàn hồi của tấm FRP gia cường có ảnh hưởng lớn nhất đến khả năng chịu lực bám dính giữa FRP và bê tông. Xếp thứ 2 là độ dày của tấm FRP gia cường. Chiều rộng mặt bê tông ảnh hưởng đến khả năng bám dính giữa tấm FRP gia cường với bê tông ở vị trí thứ 3. Xếp thứ 4 là chiều rộng của tấm FRP. Cuối cùng là chiều dài tấm FRP.

Kết quả nhằm phục vụ xem xét mức độ quan trọng để tính toán thiết kế, tối ưu hóa và sử dụng hiệu quả vật liệu FRP gia cường dựa trên mức độ quan trọng của từng yếu tố đầu vào.

**6. KẾT LUẬN**

Nghiên cứu này xây dựng một mô hình có thể sử dụng nhiều thuật toán hoặc kỹ thuật khác nhau để tăng phạm vi khái quát cho các mẫu dự đoán trong dữ liệu nhằm nâng cao hiệu suất tính toán. Mô hình JS-WFSS có kết quả đánh giá hiệu suất tốt nhất, giảm thiểu vấn đề nhiễu và thiếu dữ liệu mạnh mẽ hơn so với mô hình đơn hay mô hình hỗn hợp. Bằng cách sử dụng các thuật toán hoặc kỹ thuật khác nhau, nó ít có khả năng bị ảnh hưởng bởi các điểm dữ liệu riêng lẻ có thể gây ra lỗi hoặc sai lệch trong dự đoán.

**Bảng 5:** Kết quả chuẩn hóa của các trọng số đại diện cho các biến đầu vào.

Số lần	W1 $b_c$	W2 $f'_c$	W3 $E_r$	W4 $t_r$	W5 $b_r$	W6 $L_r$
1	1,0000	0,1052	1,0000	0,4820	0,5965	0,1014
2	0,9713	0,1160	0,0000	0,9943	0,9193	0,0746
3	0,1429	0,1079	0,8838	0,9972	0,1688	1,0000
4	0,9962	0,8427	1,0000	1,0000	1,0000	0,8714
5	0,0000	0,0000	0,1193	0,0000	0,9279	0,0000
6	0,7780	0,0354	1,0000	1,0000	1,0000	0,2978
7	0,7628	0,4005	0,9998	0,7226	0,9572	0,9043
8	0,8883	0,7226	0,8828	0,9519	0,7409	0,3519
9	1,0000	0,6896	1,0000	0,5846	1,0000	0,7473
10	0,7797	1,0000	1,0000	0,7448	0,0000	0,5041
<b>Trung bình</b>	0,7319	0,4020	0,7886	0,7478	0,7311	0,4853
<b>Xếp hạng</b>	<b>3</b>	<b>6</b>	<b>1</b>	<b>2</b>	<b>4</b>	<b>5</b>

Ngoài ra, mô hình còn phân tích độ quan trọng của các thuộc tính. Từ sự kết hợp của nhiều mô hình khác nhau, mô hình lai JS-WFSS sẽ giúp chúng ta phân tích độ quan trọng của các thuộc tính và đưa ra những giải pháp xử lý để tăng cường khả năng liên kết của FRP và bê tông.

Nghiên cứu này tập trung 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, kết quả được so sánh với các nghiên cứu đã được công bố trước đây. Tiêu chí MAPE đối với phương pháp JS-WFSS là 12,8% so với phương pháp nghiên cứu tối ưu khả năng liên kết giữa các bề mặt FRP với bê tông gần nhất là 15,56% của tác giả Wei-Chih Wang và các cộng sự [11]; Ở tiêu chí có giá trị RMSE cải thiện 93% chỉ số RMSE và tốt hơn 18% ở chỉ số MAPE so với nghiên cứu đã công bố trước.

Bên cạnh việc xây dựng mô hình, bằng cách so sánh đối trọng của các biến trong mô hình dự báo, nghiên cứu này xác định mức độ quan trọng của các biến đầu vào: (1) mô đun đàn hồi, (2) độ dày tấm, (3) chiều rộng mặt bê tông ảnh hưởng, (4) chiều rộng tấm và (5) chiều dài tấm FRP trong xác định khả năng chịu lực bám dính giữa FRP gia cường bê tông.

Tóm lại, những kết quả thực nghiệm này đã cho thấy Mô hình JS-WFSS có khả năng vượt trội hơn hẳn so với các phương pháp truyền thống và các mô hình học máy đã được nghiên cứu trước đây về dự đoán khả năng chịu lực bám dính giữa vật liệu bê tông cốt thép và vật liệu FRP gia cường.

#### TÀI LIỆU THAM KHẢO

- [1]. Le, M.-T., et al., *Building a machine learning model to predict adhesion force between reinforced concrete and FRP material*. Journal of Construction, 2023. **10**: p. 60-65.
- [2]. Chou, J.-S., et al., *Machine learning in concrete strength simulations: Multi-nation data analytics*. Construction and Building Materials, 2014. **73**: p. 771-780.
- [3]. Chou, J.-S., et al., *Bio-inspired optimization of weighted-feature machine learning for strength property prediction of fiber-reinforced soil*. Expert Systems with Applications, 2021. **180**: p. 115042.
- [4]. Contractor, T. *Fibre Reinforced Polymer (FRP) in Construction, Types and Uses*. 2022; Available from: <https://theconstructor.org/concrete/fibre-reinforced-polymer/1583/>.
- [5]. 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.
- [6]. Sahu, N.P., et al., *Study on aramid fibre and comparison with other composite materials*. Int. J. Innov. Res. Sci. Technol. 1, 2014. **7**: p. 303-306.
- [7]. Zhou, J., et al., *Experimental investigation of size effect on mechanical properties of carbon fiber reinforced polymer (CFRP) confined concrete circular specimens*. Construction and Building Materials, 2016. **127**: p. 643-652.

[8]. 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.

[9]. Cabral-Fonseca, S., *Fiber Reinforced Polymer Composite Material used in Civil Engineering*. Laboratório Nacional de Engenharia Civil (LNEC, IPLisboa, Portugal), 2008: p. TR 6.2.

[10]. Mugahed Amran, Y.H., et al., *Properties and applications of FRP in strengthening RC structures: A review*. Structures, 2018. **16**: p. 208-238.

[11]. 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.

[12]. 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*. Journal of Computing in Civil Engineering, 2016. **30**(6): p. 04016036.

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

[14]. Chou, J.-S. and D.-N. Truong, *A novel metaheuristic optimizer inspired by behavior of jellyfish in ocean*. Applied Mathematics Computation, 2021. **389**: p. 125535.

[15]. Truong, D.-N. and J.-S. Chou, *Fuzzy adaptive jellyfish search-optimized stacking machine learning for engineering planning and design*. Automation in Construction, 2022. **143**: p. 104579.

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

[17]. 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.

[18]. 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.

[19]. 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.