

Dự báo khả năng chịu tải nén lệch tâm của cột thép nhồi bê tông bằng mô hình học máy được tối ưu hóa bằng thuật toán Jellyfish Search

Predicting the eccentric axial load capacity of concrete filled steel tube columns using a machine learning model optimized by Jellyfish Search algorithm

> **KS TRẦN HỮU THẮNG¹, TS TRƯƠNG ĐÌNH NHẬT^{2,*}, PGS.TS NGUYỄN HỮU ANH TUẤN³, THS LÊ THỊ THÙY LINH⁴**

¹ HVCH Ngành Kỹ thuật xây dựng, Trường ĐH Kiến trúc TP.HCM; Email: 22xd11@uah.edu.vn

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

³ GV Khoa Xây dựng, Trường ĐH Kiến trúc TP.HCM; Email: tuan.nguyenhuuanh@uah.edu.vn

⁴ GV Khoa Sư phạm công nghiệp, ĐH Sư phạm Kỹ thuật, Đại học Đà Nẵng; Email: lttlinh@ute.udn.vn

*Corresponding author

TÓM TẮT

Cột thép nhồi bê tông (Concrete-filled steel tube, CFST) ngày càng được ưa chuộng trong các công trình dân dụng và giao thông hiện nay bởi các ưu thế vượt trội của nó so với kết cấu bê tông cốt thép thông thường. Nghiên cứu này tập trung vào xây dựng mô hình dự báo dựa trên thuật toán tối ưu hóa Jellyfish Search (JS) để tự động tìm kiếm các thông số của mô hình học máy nhằm dự báo độ nén lệch tâm của CFST. Một bộ dữ liệu gồm 499 mẫu với 11 biến đầu vào và đầu ra là khả năng chịu nén lệch tâm của cột được sử dụng để xây dựng các mô hình học máy đơn ANN, SVR, CART, LR và mô hình hỗn hợp Voting, Bagging, Stacking. Sau khi xây dựng và so sánh mô hình trên, mô hình có độ chính xác nhất được chọn để kết hợp với thuật toán tối ưu hóa JS nhằm tạo ra mô hình dự báo có hiệu suất cao nhất. Kết quả thu được rất khả quan với $R = 0.9949$, $MAE = 46.8157$ kN, $RMSE = 7.2097$ kN và $MAPE = 7.67\%$, $SI = 0.00$ (Rank=1) chứng tỏ đây là một mô hình đầy hứa hẹn để sử dụng trong thiết kế và phân tích kết cấu CFST.

Từ khóa: Cột ống thép nhồi bê tông; tải trọng lệch tâm; mô hình học máy; tối ưu hóa.

ABSTRACT

Concrete-filled steel tubes (CFST) are becoming increasingly popular in civil and transportation projects due to their significant advantages over traditional reinforced concrete structures. This study aims to develop a predictive model using the Jellyfish Search (JS) optimization algorithm to automatically optimize machine learning parameters for predicting the eccentric compressive strength of CFST. A dataset of 499 samples, comprising 11 input variables and the target variable of eccentric compressive capacity, was used to develop individual machine learning models (ANN, SVR, CART, LR) and ensemble models (Voting, Bagging, Stacking). After building and comparing these models, the most accurate one was selected for combination with the JS optimization algorithm to achieve the highest-performing predictive model. The results are highly promising, with $R = 0.9949$, $MAE = 46.8157$ kN, $RMSE = 7.2097$ kN, $MAPE = 7.67\%$, and $SI = 0.00$ (Rank = 1), indicating that this model holds great potential for CFST design and structural analysis.

Keywords: Concrete filled steel columns; eccentric axial load; machine learning model; optimization algorithm.

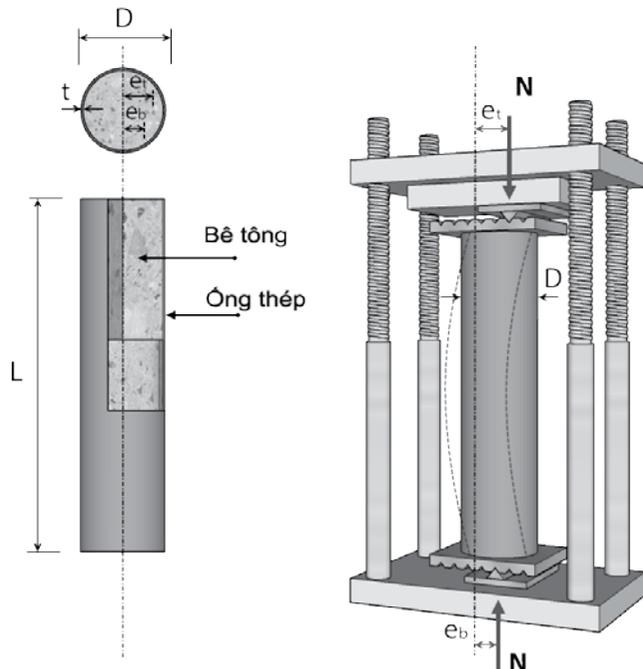
1. GIỚI THIỆU:

Cột ống thép nhồi bê tông (CFST) là một loại kết cấu cột kết hợp giữa ống thép bên ngoài và lõi bê tông nhồi bên trong (Hình 1). Ưu điểm vượt trội của loại kết cấu này so với kết cấu thép và bê tông cốt thép là sự kết hợp giữa ống thép và lõi bê tông. Ống thép cung cấp khả năng giới hạn lõi, khiến bê tông hoạt động ở trạng thái ứng suất ba trục, làm tăng cường độ và độ dẻo. Mặt khác, lõi bê tông giúp giảm đáng kể hiện tượng cong vênh cục bộ sớm của ống thép [1].

Ngoài ra, cột CFST có khả năng chịu động đất và chịu tải lớn, kích thước sử dụng nhỏ hơn dẫn đến tính thẩm mỹ tốt và khả năng chống cháy cao [2]. Quá trình thi công kết cấu này không tốn kém cốp pha, ống thép được sản xuất trong nhà máy dẫn đến đẩy nhanh tiến độ thi công so với kết cấu bê tông cốt thép truyền thống.

Những ưu điểm này thúc đẩy sự phát triển nhanh chóng của cột CFST trong các công trình xây dựng hiện đại. Chính vì vậy, việc dự đoán chính xác sức chịu tải lệch tâm của chúng đang là mối quan tâm hàng đầu của doanh nghiệp cũng như các kỹ sư kết cấu. Đã có

nhiều nghiên cứu về sự làm việc của cột CFST dưới tải trọng đúng tâm, tuy nhiên điều này chưa phù hợp với sự làm việc chịu tải trọng lệch tâm trong thực tế vì nén và uốn kết hợp sẽ dẫn đến cơ chế phá hủy phức tạp hơn ở độ bền cực đại [1].



Hình 1. Mô tả các thành phần của cột thép nhồi bê tông CFST chịu nén lệch tâm (Trong đó: D : đường kính tiết diện cột; t : độ dày của ống thép; L : chiều dài của cột thép; e_t, e_b : lần lượt là độ lệch tâm phía trên và độ lệch tâm phía dưới của mẫu thử và N : khả năng nén lệch tâm của cột CFST)

Để giải quyết vấn đề này, nghiên cứu này sẽ đề xuất một mô hình dự báo khả năng chịu lực nén lệch tâm của cột CFST bằng phương pháp học máy, một ưu điểm vượt trội của mô hình này là nó có thể tự tìm kiếm và tối ưu hóa các siêu tham số nhằm đem lại kết quả dự báo tối ưu nhất.

2. TỔNG QUAN VỀ NGHIÊN CỨU

Ống thép nhồi bê tông (CFST) là cấu kiện composite được sử dụng rộng rãi trong xây dựng nhà cao tầng, cầu, tháp, giàn và các loại kết cấu khác. Cột CFST thường có tiết diện hình tròn, hình vuông và hình chữ nhật, trong khi tiết diện hình elip và hình đa giác có thể được áp dụng để đáp ứng các yêu cầu về mặt thẩm mỹ kiến trúc hoặc công năng. Có nhiều dạng cột CFST [3] thông dụng hiện nay như cột ống thép nhồi bê tông (CFST), cột CFST gia cố bằng dải thép hàn FRP hoặc vòng thép, cột ống thép 2 lớp nhồi bê tông đặc (CFDST), cột ống thép 2 lớp nhồi bê tông lõi rỗng (CFDST), cột CFST gia cố bằng đinh tán hoặc kết cấu thép bên trong, cột ống thép nhồi bê tông CFST gia cố bằng các thanh cốt thép bên trong.

Phương pháp thực nghiệm và phương pháp phần tử hữu hạn là hai phương pháp chính để dự đoán tác động của các thành phần CFST [4]. Mặc dù các thí nghiệm cung cấp dữ liệu và quan sát rất giá trị, nhưng rất tốn công và vật liệu của các thí nghiệm. Phương pháp phần tử hữu hạn có thể giảm số lượng thử nghiệm ở một mức độ nào đó bằng mô phỏng máy tính, nhưng kết quả phân tích phần tử hữu hạn phụ thuộc phần lớn vào trình độ kỹ năng của người lập mô hình do các tính chất vật liệu phức tạp, mối quan hệ tiếp xúc, điều kiện biên, v.v. Hơn nữa, các phương pháp phần tử hữu hạn thường yêu cầu cấu hình máy tính cao [5].

Với sự quan tâm ngày càng tăng và thử nghiệm trong phòng thí nghiệm, một số quốc gia đã thiết lập các tiêu chuẩn thiết kế dựa trên phương trình dựa trên các kết quả thử nghiệm mở rộng, chẳng hạn như ACI 318 (ACI 2014), Eurocode 4 (CEN 2004), AISC 360 (AISC 2016) và các tiêu chuẩn của Trung Quốc (GB 50936-2014 và GB/T 51446-2021) [6].

Mặc dù nhiều tiêu chuẩn thiết kế hiện có có thể ước tính cường độ, các quy định khác nhau ở các quốc gia có thể có kết quả khác nhau theo các mô hình quy định khác nhau. Hơn nữa, cường độ vật liệu, hình dạng, chiều dài mặt cắt ngang và độ mảnh của các cột thực tế có thể vượt quá khả năng áp dụng của các tiêu chuẩn này. Bên cạnh đó, các công thức thực nghiệm thường là các phương trình rõ ràng với mối quan hệ phi tuyến với hạn chế giữa đầu vào và đầu ra. Ngược lại, các mô hình học máy có thể nắm bắt mối quan hệ ảnh xạ chính xác và phức tạp hơn giữa đầu vào và đầu ra ở dạng hàm ẩn [6].

Đã có nhiều nghiên cứu sử dụng phương pháp phân tích số để dự đoán khả năng chịu nén lệch tâm của cột CFST nhằm đơn giản hoá quá trình tính toán, tuy nhiên phạm vi áp dụng của các phương pháp còn khá hạn chế do các quy tắc khác nhau [6]. Với sự phát triển vượt bậc của lĩnh vực trí thông minh nhân tạo, việc ứng dụng các phương pháp học máy để dự báo trong lĩnh vực xây dựng đang trở thành một xu thế tất yếu. Phương pháp học máy được xem là công cụ ưu việt nhất hiện nay để giải quyết các bài toán khó trong kết cấu [7]. Tuy nhiên, mối quan hệ phi tuyến phức tạp này luôn là thách thức với các nhà khoa học để tìm ra các mô hình dự báo phù hợp.

Khan. S và cộng sự năm 2021 đã áp dụng trí tuệ nhân tạo để dự đoán khả năng chịu lực trục cực hạn của các cột CFST chịu tải lệch tâm [8]. Nghiên cứu này cho thấy kỹ thuật đáng tin cậy và chính xác nhất để phát triển các mô hình dự đoán là GEP. Các mô hình dự đoán được phát triển thông qua kỹ thuật GEP được đánh giá là đơn giản hơn các mô hình ANN và ANFIS. Năm 2022 Ngoc-Tri Ngo và cộng sự đã nghiên cứu dự đoán khả năng chịu lực dọc trục của cột bê tông nhồi ống thép bằng mô hình học máy lai [9]. Gần đây nhất vào năm 2023, Jing Wang và cộng sự đã nghiên cứu ứng dụng mô hình tổng hợp trong dự đoán khả năng chịu nén đúng tâm và nén lệch tâm của các cột RCFST [2].

Mặc dù đã có nhiều nghiên cứu liên quan đến cột CFST, bằng các phương pháp học máy khác nhau, tuy nhiên độ chính xác của mô hình cần được tiếp tục nghiên cứu để nâng cao. Một trong những vấn đề khó khi xây dựng mô hình học máy là việc lựa chọn mô hình và thiết lập các thông số của mô hình. Do đó, nghiên cứu này đã tiến hành khảo sát các mô hình học máy phổ biến khác nhau để tìm ra mô hình có độ chính xác cao nhất. Thuật toán tối ưu hoá có khả năng tự động điều chỉnh siêu tham số được tích hợp vào mô hình được chọn để tăng hiệu quả dự báo của mô hình. Kết quả cuối cùng sẽ được so sánh với các nghiên cứu đã công bố là minh chứng rõ ràng nhất cho hiệu suất vượt trội của mô hình đề xuất.

3. THU THẬP VÀ XỬ LÝ DỮ LIỆU

Nghiên cứu này sử dụng bộ dữ liệu trong nghiên cứu của Thai, Huu-Tai và cộng sự [10]. Bộ dữ liệu bao gồm 499 mẫu cột CFST chịu nén lệch tâm, được thu thập từ các nghiên cứu đã công bố. Sau khi phân tích và chọn lọc nhằm loại bỏ các mẫu thiếu thông tin (X8- Modul đàn hồi của bê tông), bộ dữ liệu nghiên cứu sẽ bao gồm 467 mẫu và 10 biến đầu vào liên quan đến thành phần cấu tạo và sự làm việc của cột CFST và đầu ra chính là khả năng chịu nén của cột CFST, chi tiết được trình bày ở Bảng 1.

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	Giá trị	Giá trị	Độ
					nhỏ nhất	lớn nhất	trung bình	lệch chuẩn
1	Đường kính tiết diện cột	X ₁	D	mm	76.00	600.00	132.000	56.046
2	Độ dày của ống thép	X ₂	t	mm	.86	16.00	4.500	2.030
3	Chiều dài của cột thép	X ₃	L	mm	284.50	4956.00	1700.000	1001.478
4	Giới hạn chảy của thép	X ₄	f _y	Mpa	185.70	517.00	306.100	58.518
5	Độ bền kéo của thép	X ₅	f _u	Mpa	307.600	638.00	450.831	39.955
6	Modul đàn hồi của thép	X ₆	E _a	Gpa	167.00	236.00	200.008	6.112
7	Cường độ chịu nén của bê tông	X ₇	f _c	Mpa	18.40	184.00	42.200	27.738
8	Modul đàn hồi của bê tông	X ₈	E _c	Mpa	-	-	-	-
9	Hệ số hiệu chỉnh mẫu	X ₉	f _c	type	.96	1.00	1.000	.005
10	Độ lệch tâm phía trên của mẫu thử	X ₁₀	e _t	mm	4.00	300.00	26.030	33.174
11	Độ lệch tâm phía dưới của mẫu thử	X ₁₁	e _b	mm	-100.00	300.00	24.000	35.397
12	Khả năng nén lệch tâm của cột CFST	Y	N _{text}	kN	66.72	5288.00	475.200	821.868

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

Mô hình	Test				Chỉ số SI (Rank)
	R	MAE (kN)	RMSE (kN)	MAPE (%)	
Mô hình đơn - single model					
ANN	0.9954	152.8505	168.3559	28.9048	0.455 (19)
SVR	0.9227	253.3598	504.8572	47.9116	1.000 (24)
CART	0.9513	96.0277	253.1672	18.1593	0.366 (18)
LR	0.9627	150.3755	222.1232	28.4367	0.495 (23)
Mô hình Voting					
ANN - SVR	0.9875	107.9016	151.2963	20.4047	0.317 (12)
ANN - CART	0.9849	101.4297	161.7483	19.1809	0.307 (11)
ANN - LR	0.9877	116.3702	149.3333	22.0062	0.340 (14)
SVR - CART	0.9724	98.2468	204.7492	18.579	0.332 (13)
SVR - LR	0.9611	141.083	231.4664	26.6795	0.476 (20)
CART - LR	0.9722	105.29	193.7617	19.9109	0.344 (16)
ANN - SVR - CART	0.9863	91.0645	151.1125	17.2207	0.270 (7)
ANN - SVR - LR	0.9814	112.5521	167.1458	21.2842	0.343 (15)
ANN - CART - LR	0.9856	96.3446	149.9074	18.2192	0.284 (8)
SVR - CART - LR	0.9727	111.5585	197.9868	21.0963	0.365 (17)
ANN - SVR - CART - LR	0.9834	98.6682	158.5351	18.6586	0.297 (9)
Mô hình Bagging					
ANN	0.9839	78.4327	149.1865	14.832	0.233 (6)
SVR	0.957	137.8208	247.3618	26.0626	0.479 (21)
CART	0.9626	149.9318	222.6163	28.3528	0.494 (22)
LR	0.9786	94.4544	177.7301	17.8618	0.300 (10)
Mô hình stacking					
ANN	0.9932	63.5258	101.463	12.0131	0.154 (3)
SVR	0.993	60.6092	100.752	11.4615	0.145 (2)
CART	0.9934	66.1394	100.0015	12.5073	0.161 (4)
LR	0.9904	71.9423	115.073	13.6047	0.189 (5)
Mô hình lai					
JS-Stacking-LSSVR	0.9949	46.8157	7.2097	7.67	0.000 (1)

(Trong đó: ANN: Artificial Neural Network; SVR: Support Vector Regression; LR: Linear Regression; CART: Classification and Regression Tree)

4. CƠ SỞ LÝ THUYẾT

4.1 Mô hình đơn - (Single model)

4.1.1 Mô hình mạng thần kinh nhân tạo

Mô hình mạng thần kinh nhân tạo (Artificial Neural Network, ANN) lấy từ cảm hứng hoạt động của bộ não con người. Cấu trúc đơn giản nhất của mạng này bao gồm tín hiệu đầu vào, nút ẩn, và đầu ra. Mô hình mạng nơ-ron có thể được biểu diễn dưới dạng toán học như sau:

$$h_{\theta}(x) = \frac{1}{1 + e^{-\theta x T}} \quad (1)$$

Trong đó $h_{\theta}(x)$ là đầu ra, x là đầu vào nhưng x và θ là các vectơ tham số.

4.1.2 Mô hình véc-tơ hỗ trợ hồi quy SVR

Mô hình véc-tơ hỗ trợ hồi quy (Support Vector Regression, SVR) là một mở rộng của thuật toán Support Vector Machine (SVM) để giải quyết các bài toán hồi quy [11]. Mô hình SVR được mô hình đơn giản như sau:

$$f(x) = \phi(x) \times W + b \quad (2)$$

Trong đó: $f(x)$ là hàm hồi quy; $\phi(x)$ là hàm ánh xạ dữ liệu đầu vào lên không gian đa chiều; w là vectơ trọng số; b là hệ số thiên lệch.

Least square support vector machine (LSSSVR) là một phiên bản phát triển của SVR làm tăng khả năng hình toán và hiệu suất mô hình.

4.1.3 Mô hình hồi quy tuyến tính LR

Mô hình hồi quy tuyến tính (Linear Regression, LR) là một trong những phương pháp cơ bản và phổ biến nhất trong thống kê và học máy để mô hình hóa mối quan hệ giữa một biến phụ thuộc (biến kết quả) và một hoặc nhiều biến độc lập (biến giải thích). Hồi quy tuyến tính là dạng cơ bản nhất của hồi quy tuyến tính, khi chỉ có một biến độc lập X và một biến phụ thuộc Y . Mô hình có dạng:

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (3)$$

Trong đó Y là biến phụ thuộc (giá trị cần dự đoán), X là biến độc lập (giá trị đầu vào), β_0 là hệ số chặn (intercept), hay giá trị của Y khi $X=0$, β_1 là hệ số góc, biểu thị mức độ thay đổi của Y khi X thay đổi một đơn vị, ε là sai số (error term).

Bắt đầu

1. Giai đoạn khởi tạo

(1) Phân chia dữ liệu thành k tập hợp con làm dữ liệu học tập (dữ liệu đào tạo (training data) và dữ liệu xác thực (validation data)) và dữ liệu kiểm tra (test data)

(2) Khởi tạo số lượng dân số, số lần lặp tối đa ($Max_Iteration$) và khoản tìm kiếm của các tham số được tối ưu hóa.

2. Thực hiện K lần, đối với mỗi lần các bước sau được thực hiện như sau

while ($t < Max_Iteration$) **do**

2.1 Tính toán thuật toán JS

(1) Tính toán hàm thời gian

(2) Sửa theo dòng đại dương

(3) Sửa di chuyển bên trong đàn sứa

end while

2.2 Xây dựng hàm xác thực Stacking- LSSVR

(1) Thiết lập siêu tham số: $C_c, \sigma_c, C_{LSSVR}, \sigma_{LSSVR}, N_{ann}, \sigma_{ann}$

(2) Mô hình đào tạo với siêu tham số ($C_c, \sigma_c, C_{LSSVR}, \sigma_{LSSVR}, N_{ann}, \sigma_{ann}$) cho mô hình Stacking-LSSVR

(3) Đánh giá mô hình đã được đào tạo (tối ưu hóa) bằng cách sử dụng dữ liệu xác thực

(4) Xác định giá trị của $f(C_c, \sigma_c, C_{LSSVR}, \sigma_{LSSVR}, N_{ann}, \sigma_{ann})$ bằng phương trình (9) và tiếp tục với bước 2.1

2.3 Kiểm tra tiêu chí dừng?

(1) Nếu đáp ứng đủ tiêu chí dừng thì chuyển sang bước 3

(2) Nếu không, quay lại bước 2.1

3. Mô hình Stacking-LSSVR được tối ưu hóa

(1) Kết hợp các thông số được tối ưu hóa ($C_c, \sigma_c, C_{LSSVR}, \sigma_{LSSVR}, N_{ann}, \sigma_{ann}$) vào mô hình sử dụng dữ liệu học tập

(2) Tính độ chính xác trung bình của k lần thử nghiệm

(3) Lưu k mô hình tối ưu hóa

4. Giai đoạn vẽ sơ đồ kết quả

(1) Đánh giá kết quả sau tính toán

(2) Xem kết quả và xác nhận giải pháp tốt nhất

Kết thúc

Hình 2. Pseudo-code mô hình lai JS-Stacking-LSSVR

Bảng 3: Chỉ số đánh giá hiệu suất và xếp hạng của các mô hình đã công bố trước đây .

TT	Mô hình	Test				Chỉ số
		R	MAE (kN)	RMSE (kN)	MAPE (%)	
1	SVR [6]	0.991	88.884	149.849	16.691	0.422 (4)
2	RF [6]	0.989	74.254	135.276	16.760	0.447 (5)
3	XGBoost [6]	0.994	70.725	101.035	13.805	0.241 (3)
4	EC4 [12]	0.987	272.18	188.28	10.07	0.475 (6)
5	AISC [12]	0.983	507.41	359.56	17.71	1.000 (7)
6	SVR-GWO [12]	0.992	209.14	143.47	7.00	0.227 (2)
7	JS-Stacking-LSSVR	0.9949	46.8157	7.2097	7.67	0.000 (1)

(Trong đó: RF: random forest; XGBoost: Extreme Gradient Boosting model; EC4: Eurocode 4; AISC: American Institute of Steel Construction; SVR-GWO: Support vector regression-grey wolf optimization; JS-Stacking-LSSVR: Jellyfish Search-Stacking- least squares SVR)

4.1.4 Mô hình cây phân loại hồi quy tuyến tính

CART được xây dựng từ các cây nhị phân, cụ thể là mỗi nút bên trong có chính xác hai cành đi ra. CART sử dụng các tiêu chí như Gini index (cho bài toán phân loại) hoặc mean squared error (MSE) (cho bài toán hồi quy) để chọn thuộc tính và giá trị ngưỡng để phân chia dữ liệu.

4.2 Mô hình hỗn hợp

Từ các mô hình cơ bản bên trên (ANN, SVR, LR và CART), mô hình hỗn hợp kết hợp các dự đoán của nhiều mô hình cơ bản (base models) bằng cách sử dụng một mô hình meta (meta-model) để đưa ra dự đoán cuối cùng. Mô hình này có nhiều thuộc tính của các mô hình đơn khác nhau, nên độ chính xác được nâng cao hơn so với các mô hình cơ bản. Các mô hình hỗn hợp phổ biến hiện nay bao gồm: Voting, bagging và stacking.

4.3 Thuật toán tối ưu hóa Jellyfish Search

Jui-Sheng Chou và Dinh-Nhat Truong đã phát triển lý thuyết cảm hứng mới từ sứa biển (Jellyfish Search, JS). Nghiên cứu này phát triển một siêu thuật toán mới dựa trên hành vi của sứa trong đại dương và được gọi là trình tối ưu hóa tìm kiếm sứa (JS). Việc mô phỏng hành vi tìm kiếm của sứa bao gồm việc chúng đi theo dòng hải lưu, chuyển động của chúng bên trong đàn sứa (chuyển động chủ động và chuyển động thụ động), cơ chế kiểm soát thời gian để chuyển đổi giữa các chuyển động này và sự hội tụ của chúng hay còn gọi là hiện tượng sứa nở hoa [13].

4.4 Đánh giá mô hình

4.4.1 Các chỉ số đánh giá

Năm chỉ số đánh giá hiệu suất phổ biến được sử dụng để đánh giá độ chính xác của mô hình học máy trong nghiên cứu này bao gồm: hệ số tương quan (R), sai số bình phương trung bình (RMSE), sai số tuyệt đối trung bình (MAE) và sai số phần trăm tương đối trung bình (MAPE). Chỉ số tổng hợp (SI) để định lượng độ chính xác dự đoán tổng thể của hệ thống được đề xuất. SI nằm trong khoảng từ 0 đến 1, SI gần bằng 0 biểu thị một mô hình chính xác [14].

$$R = \frac{n \sum y \cdot y' - (\sum y)(\sum y')}{\sqrt{n(\sum y^2)(\sum y')^2} \sqrt{n(\sum y'^2)(\sum y)^2}} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y' - y)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - y'| \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y - y'}{y} \right| \quad (7)$$

$$SI = \frac{1}{m} \sum_{i=1}^m \left(\frac{P_i - P_{\min,i}}{P_{\max,i} - P_{\min,i}} \right) \quad (8)$$

4.4.2 Xác thực chéo K lần

Phương pháp xác thực chéo K lần được sử dụng để so sánh hai hoặc nhiều mô hình dự báo. Phương pháp này chia ngẫu nhiên mẫu dữ liệu thành K tập con, trong đó K-1 tập con được sử dụng để huấn luyện mô hình (dữ liệu học tập) và tập con còn lại được dùng để kiểm tra. Quá trình huấn luyện này được lặp lại K lần. Để so sánh các mô hình, giá trị trung bình của các kết quả đánh giá hiệu suất được tính toán. Kohavi (1997) chỉ ra rằng K = 10 đảm bảo tính hợp lệ phân tích, hiệu quả tính toán và độ lệch tối ưu [15]. Do đó, K = 10 được sử dụng trong nghiên cứu này.

5. MÔ HÌNH HỌC MÁY ĐƯỢC TỐI ƯU HÓA

Đầu tiên, các mô hình đơn và hỗn hợp được xây dựng, so sánh và chọn ra có độ chính xác cao nhất (Stacking-SVR) (Bảng 2). Một phiên bản cao hơn của SVR là LSSVR được sử dụng nhằm cải thiện hiệu suất mô hình hỗn hợp (Stacking-LSSVR). LSSVR có tốc độ tính nhanh hơn và số lượng thông số đầu vào ít hơn mô hình SVR. Mô hình Stacking-LSSVR lại tiếp tục được tích hợp với thuật toán tối ưu hoá Jellyfish Search để tạo ra mô hình dự báo có hiệu suất tốt nhất gọi là JS-Stacking-LSSVR.

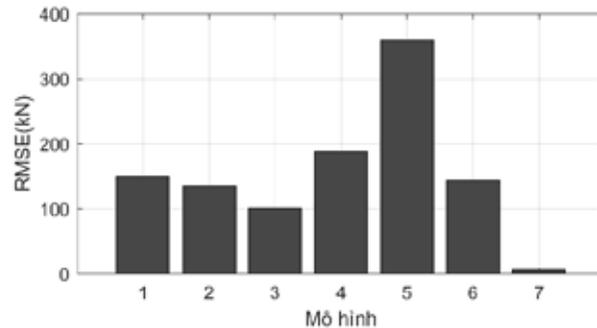
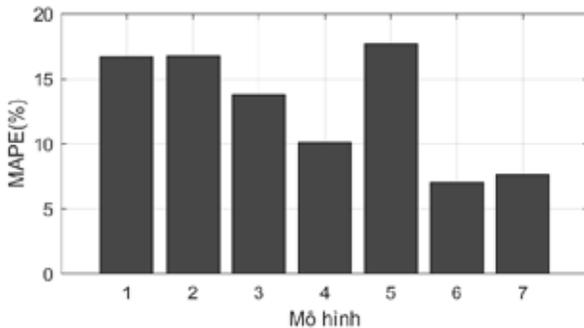
Pseudo-code mô hình lai JS-Stacking-LSSVR được trình bày tại Hình 2. Ban đầu dữ liệu được phân thành tập dữ liệu học tập (learning data) và tập dữ liệu kiểm tra (test data) bằng kỹ thuật xác thực chéo K- lần (K=10). Tiếp theo dữ liệu học được phân chia thành tập đào tạo (training data) và tập xác thực (validation data) với tỷ lệ lần lượt là 70% và 30%. Thuật toán tối ưu hoá JS sẽ tìm kiếm các thông số của mô hình Stacking-LSSVR với tập dữ liệu đào tạo và mục tiêu là sai số của tập xác thực là nhỏ nhất.

$$f(\text{hyperparameters}) = MAPE_{data}^{validation} \quad (9)$$

Trong đó các siêu tham số hyperparameters = $[C_c, \sigma_c, C_{lssvr}, \sigma_{lssvr}, N_{ann}, \sigma_{ann}]$. Với C_c, σ_c : Hằng số hàm phạt, bề rộng hàm nhân của của mô hình kết hợp, $C_{lssvr}, \sigma_{lssvr}$: Hằng số hàm phạt, bề rộng hàm nhân của của mô hình thứ nhất (mô hình LSSVR), N_{ann}, σ_{ann} : Số lượng nút mạng, bề rộng hàm nhân của mô hình thứ hai (Mô hình ANN). Trong đó dân số là 50, số vòng lặp là 2, vùng tìm kiếm của C_c từ 10^{-2} đến 10^{12} , σ_c từ 10^{-2} đến 10^8 , C_{lssvr} từ 10^{-2}

đến 10^{12} , σ_{LSSVR} từ 10^{-2} đến 10^8 , N_{ann} từ 1 đến 500, và σ_{ann} từ 10^{-2} đến 10^5 .

Kết quả so sánh như trong Bảng 2 cho thấy mô hình JS-Stacking-LSSVR có độ chính xác cao nhất so với tất cả các mô hình còn lại với giá trị $SI=0.00$ (Rank=1, với $MAPE=7.67\%$). Để đánh giá lại một lần nữa hiệu suất của mô hình đề xuất, JS-



(a) MAPE giữa các mô hình

(b) RMSE giữa các mô hình

Hình 3. So sánh độ chính xác dự báo giữa JS-Stacking-LSSVR và các mô hình đã công bố

6. KẾT LUẬN

Nghiên cứu này khảo sát các mô hình học máy khác nhau, bao gồm các mô hình đơn (ANN, SVR, CART, LR) và các mô hình hỗn hợp (Voting, Bagging, Stacking) nhằm lựa chọn mô hình tốt nhất và tích hợp nó với thuật toán tối ưu có khả năng tự điều chỉnh siêu tham số JS nhằm tìm ra mô hình hiệu quả nhất để dự báo khả năng chịu lực nén lệch tâm của cột CFST.

Mô hình đề xuất JS-Stacking-LSSVR đã cho ra hiệu suất rất cao với $SI=0.00(1)$. Mô hình JS-Stacking-LSSVR cũng đã chứng minh được hiệu suất vượt trội khi được so sánh với các nghiên cứu trước đây. Do đó, mô hình JS-Stacking-LSSVR được đề xuất thực sự là một công cụ hiệu quả để ứng dụng trong việc thiết kế và phục vụ các nghiên cứu liên quan đến cột ống thép nhồi bê tông CFST chịu tải dọc trục và tải lệch tâm.

Hướng nghiên cứu tiếp theo sẽ xây dựng giao diện để tiện giúp cho người sử dụng dễ dàng. Ngoài ra các mô hình học máy cũng như phương pháp tối ưu hóa khác cũng sẽ được khảo sát để tìm ra mô hình có độ chính xác hơn mô hình hiện tại. Cuối cùng độ nhạy của các biến sẽ được phân tích để tìm ra tổ hợp có độ chính xác nhất cũng như tổ hợp đơn giản nhất cho việc nhập dữ liệu.

TÀI LIỆU THAM KHẢO

1. Wang, C. and T.-M. Chan, *Machine learning (ML) based models for predicting the ultimate strength of rectangular concrete-filled steel tube (CFST) columns under eccentric loading*. Engineering Structures, 2023. **276**: p. 115392.
2. Wu, F., et al., *Predicting compressive strength of RCFST columns under different loading scenarios using machine learning optimization*. Sci Rep, 2023. **13**(1): p. 16571.
3. Kumari, B., *Concrete filled steel tubular (CFST) columns in composite structures*. IOSR Journal of Electrical and Electronics Engineering (IOSR-JEEE), 2018. **13**(1): p. 11-18.
4. Nguyen, T.-T., et al., *Behaviour and design of high strength CFST columns with slender sections*. Journal of Constructional Steel Research, 2021. **182**: p. 106645.
5. Wang, Z.-B., et al., *Strength, stiffness and ductility of concrete-filled steel columns under axial compression*. Engineering Structures, 2017. **135**: p. 209-221.
6. Wang, J., R. Lu, and M. Cheng, *Application of ensemble model in capacity prediction of the CCFST columns under axial and eccentric loading*. Sci Rep, 2023. **13**(1): p. 9488.
7. Cakiroglu, C., et al., *Explainable machine learning models for predicting the axial compression capacity of concrete filled steel tubular columns*. Construction and Building Materials, 2022. **356**: p. 129227.

Stacking-LSSVR sẽ được so sánh với các nghiên cứu đã công bố trước đây (Bảng 3 và hình 3). Kết quả vượt trội cho thấy rằng mô hình JS-Stacking-LSSVR đáp ứng được kì vọng và nhu cầu của các nhà thiết kế để dự báo khả năng chịu lực nén lệch tâm của cột CFST.

8. Khan, S., et al., *Predicting the Ultimate Axial Capacity of Uniaxially Loaded CFST Columns Using Multiphysics Artificial Intelligence*. Materials (Basel), 2021. **15**(1).
9. Ngo, N., H. Le, and Q. Nguyen, *Axial strength prediction of steel tube confined concrete columns using a hybrid machine learning model*. Structures, 2022, Elsevier.
10. Thái, H.-T.T., Sơn; Ngô, Tuấn; Uy, Brian; Kang, Won Hee; Hicks, Stephen J., *Concrete Steel Pipe (CFST) Database with 3,208 Tests*. Mendeley Data, 2020.
11. Cortes, C. and V. Vapnik, *Support-vector networks*. Machine Learning, 1995. **20**(3): p. 273-297.
12. Ngo, N.-T., et al., *Axial strength prediction of steel tube confined concrete columns using a hybrid machine learning model*. Structures, 2022. **36**: p. 765-780.
13. Chou, J.-S. and D.-N. Truong, *A novel metaheuristic optimizer inspired by behavior of jellyfish in ocean*. Applied Mathematics and Computation, 2021. **389**: p. 125535.
14. 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.
15. Kohavi, R. and G.H. John, *Wrappers for feature subset selection*. Artificial intelligence, 1997. **97**(1-2): p. 273-324.