

## Application of Tree-Based Machine Learning Methods in Predicting the Shear Capacity of Steel Reinforced Concrete Beams without Stirrups

Thuy Anh Nguyen, Hai Bang Ly\*

*University of Transport Technology, 54 Trieu Khuc, Thanh Xuan, Hanoi 100000, Vietnam*

### Article info

#### Type of article:

Original research paper

#### Corresponding author:

E-mail address:

banglh@utt.edu.vn

**Published:** 27 September 2021

**Abstract:** This study proposes two tree-based machine learning models, namely Ensemble Learning (ELB) and Random Forest (RF), to predict the shear resistance of reinforced concrete beams without reinforcement. A database of 1849 beam test results collected from the available literature is used for the training and validation phases of the proposed tree models. The database uses twelve input parameters, representing the beam's geometry, loading conditions, and material properties. The evaluation of the models is performed using the cross-validation technique and well-known statistical criteria, namely the coefficient of determination ( $R^2$ ), root mean square error (RMSE), and mean absolute error (MAE). The results show that both models can perform well in predicting the shear resistance of reinforced concrete beams without reinforcement, with  $R^2 = 0.917$ , RMSE = 43.32, MAE = 20.82 using ELB model, and  $R^2 = 0.913$ , RMSE = 46.4, MAE = 22.43 for RF model. These excellent results demonstrate that the proposed tree-based machine learning models are accurate and useful predictors for engineers in the pre-design phase.

**Keywords:** *Machine learning, Ensemble learning, Random Forest, Shear Resistance, Reinforced concrete beam without stirrups*

## Ứng dụng các mô hình học máy dựa trên thuật toán cây để giải bài toán dự báo sức kháng cắt của dầm BTCT không cốt đai

Nguyễn Thùy Anh, Lý Hải Bằng\*

Trường Đại học Công nghệ Giao thông vận tải, 54 Triều Khúc Thanh Xuân,  
Hà Nội 100000

### Thông tin bài viết

### Dạng bài viết:

Bài báo nghiên cứu

### Tác giả liên hệ:

Địa chỉ E-mail:  
banglh@utt.edu.vn

Ngày đăng bài: 27/9/2021

**Tóm tắt:** Mô hình Ensemble Learning (ELB) và mô hình rừng ngẫu nhiên (RF) để dự đoán sức kháng cắt của dầm bê tông cốt thép không có cốt đai được đề xuất trong nghiên cứu này. Bộ cơ sở dữ liệu gồm 1849 kết quả thí nghiệm dầm thu thập được từ các tài liệu có sẵn đã được sử dụng cho quá trình huấn luyện và kiểm chứng các mô hình học máy đề xuất, với 12 thông số đầu vào, miêu tả các đặc tính hình học, vật liệu của dầm, các điều kiện gia tải. Việc đánh giá các mô hình được tiến hành và so sánh bằng cách sử dụng các phép đo thống kê nổi tiếng, cụ thể là hệ số xác định ( $R^2$ ), căn của sai số toàn phương trung bình (RMSE) và sai số tuyệt đối trung bình (MAE). Kết quả của nghiên cứu cho thấy cả hai mô hình học máy có khả năng thực hiện tốt việc dự đoán sức kháng cắt của dầm BTCT không có cốt đai, với  $R^2 = 0.917$ , RMSE = 43.32, MAE = 20.82 tương ứng với mô hình ELB và  $R^2 = 0.913$ , RMSE = 46.4, MAE = 22.43 tương ứng với mô hình RF. Điều này thể hiện cả hai mô hình học máy được đề xuất là một công cụ dự đoán chính xác và hữu ích cho các kỹ sư trong giai đoạn tiền thiết kế.

**Từ khóa:** Học máy, Ensemble learning, Rừng ngẫu nhiên, Sức kháng cắt, Dầm BTCT không cốt đai

### 1. Giới thiệu

Ứng xử cắt của dầm bê tông cốt thép (BTCT) với vết nứt hình thành trên tiết diện nghiêng là một hiện tượng phức tạp. Điều này là do ứng xử cắt của dầm BTCT chịu ảnh hưởng của nhiều tham số như kích thước dầm, chiều dài nhịp cắt, cường độ nén của bê tông, tỷ lệ phần trăm cốt thép và cường độ chảy của thép [1,2]. Sự phụ thuộc lẫn nhau của các tham số này rất phức tạp để có thể được mô hình hóa và tính toán. Ngoài ra, lực cắt tác động kết hợp với các loại tải trọng khác như tải trọng uốn, tải trọng dọc trục và đôi

khi là lực xoắn, khiến bài toán trở nên thêm phức tạp trong thực tế [3]. Do đó, dự đoán khả năng chịu cắt chính xác là điều quan trọng vì sự hư hỏng do hiện tượng cắt thường xảy ra đột ngột mà không có sự cảnh báo trước. Phương pháp thiết kế truyền thống để xác định khả năng chịu cắt của dầm là thiết kế các mẫu dầm trong phòng thí nghiệm để xác định sức kháng cắt đảm bảo yêu cầu. Tuy nhiên, với một số lượng lớn các nhân tố ảnh hưởng, cần phải chuẩn bị một số lượng mẫu lớn, điều này gây tốn kém thời gian và tiền bạc [4]. Đối với dầm BTCT không có cốt đai, nhiều phương pháp thiết kế đã được đề xuất để

giải quyết vấn đề này, chẳng hạn như mô hình do Zhang và cộng sự [5], Sigrist và cộng sự [6], Xu và cộng sự [7], Park và Kuchma [8], Bentz và cộng sự [9], Vecchio và Collins [10]. Một số mô hình này đã được ứng dụng cho các tiêu chuẩn thiết kế hiện tại, chẳng hạn như ACI 318-14 [11], Eurocode 2 [12] và CSA A23.3-14 [13]. Tuy nhiên, hầu hết các mô hình này đều dựa trên các phương pháp tiếp cận thực nghiệm hoặc bán thực nghiệm, được phát triển chủ yếu bằng cách điều chỉnh cho phù hợp với dữ liệu thực nghiệm, và do đó, trong một số trường hợp nhất định, chúng có thể dẫn đến việc đánh giá không chính xác về khả năng chịu cắt của dầm.


Trong những năm gần đây, với sự phát triển nhanh chóng của kỹ thuật trí tuệ nhân tạo, các thuật toán học máy đã được phổ biến trong mọi lĩnh vực của cuộc sống do hiệu quả mà chúng đem lại đối với nhiều vấn đề có độ phức tạp cao [14–16]. Một số thuật toán máy học khá phổ biến có thể kể đến như: mạng nơ ron nhân tạo (ANN), rừng ngẫu nhiên (RF), máy vec tơ hỗ trợ (SVM). Trong số các thuật toán học máy, mô hình mạng nơ ron nhân tạo đã được nhiều nhà khoa học ứng dụng để dự đoán sức kháng cắt của dầm bê tông cốt thép. Trong nghiên cứu của Oreta [17], mô hình ANN được xây dựng dựa trên bộ dữ liệu gồm 155 mẫu với 5 thông số đầu vào để dự đoán sức kháng cắt của dầm mảnh không có cốt đai, cũng như mô phỏng ảnh hưởng của kích thước đến khả năng chịu cắt. Mansour và cộng sự [18] đã sử dụng ANN để dự đoán khả năng chịu cắt của dầm BTCT có cốt thép đai với bộ dữ liệu gồm

176 mẫu và 9 thông số đầu vào. Kết quả cho thấy mô hình ANN là một công cụ khả thi để dự đoán sức chống cắt cuối cùng của dầm BTCT có cốt thép đai trong phạm vi tham số đầu vào được xem xét. Bên cạnh đó, mô hình ANN cũng được phát triển trong các nghiên cứu của Amani và Moeini [19], Cladera và Mari [20], Abdalla và cộng sự [21]. Tuy nhiên, một hạn chế của mô hình ANN là cần phải xác định cấu trúc tối ưu và tham số của của mô hình thông qua quá trình “thử và sai”. Điều này có thể làm mất nhiều thời gian cho quá trình xây dựng mô hình. Đồng thời, bộ dữ liệu sử dụng cho các nghiên cứu kể trên vẫn còn hạn chế, mới đang dừng lại ở một số loại dầm với các điều kiện cụ thể, và khoảng biến thiên của các thông số ảnh hưởng không quá lớn.

Trong nghiên cứu này, một bộ dữ liệu lớn gồm 1849 kết quả thí nghiệm dầm BTCT không có cốt thép đai được tiến hành trong hơn 60 năm qua đã được thu thập để xây dựng các mô hình học máy. Đồng thời, mô hình rừng ngẫu nhiên và mô hình Ensemble Learning, hai trong số các mô hình học máy phổ biến được phát triển để dự đoán sức kháng cắt của dầm. Nội dung của bài báo được chia thành các phần như sau: Phần hai là nội dung cơ bản của bộ dữ liệu, sau đó trình bày vắn tắt mô hình dự báo và các thông tin liên quan; phần 4 trình bày kết quả tính toán và thảo luận; và cuối cùng là kết luận.

## 2. Cơ sở dữ liệu

Bộ dữ liệu về dầm BTCT không có cốt thép đai được tổng hợp từ các tài liệu quốc tế có uy tín và



Hình 1. Minh họa sơ đồ thí nghiệm dầm và các mặt cắt được xét tới trong cơ sở dữ liệu

được tổng hợp trong tài liệu [22]. Bộ dữ liệu này bao gồm 1849 kết quả thí nghiệm được thực hiện từ các nghiên cứu trong hơn 60 năm qua. Các tiêu chí để thu thập dữ liệu của mẫu dầm được xét như sau: (1) mặt cắt ngang hình chữ nhật hoặc chữ T và không giới hạn kích thước dầm; (2) dầm bê tông cốt thép không có cốt đai; (3) được tiến hành thí nghiệm cắt dưới tác dụng của tải trọng tập trung đặt tại 1 hoặc 2 điểm đối xứng trên dầm. Sơ đồ thí nghiệm dầm được minh họa trên hình 1.

Bộ cơ sở dữ liệu gồm 12 thông số khác nhau ảnh hưởng đến sức kháng cắt của dầm BTCT không có cốt đai (được ký hiệu là O), cụ thể là chiều rộng sườn dầm ( $l_1$ ), chiều rộng cánh dầm ( $l_2$ ), chiều cao mặt cắt ( $l_3$ ), chiều cao hữu hiệu ( $l_4$ ), khoảng cách từ điểm đặt tải trọng đến vị trí đặt mô men uốn lớn nhất ( $l_5$ ), chiều dài nhịp cắt ( $l_6$ ), tỷ lệ giữa chiều dài nhịp cắt và chiều cao hữu hiệu ( $l_7$ ), chiều dài của tấm chịu lực ở mặt chịu uốn ( $l_8$ ), tỷ lệ cốt thép dọc ( $l_9$ ), cường độ nén của bê tông ( $l_{10}$ ), kích thước cốt liệu tối đa ( $l_{11}$ ) và cuối cùng là

cường độ chảy của thép ( $l_{12}$ ). Bảng 1 trình bày chi tiết ký hiệu, vai trò và phân tích thống kê (giá trị tối thiểu, tối đa, trung bình, trung vị, độ lệch và độ lệch chuẩn) của các tham số đầu vào cũng như tham số đầu ra.

Dữ liệu trong nghiên cứu này được chia thành hai tập hợp con, trong đó 70% dữ liệu được sử dụng để phát triển các mô hình học máy, và được gọi là bộ dữ liệu huấn luyện, 30 % còn lại được sử dụng để kiểm tra và đánh giá mức độ chính xác của mô hình đã phát triển, được gọi là bộ dữ liệu kiểm chứng. Quá trình phân chia được lựa chọn một cách ngẫu nhiên, đảm bảo cho các mẫu được chọn có khả năng đại diện cho toàn bộ dữ liệu. Lưu ý rằng, 555 mẫu thí nghiệm trong bộ dữ liệu kiểm chứng không tham gia vào phát triển các mô hình học máy để đảm bảo tính khách quan khi tiến hành dự báo. Nói cách khác, 555 mẫu thí nghiệm trong bộ dữ liệu kiểm tra được xem như một bộ dữ liệu mới mà các mô hình học máy chưa từng gặp trong quá trình học và phát

**Bảng 1.** Thống kê dữ liệu được sử dụng trong nghiên cứu này

#	Min	Trung vị	Trung bình	Max	StD <sup>1</sup>	Sk <sup>2</sup>
$l_1$	21	153	213.01	3000	212.94	5.13
$l_2$	21	157	256.76	3000	230.22	3.79
$l_3$	51	305	364.35	3140	254.05	3.53
$l_4$	41	270	320.25	3000	237.77	3.67
$l_5$	80	711	953.22	9000	823.70	3.33
$l_6$	80	800	1000.97	9000	845.97	3.17
$l_7$	0.25	3	3.20	15.06	1.82	1.95
$l_8$	0	102	107.13	600	74.15	0.59
$l_9$	0.10	1.87	2.24	9.50	1.52	1.88
$l_{10}$	6.10	29.70	34.86	127.50	18.34	2.03
$l_{11}$	1	19	18.48	50	6.96	0.14
$l_{12}$	267	420	462.37	1779	172.14	4.39
O	1.90	73.40	129.59	1575	153.21	2.95

<sup>1</sup>Độ lệch chuẩn; <sup>2</sup>Độ lệch

triển. Cũng theo một số nghiên cứu, tỷ lệ 70/30 cho quá trình phân chia dữ liệu là tỷ lệ hợp lý để đảm bảo mức độ tin cậy và đại diện của dữ liệu cho các mô hình học máy trong quá trình huấn luyện cũng như quá trình kiểm chứng [23].

### 3. Các mô hình máy học

#### 3.1. Mô hình Ensemble Learning, sử dụng thuật toán Bagging (ELB)

Lĩnh vực máy học ngày càng trở nên phổ biến theo thời gian, trong đó các mô hình dự đoán là cốt lõi của học máy. Độ chính xác tốt hơn nghĩa là mô hình được xây dựng có khả năng dự báo tốt, sẽ càng được sử dụng nhiều và trở thành giải pháp cho một vấn đề cụ thể. Nhưng trong thực tế, thì không phải mô hình nào cũng đạt hiệu suất cao và có kết quả tốt. Một trong những phương pháp để cải thiện hiệu suất của mô hình học máy là sử dụng việc kết hợp các mô hình lại với nhau, phương pháp này gọi là phương pháp tập hợp mô hình (Ensemble Learning) [24]. Ensemble là một giải pháp kết hợp một tập hợp đa dạng các mô hình riêng lẻ với nhau để tăng tính ổn định và khả năng dự đoán của mô hình. Các kỹ thuật phổ biến sử dụng trong các mô hình Ensemble learning có thể được kể đến như kỹ thuật Bagging (đóng bao), kỹ thuật Boosting (tăng cường) và kỹ thuật Stacking (xếp chồng). Trong nghiên cứu này, kỹ thuật Bagging được lựa chọn để dự đoán sức kháng cắt của dầm bê tông cốt thép không có cốt đai. Nguyên lý cơ bản của kỹ thuật Bagging là xây dựng một lượng lớn các mô hình (thường là cùng loại) trên những tập con khác nhau từ tập dữ liệu huấn luyện. Những mô hình này sẽ được huấn luyện độc lập và song song với nhau nhưng đầu ra của chúng sẽ được tính trung bình cộng để cho ra kết quả cuối cùng. Chính vì vậy, kỹ thuật Bagging giúp Ensemble Learning giảm sai số đáng kể.

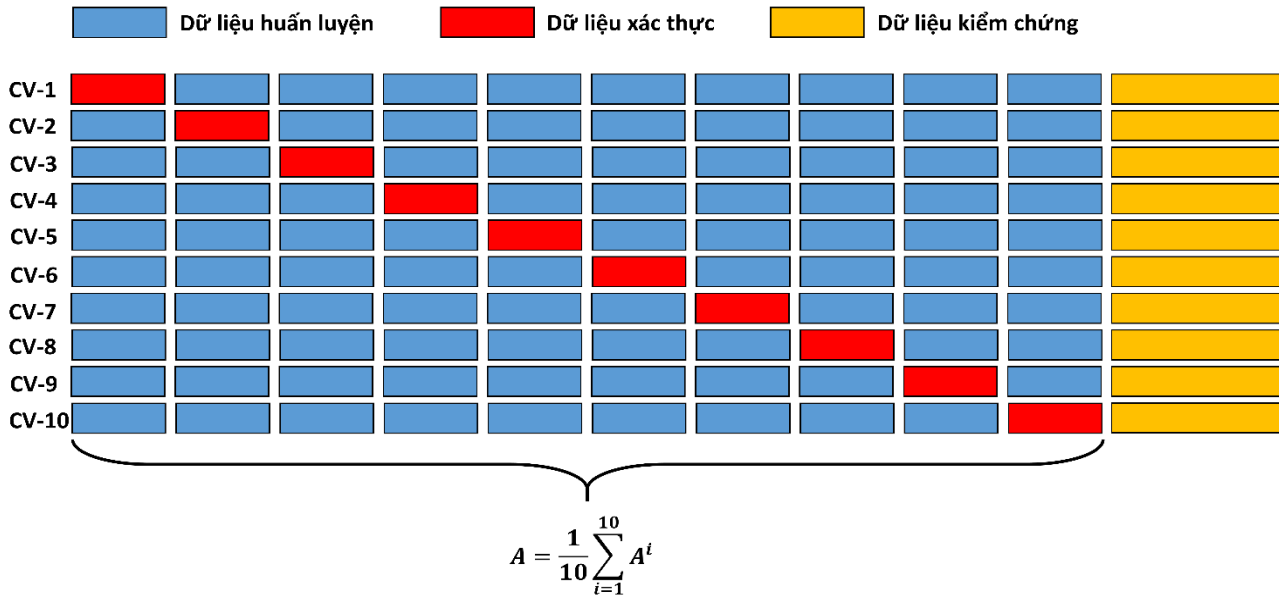
#### 3.2. Mô hình rừng ngẫu nhiên

Thuật toán rừng ngẫu nhiên (Random Forest – RF) do Breiman [25] đề xuất là một thuật toán học máy với nhiều cây quyết định. Nó là sự kết hợp của phương pháp Bagging [26] và Random

Subspaces [27]. Phương pháp này đã chứng tỏ sự thành công của nó trong cả các bài toán hồi quy và phân loại trong những năm gần đây và là một trong những thuật toán học máy tốt nhất được sử dụng trong nhiều lĩnh vực khác nhau [28–30]. Trong kỹ thuật bagging, các cây được trồng bằng cách chọn điểm chia tốt nhất tại mỗi nút cho tất cả các biến dự báo. Thuật toán RF chỉnh sửa phương pháp chia tách bằng cách lựa chọn điểm chia tốt nhất từ một tập hợp con ngẫu nhiên được lựa chọn của các biến dự báo [31]. Việc lựa chọn các biến dự báo ngẫu nhiên sẽ tạo ra sự đa dạng hơn giữa các cây và làm giảm mối tương quan giữa chúng. Tuy nhiên, do sử dụng các lựa chọn ngẫu nhiên nên RF mang lại kết quả có thể hơi khác nhau tại mỗi lần tính toán. Việc kết hợp biến đầu ra từ các cây có khả năng làm giảm sự sai khác kết quả giữa các cây, đồng thời tạo ra mô hình tổng quát hơn. Ước tính cuối cùng RF là giá trị trung bình của tất cả các kết quả từ mỗi cây đối với bài toán hồi quy. Thuật toán RF mạnh hơn các thuật toán học máy khác do khả năng nhận dữ liệu huấn luyện một cách ngẫu nhiên từ các tập con và hình thành cây với thuật toán ngẫu nhiên.

#### 3.3. Xác thực chéo (Cross Validation)

Trong lĩnh vực máy học, xác thực chéo là một phương pháp phổ biến để hạn chế hiện tượng quá khớp “overfitting” trong huấn luyện mạng. Thông thường, một bộ dữ liệu được chia thành 3 tập: tập dữ liệu huấn luyện (training set), tập dữ liệu xác thực (validation set) và tập dữ liệu kiểm chứng (testing set), trong đó training set dùng để huấn luyện mô hình, validation set dùng để xác thực trong quá trình huấn luyện và testing set dùng để kiểm tra cho mô hình cuối cùng. Với trường hợp tập dữ liệu chia thành hai phần là tập dữ liệu huấn luyện và tập dữ liệu kiểm chứng, xác thực chéo là một giải pháp để tránh hiện tượng quá khớp “overfitting”. Khi đó, tập dữ liệu kiểm chứng sẽ được để riêng và dành cho bước đánh giá cuối cùng nhằm kiểm tra “phản ứng” của mô hình khi gặp các dữ liệu hoàn toàn không được biết. Tập dữ liệu huấn luyện thì sẽ được chia ngẫu nhiên thành K phần bằng nhau. Sau đó đào tạo



**Hình 2.** Minh họa kỹ thuật xác nhận chéo 10 lần

mô hình K lần, mỗi lần đào tạo sẽ chọn 1 phần làm dữ liệu xác thực và K-1 phần còn lại làm dữ liệu huấn luyện. Kết quả đánh giá mô hình cuối cùng sẽ là trung bình cộng kết quả đánh giá của K lần huấn luyện. Trong nghiên cứu này, xác thực chéo với K = 10 được chọn, vì nếu K quá lớn, tập huấn luyện sẽ lớn hơn nhiều so với tập kiểm tra, và kết quả đánh giá sẽ không phản ánh đúng bản chất của phương pháp máy học, đặc biệt là với các tập dữ liệu lớn. Đó cũng là lý do đánh giá chéo 10-fold được nhiều học giả quốc tế lựa chọn [32]. Kỹ thuật xác thực chéo 10 lần trong nghiên cứu này được minh họa trong hình 2.

**3.4. Đánh giá năng lực dự báo**

Để đánh giá hiệu suất và độ chính xác của các mô hình học máy trong việc dự đoán sức kháng cắt của dầm BTCT không có cốt đai, các chỉ số hiệu suất được sử dụng trong nghiên cứu này bao gồm hệ số xác định ( $R^2$ ), căn của sai số toàn phương trung bình (RMSE) và sai số tuyệt đối trung bình (MAE). Các chỉ số hiệu suất này được xác định theo công thức sau:

$$R^2 = 1 - \frac{\sum_{k=1}^N (p_k - q_k)^2}{\sum_{k=1}^N (p_k)^2} \tag{1}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (p_k - q_k)^2} \tag{2}$$

$$MAE = \frac{1}{N} \sum_{k=1}^N |p_k - q_k| \tag{3}$$


trong đó p là giá trị thí nghiệm thực tế, q là giá trị dự đoán, tính theo dự báo của mô hình, N là số lượng mẫu trong cơ sở dữ liệu.

Trong số các chỉ số hiệu suất dự báo mô hình được sử dụng, RMSE và MAE đạt giá trị tối ưu khi bằng 0 và  $R^2$  đạt giá trị tối ưu khi bằng 1, nghĩa là mô hình có khả năng dự báo tốt khi các chỉ số trên đạt được những giá trị đó. Đây là 3 chỉ tiêu phổ biến thường được sử dụng để đánh giá năng lực dự báo của mô hình.

**4. Kết quả và thảo luận**

**4.1. Đánh giá tương quan biến đầu vào từ bộ dữ liệu ban đầu**

Trong các bài toán dự báo nói chung, việc tinh giản miền không gian biến đầu vào là một bước quan trọng để các mô hình có khả năng dự báo chính xác hơn, mô phỏng được nhanh hơn và sử dụng ít bộ nhớ hơn. Mỗi tương quan giữa các thông số đầu vào, và giữa các thông số đầu vào



**Hình 3.** Mối tương quan giá trị của các biến đầu vào trong bộ dữ liệu: (a) bộ dữ liệu gốc – Dataset.01; (b) bộ dữ liệu sau khi đã giảm các biến đầu vào – Dataset02

với thông số đầu ra là một trong những cơ sở quan trọng để lựa chọn số lượng tham số đầu vào cho mô hình dự báo. Do đó, một ma trận tương quan giữa các thông số đã được phân tích và được minh họa trên hình 3, với mục đích giảm số lượng biến đầu vào của bộ dữ liệu thu thập được. Trong đó, các giá trị dương biểu thị mối tương quan tích cực, các giá trị âm biểu thị mối tương quan tiêu cực. Đồng thời mức độ đậm nhạt của màu sắc cũng thể hiện giá trị tương quan giữa chúng. Các cặp thuộc tính có mức độ tương quan cao có thể được loại bỏ để giảm mức độ ảnh hưởng của các biến không cần thiết đến mô hình dự báo [33]. Theo đó, các cặp thuộc tính có mối tương quan lớn hơn 0.75 hoặc nhỏ hơn -0.75 được coi là các cặp thuộc tính có mối tương quan cao và cần xem xét một cách kỹ lưỡng.

Hình 3a thể hiện mối tương quan giá trị của các thông số cho bộ dữ liệu ban đầu (được đặt tên là Dataset.01) với 12 thông số đầu vào. Phân tích ban đầu cho thấy một số cặp thông số đầu vào có mối tương quan rất cao, cụ thể là tương quan giữa  $I_1$  và  $I_2$  ( $\approx 0.9$ ),  $I_3$  và  $I_4$  ( $\approx 1$ ),  $I_5$  và  $I_6$  ( $\approx 1$ ). Ngoài ra, các tham số đầu vào  $I_5$  và  $I_6$  còn có mối tương quan tương đối lớn với  $I_3$ ,  $I_4$  và  $I_7$ . Chính vì vậy, để tối ưu hóa không gian các tham số đầu vào của bài toán, giảm thời gian tính toán và dung lượng bộ nhớ, nhóm tác giả lựa chọn phương án bỏ các biến  $I_2$ ,  $I_3$ ,  $I_5$ , và  $I_6$  khỏi miền không gian biến đầu vào. Hình 3b thể hiện mối tương quan

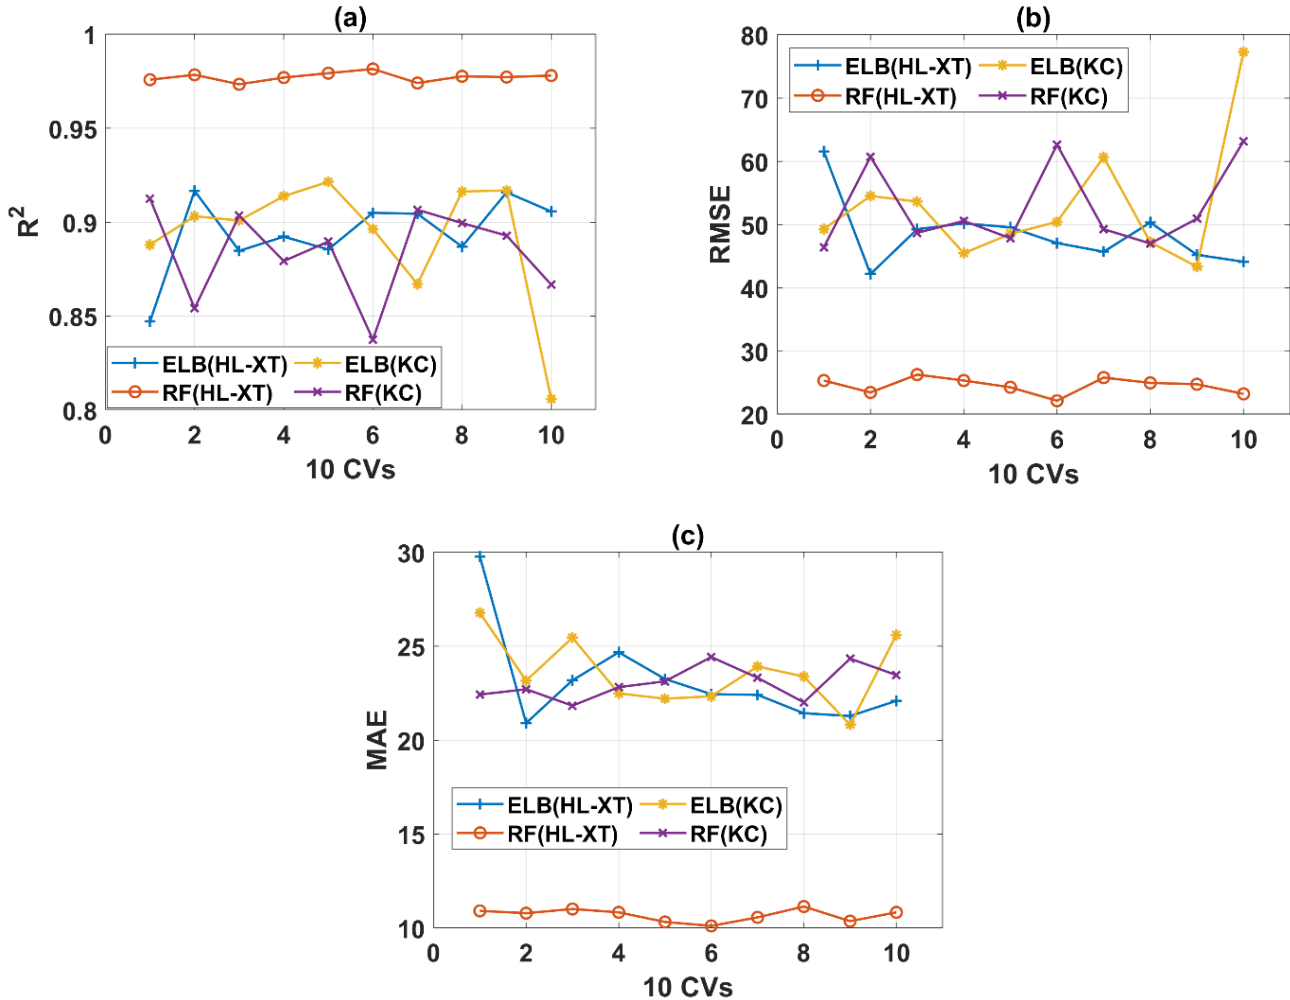
giữa các thông số còn lại sau khi đã loại bỏ các thông số nói trên, tạo thành bộ dữ liệu Dataset.02. Qua phân tích mối tương quan của bộ dữ liệu rút gọn, các thông số được giữ lại có mối tương quan vừa và nhỏ. Điều này cho thấy tám thông số đầu vào của bộ dữ liệu này được coi là các biến độc lập. Trong khi đó, sức kháng cắt của dầm BTCT không có cốt đai được dự báo dựa trên tám thông số đầu vào này được gọi là biến phụ thuộc. Với bộ dữ liệu này, sức kháng cắt của dầm có tương quan tương đối với các biến  $I_1$  (chiều rộng sườn dầm) và  $I_4$  (chiều cao hữu hiệu). Bộ dữ liệu Dataset.02 sẽ được sử dụng trong nghiên cứu này nhằm dự báo sức kháng cắt của dầm BTCT không có cốt đai

**4.2. Xây dựng mô hình ELB và RF cho bài toán**

Trong phần này, quá trình xây dựng hai công cụ mô phỏng số ELB và RF được thực hiện. Quá trình xây dựng này bản chất nằm ở việc xác định giá trị các siêu tham số (hyper-parameters) của hai mô hình trên. Với các mô hình học máy dựa trên thuật toán cây, các siêu tham số phổ biến thường là số cây, số nhánh cây và số lá cây. Trước tiên, quá trình đào tạo hai mô hình học máy được tiến hành trên bộ dữ liệu Dataset.02. Ở bước này, bộ dữ liệu huấn luyện được chia thành 10 phần để tiến hành xác thực chéo. Với 10 lần mô phỏng, hiệu suất trung bình của bộ dữ liệu huấn luyện được tính ra và trình bày ở Hình 4.

Đáng chú ý, dữ liệu kiểm chứng (30% bộ dữ liệu) không được xét đến trong quá trình xây dựng mô hình, các siêu tham số của ELB và RF được lựa chọn chỉ dựa trên dữ liệu huấn luyện và dữ liệu xác thực.

xuất đã đưa ra năng lực dự báo khá cao. Cụ thể, mô hình RF cho hiệu suất  $R^2 \approx 0.88$ ,  $RMSE \approx 52.7$ , và  $MAE \approx 23.0$ , mô hình ELB cho  $R^2 \approx 0.89$ ,  $RMSE \approx 53.0$ , và  $MAE \approx 23.6$ .



**Hình 4.** Kết quả hiệu suất dự báo của hai mô hình cây ELB và RF trên bộ dữ liệu Dataset02 dựa trên các tiêu chí: (a)  $R^2$ , (b) RMSE, và (c) MAE

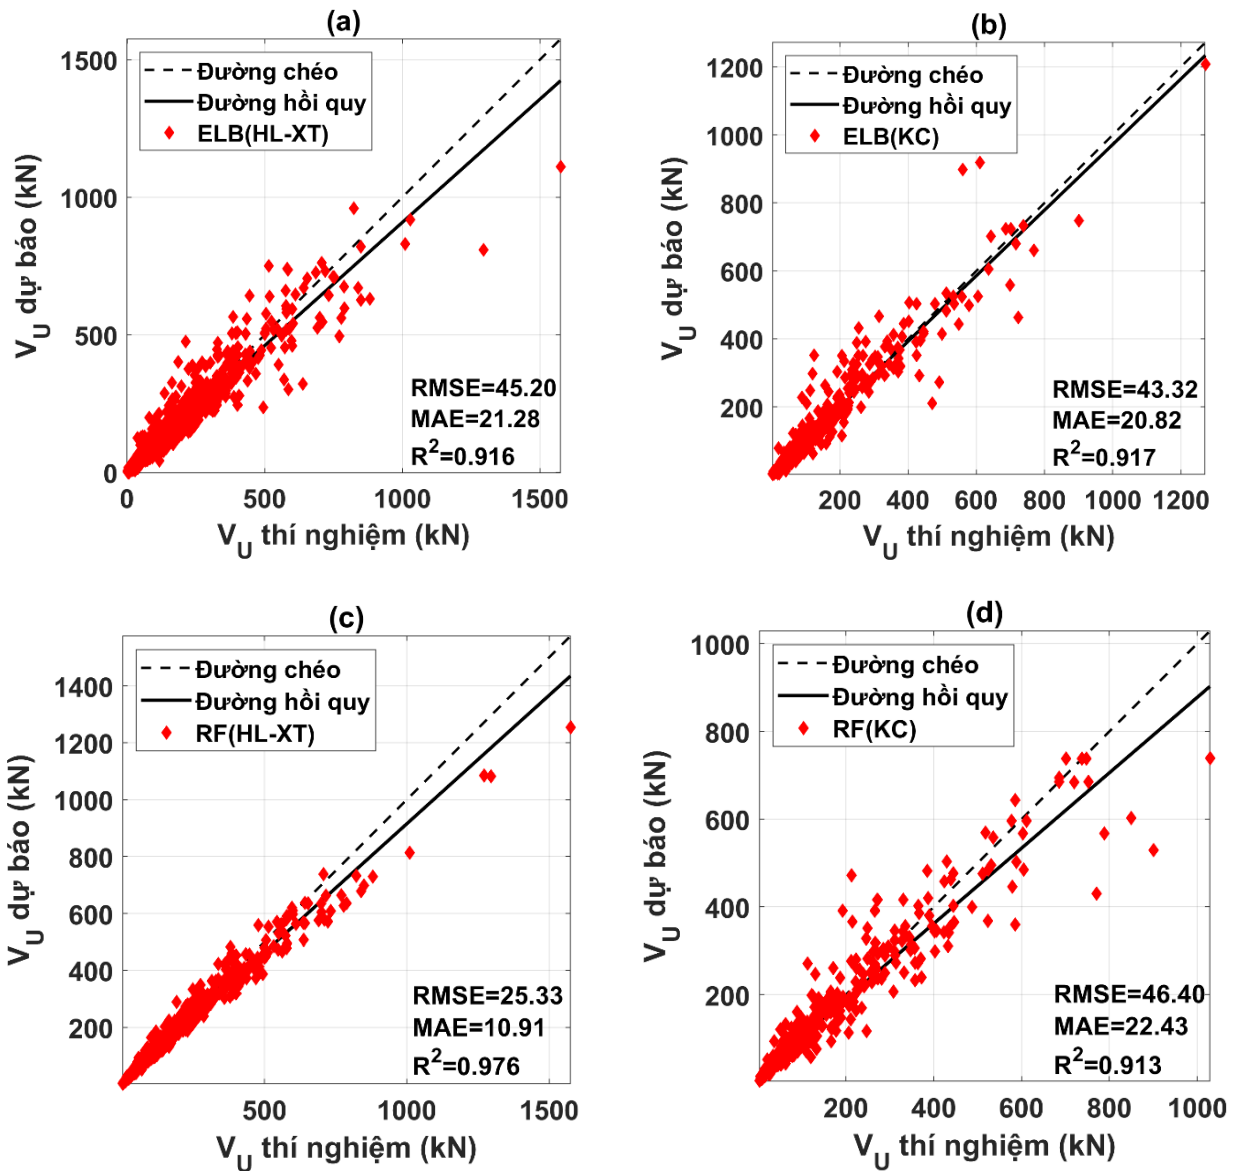
Đánh giá kết quả trên hình 4 cho thấy mô hình RF có khả năng đào tạo rất tốt, bởi các giá trị  $R^2$  rất cao và ổn định ở  $R^2 \approx 0.977$ ,  $RMSE \approx 24.5$ , và  $MAE \approx 10.7$ . Năng lực đào tạo của mô hình ELB so với RF là thấp hơn, với các giá trị  $R^2 \approx 0.894$ ,  $RMSE \approx 48.5$ , và  $MAE \approx 23.1$ . Tuy nhiên, các hiệu suất đạt được của 2 mô hình đều cho thấy khả năng dự báo sức kháng cắt của dầm BTCT là rất tốt. Đối với bộ dữ liệu kiểm chứng, các chỉ tiêu đánh giá năng lực dự báo cũng được tính toán tương ứng với 10 lần xác thực chéo (Hình 3). Với 30% dữ liệu hoàn toàn không được biết tới trong quá trình huấn luyện, hai mô hình cây được đề

Như vậy, có thể nói sau khi thực hiện 10 lần xác thực chéo, hai mô hình ELB và RF đã được xây dựng với độ chính xác cao và kiểm chứng độ tin cậy bởi 3 phần dữ liệu độc lập được trích xuất từ bộ dữ liệu Dataset.02. Vì vậy, cả hai mô hình được lựa chọn để trình bày kết quả dự báo tiêu biểu.

#### 4.3. Kết quả dự báo tiêu biểu của hai mô hình ELB và RF

Trong phần này, kết quả dự báo điển hình của hai mô hình ELB và RF được trình bày. Những kết quả này được trích xuất từ hai mô hình đã



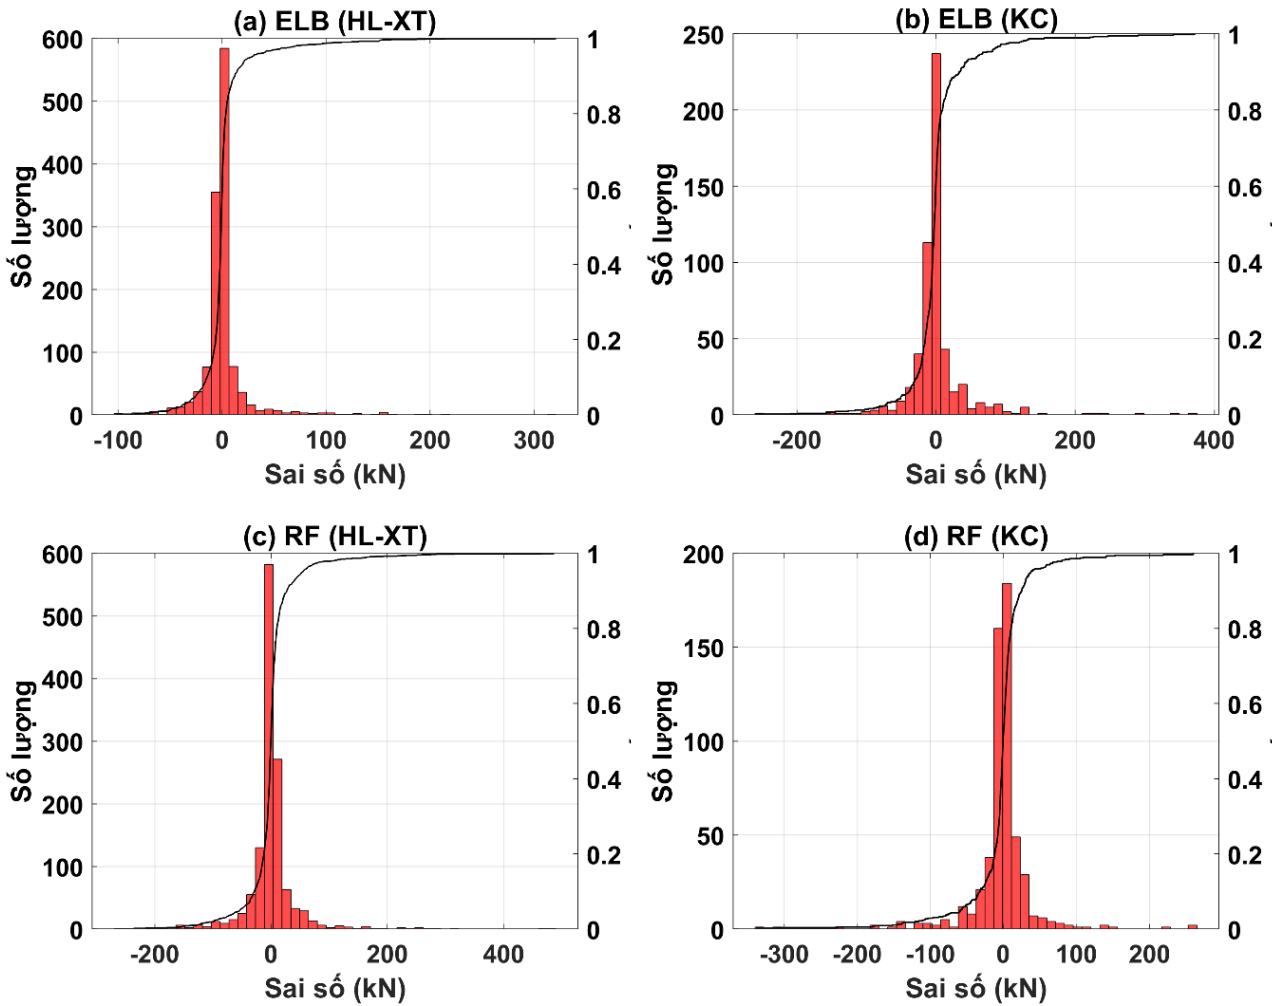


**Hình 5.** Kết quả hồi quy của hai mô hình cây trên bộ dữ liệu Dataset.02: (a) mô hình ELB với tập dữ liệu huấn luyện – xác thực, (b) mô hình ELB với tập dữ liệu kiểm chứng, (c) mô hình RF với tập dữ liệu huấn luyện – xác thực, và (d) mô hình RF với tập dữ liệu kiểm chứng.

được xây dựng, xác thực và kiểm chứng ở phần trước. Mô hình hồi quy cho các bộ dữ liệu khác nhau, dự đoán bởi ELB và RF được thể hiện trên hình 5.

Mô hình hồi quy cho các bộ dữ liệu khác nhau, dự đoán bởi ELB và RF được thể hiện trên hình 4. Rõ ràng đây là hai mô hình máy học rất tốt để dự đoán sức kháng cắt của dầm BTCT không cốt đai. Hai mô hình được đề xuất trong nghiên cứu này đều đạt độ chính xác cao. Cụ thể, mô hình ELB đạt được  $R^2 = 0.916$ ,  $RMSE = 45.20$ , và  $MAE = 21.28$  cho tập dữ liệu huấn luyện – xác thực, và

$R^2 = 0.917$ ,  $RMSE = 43.32$ , và  $MAE = 20.82$  cho tập dữ liệu kiểm chứng. Bên cạnh đó, mô hình RF đạt được  $R^2 = 0.976$ ,  $RMSE = 25.33$ , và  $MAE = 10.91$  cho tập dữ liệu huấn luyện – xác thực, và  $R^2 = 0.913$ ,  $RMSE = 46.40$ , và  $MAE = 22.43$  cho tập dữ liệu kiểm chứng. Hệ số tương quan  $R^2$  cao kết hợp với sai số thấp chỉ ra rằng hai mô hình được đề xuất là những mô hình dự báo tuyệt vời và thể hiện hiệu suất tổng quát hóa trong việc dự đoán sức kháng cắt của dầm BTCT không có cốt đai. Mô hình RF tuy rằng có độ chính xác cao hơn trên tập dữ liệu huấn luyện – xác thực, nhưng ở



**Hình 6.** Kết quả phân bố sai số của hai mô hình cây trên bộ dữ liệu Dataset.02: (a) mô hình ELB với tập dữ liệu huấn luyện – xác thực, (b) mô hình ELB với tập dữ liệu kiểm chứng, (c) mô hình RF với tập dữ liệu huấn luyện – xác thực, và (d) mô hình RF với tập dữ liệu kiểm chứng.

tập dữ liệu kiểm chứng, mô hình này dường như đưa ra nhiều kết quả lệch với các giá trị của sức kháng cắt lớn (trên 600 kN).

Để các so sánh được cụ thể hơn, nhóm tác giả trình bày trong hình 6 các đồ thị phân bố sai số mô phỏng của các mô hình ELB và RF thông qua các tập dữ liệu huấn luyện – xác thực và kiểm chứng. Có thể nhận thấy các sai số trong cả 4 trường hợp đều tập trung phân bố quanh vị trí 0 kN với mật độ rất lớn. Ngoài ra, dựa trên đường phân phối tích lũy thì khoảng 95% sai số đều tập trung ở những khoảng rất gần 0 kN, điều này khẳng định khả năng mô phỏng chính xác khả năng chịu cắt của dầm BTCT không cốt đai. Chỉ một vài trường hợp có sai số lớn (ngoài 200 kN) được phát hiện ở cả hai mô hình ELB và RF, tuy nhiên điều này không ảnh hưởng nhiều tới tính tổng quát của những mô hình học máy trên.

### 5. Kết luận

Xác định khả năng chịu cắt của dầm bê tông cốt thép luôn là một vấn đề quan trọng trong lĩnh vực xây dựng. Để giải quyết vấn đề này, hai mô hình dựa trên thuật toán cây là ELB và RF đã được xây dựng và phát triển trong nghiên cứu này để dự đoán sức kháng cắt của dầm bê tông cốt thép không có cốt đai. Một cơ sở dữ liệu gồm 1849 kết quả thí nghiệm trong suốt 60 năm đã được thu thập từ những công bố quốc tế uy tín. Dữ liệu đầu vào của bài toán mô phỏng bao gồm 12 thông số, trong đó 8 thông số được lựa chọn để làm biến đầu vào cho quá trình xây dựng mô hình, cụ thể là chiều rộng sườn dầm, chiều cao hữu hiệu, tỷ lệ giữa chiều dài nhịp cắt và chiều cao hữu hiệu, chiều dài của tấm chịu lực ở mặt chịu uốn, tỷ lệ cốt thép dọc, cường độ

nén của bê tông, kích thước cốt liệu tối đa và cường độ chảy của thép. Ba tiêu chí thống kê là hệ số xác định ( $R^2$ ), căn của sai số toàn phương trung bình (RMSE) và sai số tuyệt đối trung bình (MAE) được sử dụng để đánh giá mối tương quan giữa các giá trị dự đoán bằng hai mô hình học máy và các giá trị thực nghiệm. Kết quả cho thấy cả hai mô hình học máy đều đạt độ chính xác cao để dự đoán sức kháng cắt của dầm BTCT không có cốt đai ( $R^2 = 0.917$  với mô hình ELB và  $R^2 = 0.913$  với mô hình RF). Điều này thể hiện hai mô hình học máy đề xuất trong nghiên cứu này có thể dùng để dự đoán nhanh chóng và chính xác sức kháng cắt của dầm BTCT không có cốt đai, phục vụ thực tế cho các kỹ sư công trình trong công tác tính toán, thiết kế.

### Tài liệu tham khảo

- [1] M.P. Collins, D. Mitchell, P. Adebar, F.J. Vecchio. (1996). A general shear design method. *ACI Structural Journal*. 93-S5, 36–45.
- [2] K.N. Smith, A.S. Vantsiotis. (1982). Shear strength of deep beams. *Journal Proceedings*. Vol.79, 201–213.
- [3] K.S. Ismail. (2016). Shear behaviour of reinforced concrete deep beams, PhD Thesis, *University of Sheffield*.
- [4] W. Nadir, M.K. Dhahir, F.H. Naser. (2018). A compression field based model to assess the shear strength of concrete slender beams without web reinforcement. *Case Studies in Construction Materials*. doi.org/10.1016/j.cscm.2018.e00210.
- [5] T. Zhang, P. Visintin, D.J. Oehlers. (2016). Shear strength of RC beams without web reinforcement. *Australian Journal of Structural Engineering*. Vol. 17, 87–96. DOI:10.1080/13287982.2015.1122502
- [6] V. Sigrist, E. Bentz, M.F. Ruiz, S. Foster. (2013). A. Muttoni, Background to the fib Model Code 2010 shear provisions—part I: beams and slabs. *Structural Concrete*. Vol.14, 195-203.
- [7] S. Xu, X. Zhang, H.W. Reinhard. (2012). Shear Capacity Prediction of Reinforced Concrete Beams without Stirrups Using Fracture Mechanics Approach. *ACI Structural Journal*. Vol. 109, 705-714.
- [8] J. Park, D. Kuchma. (2007). Strut-and-tie model analysis for strength prediction of deep beams. *ACI Structural Journal*. Vol. 104, 657-666.
- [9] E.C. Bentz, F.J. Vecchio, M.P. Collins. (2006). Simplified modified compression field theory for calculating shear strength of reinforced concrete elements. *ACI Structural Journal*. Vol. 103, 614-624.
- [10] F.J. Vecchio, M.P. Collins. (1986). The modified compression-field theory for reinforced concrete elements subjected to shear. *ACI J*. 83, 219-231.
- [11] A.C.I. Standard. (2008). Building Code Requirements for Structural Concrete (ACI 318M-08) and Commentary, *Reported by ACI Committee*. 318.
- [12] BS EN 1992-1-1:2004. (2015). Eurocode 2: Design of Concrete Structures – Part 1-1: General Rules and Rules for Biddings, in: BSI Standards Limited, *IEEE*, pp. 55-60.
- [13] C.S. Association. (2014) Design of Concrete Structures (CSA A23. 3-14)., CSA Group, Mississauga, ON, Canada.
- [14] H.Q. Nguyen, H.B. Ly, V.Q. Tran, T.A. Nguyen, T.T. Le, B.T. Pham. (2020). Optimization of artificial intelligence system by evolutionary algorithm for prediction of axial capacity of rectangular concrete filled steel tubes under compression, *Materials*. Vol. 13. https://doi.org/10.3390/MA13051205.
- [15] T.A. Nguyen, H.B. Ly. (2020). Phương pháp dự đoán tải trọng ổn định đàn hồi của dầm thép bản bụng khoét lỗ tròn dựa trên máy vec-tơ hỗ trợ. *Transport and Communications Science Journal*.
- [16] H.B. Ly, T.A. Nguyen. (2020). Nghiên cứu dự báo sức chịu tải tối hạn của cấu kiện cột ống thép nhồi bê tông có tiết diện hình chữ nhật bằng mạng nơ ron nhân tạo, *Transport and Communications Science Journal*. Vol.71,154-166. doi.org/10.25073/tcsj.71.2.10.
- [17] A.W.C. Oreta. (2004). Simulating size effect on shear strength of RC beams without stirrups using neural networks. *Engineering Structures*. Vol. 26, 681-691.
- [18] M.Y. Mansour, M. Dicleli, J.-Y. Lee, J. Zhang. (2004). Predicting the shear strength of reinforced concrete beams using artificial neural networks. *Engineering Structures*. Vol. 26, 781-799. https://doi.org/10.1016/j.engstruct.2004.01.011
- [19] J. Amani, R. Moeini. (2012). Prediction of shear strength of reinforced concrete beams using adaptive neuro-fuzzy inference system and artificial neural network. *Scientia Iranica*. Vol. 19, 242–248. https://doi.org/10.1016/j.scient.2012.02.009
- [20] A. Cladera, A.R. Mari. (2004). Shear design procedure for reinforced normal and high-strength concrete beams using artificial neural networks. Part II: beams with stirrups. *Engineering Structures*. Vol. 26, 927-936. https://doi.org/10.1016/j.engstruct.2004.02.011
- [21] J.A. Abdalla, A. Elsanosi, A. Abdelwahab. (2007). Modeling and simulation of shear resistance of R/C beams using artificial neural network. *Journal of the Franklin Institute*. Vol. 344, 741–756.
- [22] M.P. Collins, E.C. Bentz, E.G. Sherwood. (2008). Where is shear reinforcement required? Review of research results and design procedures. *Structural Journal*. Vol. 105, 590-600.
- [23] M.S. Khorsheed, A.O. Al-Thubaity. (2013). Comparative evaluation of text classification techniques using a large diverse Arabic dataset.

- Language Resources and Evaluation*. Vol. 47, 513-538.
- [24] T.G. Dietterich. (2002). Ensemble learning. *The Handbook of Brain Theory and Neural Networks*. Vol. 2, 110-125.
- [25] L. Breiman. (2001). Random forests. *Machine Learning*. Vol. 45, 5-32.
- [26] L. Breiman. (1996). Bagging predictors. *Machine Learning*. Vol. 24, 123-140.
- [27] T.K. Ho. (1998). The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 20, 832-844.
- [28] H.B. Ly, T.A. Nguyen, B.T. Pham. (2021). Estimation of Soil Cohesion Using Machine Learning Method: A Random Forest Approach. *Advances in Civil Engineering*. Vol. 2021.
- [29] E. Izquierdo-Verdiguier, R. Zurita-Milla. (2020). An evaluation of Guided Regularized Random Forest for classification and regression tasks in remote sensing. *International Journal of Applied Earth Observation and Geoinformation*. Vol. 88.
- [30] M. Jeung, S. Baek, J. Beom, K.H. Cho, Y. Her, K. Yoon. (2019). Evaluation of random forest and regression tree methods for estimation of mass first flush ratio in urban catchments. *Journal of Hydrology*. Vol. 575, 1099–1110.
- [31] A. Liaw, M. Wiener. (2002). Classification and regression by randomForest. *R News*. Vol.2, 218–22.
- [32] R. Kohavi. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection, in: *Ijcai*, Montreal, Canada. pp. 1137–1145.
- [33] J.R. Schott. (2016). *Matrix analysis for statistics.*, John Wiley & Sons.