

Dự đoán cường độ liên kết giữa cốt thép bị ăn mòn và lớp bê tông xung quanh bằng phương pháp XGBoost

Prediction of ultimate bond strength of corroded reinforcement and surrounding concrete using XGBoost

Nguyễn Trung Hiếu^{a,b}, Trần Xuân Linh^{a,c*}
Nguyen Trung Hieu^{a,b}, Tran Xuan Linh^{a,c*}

^aViện Nghiên cứu và Phát triển Công nghệ Cao, Trường Đại học Duy Tân, Đà Nẵng

^aInstitute of Research and Development, Duy Tan University, Da Nang, 550000, Vietnam

^bKhoa Môi trường và Khoa học Tự nhiên, Trường Đại học Duy Tân, Đà Nẵng, Việt Nam

^bDepartment of Environment and Natural Science, Duy Tan University, Da Nang, 550000, Vietnam

^cKhoa Xây dựng, Trường Đại học Duy Tân, Đà Nẵng

^cFaculty of Civil Engineering, Duy Tan University, Da Nang, 550000, Vietnam

(Ngày nhận bài: 20/7/2021, ngày phản biện xong: 22/8/2021, ngày chấp nhận đăng: 22/11/2021)

Tóm tắt

Nghiên cứu này sử dụng một mô hình học máy XGBoost để dự đoán độ bền liên kết của cốt thép bị ăn mòn và lớp bê tông xung quanh. Một bộ dữ liệu bao gồm 218 mẫu thí nghiệm đã được thu thập từ các tài liệu hiện có để xây dựng mô hình và kiểm nghiệm phương pháp đề xuất. Sáu biến, bao gồm cường độ nén (X_1), độ dày lớp bê tông bao quanh (X_2), loại cốt thép (X_3), đường kính của cốt thép (X_4), chiều dài đoạn liên kết (X_5) và mức độ ăn mòn (X_6), đã được chọn làm các yếu tố đầu vào để xác định cường độ liên kết giữa cốt thép bị ăn mòn và bê tông xung quanh. Kết quả tính toán chỉ ra rằng mô hình XGBoost có thể đạt được hiệu suất dự đoán tốt với sai số bình phương trung bình là 2.55, sai số phần trăm tuyệt đối trung bình là 28.07% và hệ số xác định là 0.88. Các chỉ số này cũng tỏ ra vượt trội so với các mô hình khác như DFP-LSSVR. Do đó, mô hình được đề xuất có thể là một công cụ đầy hứa hẹn để hỗ trợ các kỹ sư trong việc dự báo cường độ liên kết của cốt thép bị ăn mòn và lớp bê tông xung quanh.

Từ khóa: Cường độ liên kết; cốt thép bị ăn mòn; Học máy; Mô hình XGBoost; Trí tuệ nhân tạo

Abstract

This research employs the Extreme Gradient Boosting Machine (XGBoost) for predicting ultimate bond strength of corroded steel reinforcement and surrounding concrete. A data set consisting of 218 experimental tests has been collected from the literature to construct and verify the proposed method. Six variables, including the compressive strength (X_1), concrete cover (X_2), steel type (X_3), diameter of steel bar (X_4), bond length (X_5), and corrosion level (X_6), have been selected as input factors to derive ultimate bond strength between the corroded reinforcement and surrounding concrete. The experiment results, supported by statistical tests, point out that the XGBoost is able to attain good predictive performances with average root mean square error of 2.55, average mean absolute percentage error of 28.07% and average coefficient of determination of 0.88. These predictive results are superior to those of benchmark models including the hybrid model of Differential Flower Pollination and Least Squares Support Vector Regression

* Corresponding author: Trần Xuân Linh; Institute of Research and Development, Duy Tan University, Da Nang, 550000, Vietnam; Faculty of Civil Engineering, Duy Tan University, Da Nang, 550000, Vietnam;

Email: tranxuanlinh@duytan.edu.vn

DFP-LSSVR). Therefore, the proposed model can be a promising tool to assist civil engineers in forecasting ultimate bond strength of corroded steel reinforcement and surrounding concrete.

Keywords: Ultimate bond strength; Corroded steel reinforcement; Machine learning; XGBoost; Artificial intelligence

1. Giới thiệu

Cường độ liên kết là lực tương tác nhằm duy trì sự kết dính giữa cốt thép và lớp bê tông xung quanh trong kết cấu bê tông cốt thép (BTCT) [1]. Liên kết giữa cốt thép và bê tông ảnh hưởng trực tiếp đến khả năng chịu tải và tuổi thọ của kết cấu BTCT. Trong giai đoạn thiết kế kết cấu BTCT, liên kết giữa cốt thép và bê tông xung quanh thường được coi là lý tưởng. Tuy nhiên, khi cốt thép bị ăn mòn, sự kết dính giữa chúng và bê tông xung quanh sẽ kém đi do sự hình thành các vết nứt bên trong bê tông. Ngoài ra, áp lực tác dụng lên bê tông xung quanh cùng với sự lan truyền của các vết nứt bê tông đẩy nhanh sự xuống cấp của các cấu kiện BTCT Saether [2].

Sự ăn mòn cốt thép trong các kết cấu BTCT thường diễn ra trong môi trường ẩm ướt và các công trình dưới biển. Trong các kết cấu này, quá trình ăn mòn tích cực xảy ra do sự suy giảm độ pH của dung dịch lỗ rỗng bên trong khối bê tông và do sự xâm nhập của các ion chloride có chứa trong môi trường xung quanh [3]. Do đó, nghiên cứu về cường độ liên kết giữa cốt thép bị ăn mòn và lớp bê tông xung quanh là một bài toán quan trọng để giám sát cũng như dự đoán tuổi thọ của kết cấu BTCT chịu các mức độ ăn mòn khác nhau.

Tuy nhiên, việc mô hình hóa hoạt động của độ bền liên kết của cốt thép bị ăn mòn với bê tông xung quanh không phải là một nhiệm vụ dễ dàng. Sự ăn mòn cốt thép trong kết cấu BTCT là một quá trình phức tạp bị chi phối bởi nhiều yếu tố ảnh hưởng khác nhau như chất lượng bê tông, loại cốt thép được sử dụng, nồng độ của chất ăn mòn, cũng như độ dày của lớp phủ bê tông [4-7]. Ngoài ra, cường độ liên kết của cốt thép và bê tông có thể tăng nhẹ ở mức

độ ăn mòn nhất định, khi mức độ ăn mòn tăng lên, độ bền liên kết sẽ bị suy yếu [4, 8].

Hiện nay, việc ứng dụng học máy trong mô hình hóa các đặc tính của kết cấu BTCT đang ngày càng trở nên phổ biến hơn Taffese and Sistonen [9]. Các mô hình học máy đã được áp dụng hiệu quả trong việc dự đoán các tính chất khác nhau của kết cấu BTCT như sử dụng mô hình học máy XGBoost để dự đoán biến dạng từ biến của các kết cấu BTCT [10], vết nứt trong dầm [11], biến dạng từ biến của bê tông xanh [12], khả năng chọc thủng của sàn BTCT [13], độ võng của dầm bê tông [14], cường độ nén / kéo [15], cường độ cắt của BTCT [16].

Trong nghiên cứu này, chúng tôi ứng dụng mô hình học máy XGBoost để dự đoán cường độ liên kết giữa cốt thép bị ăn mòn với lớp bê tông xung quanh trong các cấu kiện BTCT. Một bộ dữ liệu gồm 218 mẫu thí nghiệm được sưu tầm từ các công trình nghiên cứu thử nghiệm trước đó sẽ được sử dụng để huấn luyện và kiểm nghiệm mô hình.

Phần còn lại của bài báo này được trình bày như sau: Mục 2 trình bày phương pháp nghiên cứu và tập dữ liệu thu thập được từ các tài liệu hiện có; mục 3 trình bày các kết quả thử nghiệm và thảo luận về hiệu suất của mô hình XGBoost trong việc dự đoán cường độ liên kết giữa cốt thép bị ăn mòn và bê tông bao quanh; phần cuối cùng nêu lên các kết luận và hướng nghiên cứu mở rộng trong tương lai.

2. Phương pháp nghiên cứu

2.1 Extreme Gradient Boosting Machine (XGBoost)

Mô hình XGBoost được phát triển bởi Tianqi Chen trong một dự án nghiên cứu tại Trường Đại học Washington [17]. Mô hình này được biết đến với tính chất linh hoạt và tính

hiệu quả. Đặc biệt, XGBoost đã được ứng dụng trong quá trình sản xuất của các công ty lớn như Amazon, Uber, Facebook, Google. Ngoài ra, nó cũng đã được sử dụng để giành chiến thắng trong nhiều cuộc thi học máy trên các nền tảng khác nhau, chẳng hạn như Kaggle, KDD Cup [18]. Mô tả chi tiết của XGBoost được cung cấp trong tài liệu [18-20]. Sau đây, chúng tôi sẽ trình bày ngắn gọn những ý chính của phương pháp này.

Cho một tập gồm n mẫu $D = \{x_i, y_i\}_{i=1}^n$, trong đó $x_i \in R^m$ là véc tơ đầu vào với m tính năng, và $y_i \in R$ là đầu ra tương ứng. Cây hồi quy được liên kết với D là cây nhị phân trong đó: a) mỗi nút bên trong đại diện cho một quy tắc phân tách quyết định xem đầu vào mẫu thuộc nhánh bên trái hay bên phải dựa trên một đặc điểm đầu vào duy nhất b) mỗi lá được gán

$$L^t = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \Omega(f_t) = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (1)$$

trong đó l là hàm tổn thất.

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (2)$$

trong đó γ là thông số giảm tối thiểu và λ là thông số điều chỉnh L2.

L_t được tính như sau [21]:

$$L^t \approx \sum_{i=1}^n \left[l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (3)$$

trong đó $g_i = \partial_{\hat{y}_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)})$ và $h_i = \partial_{\hat{y}_i^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)})$.

Xét tối thiểu hóa của hàm mục tiêu đơn giản hơn sau:

$$\tilde{L}^t = \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (4)$$

Chúng ta có thể thu được các giá trị tối ưu w_j^* và \tilde{L}^t như sau:

$$w_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda}, \quad \tilde{L}^t(q) = -\frac{1}{2} \sum_j \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (5)$$

trong đó I_j là tập con của tập đầu vào liên kết với lá thứ j , i.e., $I_j = \{i: q(x_i) = j\}$.

một giá trị là dự đoán của đầu ra. Theo kết quả của các quy tắc tách, mỗi lá được liên kết với một tập con, $I \subset \{1, 2, \dots, n\}$, của chỉ số đầu vào, và các đầu vào tương ứng $\{x_i, i \in I\}$ có cùng giá trị dự đoán.

Đối với cây hồi quy, đặt T là số lượng lá, $w \in R^T$ biểu thị các giá trị dự đoán hoặc trọng số liên quan đến các lá, $q: D_x \subset R^m \rightarrow T$ biểu thị việc gán tập đầu vào cho các lá khác nhau, $f: R^m \rightarrow R, f(x) = w_{q(x)}$ là hàm dự đoán của cây.

XGBoost xây dựng một tập hợp các cây hồi quy một cách tuần tự và kết hợp chúng để dự đoán đầu ra. Gọi $\hat{y}_i^{(t-1)}$ là giá trị dự đoán của đầu ra y_i tại bước thứ $t-1$, ở bước thứ t , XGBoost xây dựng một cây với hàm dự đoán f_t để giảm thiểu hàm mục tiêu sau:

Tuy nhiên, phương trình (5) chỉ có thể được sử dụng để tìm trọng số tối ưu khi cấu trúc của cây q đã được xác định.

Trong mô hình XGBoost, một cây mới được tạo ra bằng cách đưa vào phân tách trong cây hiện tại. Sự phân chia được xác định để tối đa hóa mức giảm bị mất.

$$\tilde{L}_{split} = -\frac{1}{2} \left[\frac{(\sum_{i \in I_L} g_i)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{(\sum_{i \in I} g_i)^2}{\sum_{i \in I} h_i + \lambda} \right] - \gamma \tag{6}$$

trong đó I_L và I_R là các tập con của tập đầu vào liên kết với các nút bên trái và bên phải sau khi phân chia.

Thuật toán XGBoost

Xác định các thông số, bao gồm số bước lặp, γ, λ và kích thước bước nhảy η

Sắp xếp bộ đầu vào theo các giá trị tính năng

Với mỗi bước lặp t

Tính g_i và h_i

Kiểm tra cây hiện tại và quyết định phân chia tốt nhất sử dụng phương trình (6)

Tính các trọng lượng của cây mới $f_t(x)$ dựa trên biểu thức (5)

Giá trị dự đoán mới được tính bằng: $\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + \eta f_t(x_i)$ (7)

Trả lại mô hình XGBoost đã được huấn luyện

Hình 1. Thuật toán XGBoost

Các bước chính của mô hình XGBoost được tóm tắt trong Hình 1. Ngoài ra, để xây dựng mô hình xấp xỉ hàm dựa trên XGBoost, các tham số sau phải được chỉ định:

(i) eta (η): kích thước bước hay tốc độ học tập được sử dụng trong biểu thức (7). Giá trị η trong khoảng $[0, 1]$, theo mặc định $\eta = 0.3$.

(ii) độ sâu tối đa nằm trong khoảng $[0, \infty]$, theo mặc định độ sâu tối đa = 6

(iii) lambda (λ): thông số hiệu chỉnh L2 được sử dụng trong phương trình (2). λ dao động trong đoạn $[0, \infty]$, theo mặc định $\lambda = 1$.

Trong bài báo này chúng tôi sử dụng các tham số mặc định của thuật toán.

2.2 Bộ dữ liệu thực nghiệm

Trong nghiên cứu này, chúng tôi sử dụng một bộ dữ liệu gồm 218 mẫu được sưu tầm từ các công trình nghiên cứu thử nghiệm trước đó

[5, 8, 22-27]. Sáu yếu tố được chọn làm biến đầu vào để xác định cường độ liên kết giữa cốt thép bị ăn mòn và bê tông xung quanh gồm cường độ nén (X1), độ dày lớp bê tông bảo vệ (X2), loại cốt thép (X3), đường kính cốt thép (X4), chiều dài đoạn liên kết (X5) và mức độ ăn mòn (X6). Bộ dữ liệu này được mô tả chi tiết trong tài liệu Güneysi, et al. [4].

Cần lưu ý rằng loại cốt thép (X3) được chia thành hai loại và được mã hóa nhị phân: 0 cho cốt thép tròn trơn và 1 cho cốt thép có gân. Hơn nữa, cường độ nén của các mẫu bê tông hầu hết được đo từ các mẫu hình lập phương $150 \times 150 \times 150$ mm. Tuy nhiên, trong một số mẫu, cường độ nén thu được từ các mẫu có dạng hình học khác nhau. Để có tính nhất quán, cường độ nén của các mẫu như vậy đã được chuyển đổi thành các mẫu hình khối $150 \times 150 \times 150$ mm [4]. Các mô tả thống kê của sáu biến đầu vào và độ bền liên kết cuối cùng được trình bày trong Bảng 1.

Bảng 1. Mô tả thống kê các biến đầu vào và đầu ra

Biến	Ký hiệu	Min	Trung bình	Std	Độ xiên	Max
Cường độ nén (MPa)	X ₁	22.13	33.65	11.88	0.70	52.10
Lớp bê tông bảo vệ (mm)	X ₂	15.00	60.66	41.13	1.22	147.50
Loại cốt thép	X ₃	--	--	--	--	--
Đường kính cốt thép (mm)	X ₄	12.00	16.19	4.56	1.01	25.00
Chiều dài liên kết (mm)	X ₅	36.60	92.25	71.69	3.52	500.00
Độ ăn mòn (%)	X ₆	0.00	4.20	8.38	5.84	80.00
Cường độ liên kết (MPa)	Y	1.30	10.94	6.96	0.82	31.70

Chú ý: Std = độ lệch chuẩn.

3. Kết quả tính toán và thảo luận

Để giảm thiểu tác động tiêu cực của các thuộc tính có giá trị lớn, tập dữ liệu được chuẩn hóa bằng phép biến đổi dữ liệu điểm Z (Z-score data transformation) (biểu thức (8)). Hiệu suất của mô hình được thực hiện dựa trên ba tiêu chí đánh giá, bao gồm sai số toàn phương trung bình (RMSE), sai số phần trăm tuyệt đối trung bình (MAPE) (biểu thức (9)) và hệ số xác định (R²) (biểu thức (10)). Việc sử dụng nhiều tiêu chí đánh giá nhằm mục đích so sánh điểm yếu và điểm mạnh của mô hình ở những khía cạnh khác nhau.

$$X_N = \frac{X_O - m_X}{s_X} \quad (8)$$

$$MAPE = \frac{100\%}{N} \sum_{t=1}^N \frac{|Y_{A,i} - Y_{P,i}|}{Y_{A,i}} \quad (9)$$


$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_{A,i} - Y_{P,i})^2}{\sum_{i=1}^N (Y_{A,i} - \bar{Y})^2} \quad (10)$$

trong đó X_N và X_O là các biến đã chuẩn hóa và biến ban đầu; m_X và s_X lần lượt biểu thị giá trị trung bình và độ lệch chuẩn của biến ban đầu;

Y_{A,i} và Y_{P,i} biểu thị kết quả đầu ra thực tế và dự đoán của mẫu dữ liệu thứ ith; \bar{Y} là giá trị trung bình của các giá trị thực tế; N là số lượng mẫu dữ liệu.

Tập dữ liệu gồm 218 mẫu được chia ngẫu nhiên thành ba tập con bằng cách sử dụng công cụ Python package *scikit-learn*. Trong đó, tập thử nghiệm chiếm 10%, tập xác thực chiếm 27% và tập huấn luyện chiếm 63% tổng số tập dữ liệu. Mô hình được chạy 20 lần. Minh họa về mô hình dự đoán trong cả giai đoạn huấn luyện (training) và thử nghiệm (testing) sử dụng dữ liệu của cả 20 lần chạy được minh họa ở Hình 2.

Kết quả được dự đoán cũng được so sánh với kết quả của phương pháp DFP-LSSVR, một phương pháp kết hợp giữa phương pháp học máy hồi quy vector hỗ trợ bình phương nhỏ nhất (Least Square Support Vector Machine Regression) và thuật toán tối ưu thụ phấn hoa vi phân (Differential Flower Pollination), đã được đề xuất và chứng minh sự hiệu quả trong việc dự đoán cường độ liên kết giữa cốt thép và bê tông bao quanh [28].



Hình 2. Minh họa của mô hình dự đoán trong giai đoạn huấn luyện (training) và thử nghiệm (testing).

Theo **Bảng 2**, trong cả giai đoạn huấn luyện và thử nghiệm, XGBoost có sai số RMSE cao hơn DFP-LSSVR. Điều này có thể hiểu được do DFP-LSSVR bản chất là phương pháp học máy LSSVR dùng các tham số tối ưu tìm được nhờ thuật toán tối ưu DFP cực tiểu hóa sai số RMSE. Tuy nhiên, mặc dù sai số MAPE của XGBoost cao hơn của DFP-LSSVR và hệ số R^2 của XGBoost thấp hơn của DFP-LSSVR trong

giai đoạn huấn luyện. Các thông số này của XGBoost đều tốt hơn của DFP-LSSVR ở giai đoạn thử nghiệm. Điều này chứng tỏ XGBoost không bị quá khớp (overfitting) nhiều như DFP-LSSVR. Phương pháp XGBoost còn có thể cải thiện được hơn nếu sử dụng một thuật toán tối ưu, như DFP hay tương tự, để tìm các giá trị thích hợp cho các tham số như γ, λ và kích thước bước nhảy η .

Bảng 2. Kết quả tính toán của mô hình XGBoost

Giai đoạn	Thông số	XGBoost		DFP-LSSVR	
		Trung bình	Std.	Trung bình	Std.
Huấn luyện	RMSE (mm)	1.44	0.12	1.27	0.03
	MAPE (%)	10.55	1.87	9.83	0.35
	R^2	0.96	0.01	0.97	0.00
Thử nghiệm	RMSE (mm)	2.55	0.39	2.39	0.39
	MAPE (%)	28.07	8.23	33.82	10.23
	R^2	0.88	0.04	0.84	0.08

Chú ý: Std. = độ lệch chuẩn

Các kết quả này cho thấy XGBoost có thể cạnh tranh được với DFP-LSSVR và hoàn toàn có thể được sử dụng để dự đoán cường độ liên kết giữa cốt thép bị ăn mòn và lớp bê tông bảo vệ xung quanh.

4. Kết luận

Trong nghiên cứu này chúng tôi ứng dụng mô hình học máy XGBoost để giải bài toán dự đoán cường độ liên kết giữa cốt thép bị ăn mòn và lớp bê tông bao quanh. Một bộ dữ liệu gồm

218 mẫu thí nghiệm được sưu tầm từ các nghiên cứu thực nghiệm trước đó được sử dụng để huấn luyện và kiểm nghiệm mô hình. Sáu yếu tố được chọn làm biến đầu vào của mô hình XGBoost gồm cường độ nén, độ dày lớp bê

tông bảo vệ, loại cốt thép, đường kính cốt thép, chiều dài đoạn liên kết và mức độ ăn mòn. Kết quả tính toán cho thấy mô hình XGBoost dự đoán với độ chính xác cao ở cả hai giai đoạn huấn luyện và thử nghiệm thể hiện ở các thông số RMSE, MAPE và R^2 .

Bên cạnh bài toán dự đoán cường độ liên kết giữa cốt thép bị ăn mòn và lớp bê tông bao quanh, hướng nghiên cứu tiếp theo của bài báo này có thể là ứng dụng mô hình XGBoost để giải các bài toán khác trong lĩnh vực xây dựng. Ngoài ra, việc phát triển mô hình XGBoost kết hợp với một công cụ tối ưu hóa cũng là một hướng mở rộng của nghiên cứu này.

Tài liệu tham khảo

- [1] J. Nepal, H. P. Chen, and A. M. Alani, "Analytical modelling of bond strength degradation due to reinforcement corrosion," in *Key Engineering Materials*, 2013, vol. 569: Trans Tech Publ, pp. 1060-1067.
- [2] I. Sæther, "Bond deterioration of corroded steel bars in concrete," *Structure and Infrastructure Engineering*, vol. 7, no. 6, pp. 415-429, 2011/06/01 2011, doi: 10.1080/15732470802674836.
- [3] N.-D. Hoang, C.-T. Chen, and K.-W. Liao, "Prediction of chloride diffusion in cement mortar using Multi-Gene Genetic Programming and Multivariate Adaptive Regression Splines," *Measurement*, vol. 112, pp. 141-149, 2017/12/01/ 2017, doi: <https://doi.org/10.1016/j.measurement.2017.08.031>.
- [4] E. M. Güneyisi, K. Mermerdaş, and A. Gültekin, "Evaluation and modeling of ultimate bond strength of corroded reinforcement in reinforced concrete elements," *Materials and Structures*, journal article vol. 49, no. 8, pp. 3195-3215, August 01 2016, doi: 10.1617/s11527-015-0713-4.
- [5] H. Yalciner, O. Eren, and S. Sensoy, "An experimental study on the bond strength between reinforcement bars and concrete as a function of concrete cover, strength and corrosion level," *Cement and Concrete Research*, vol. 42, no. 5, pp. 643-655, 2012/05/01/ 2012, doi: <https://doi.org/10.1016/j.cemconres.2012.01.003>.
- [6] E. Güneyisi, M. Gesoğlu, F. Karaboğa, and K. Mermerdaş, "Corrosion behavior of reinforcing steel embedded in chloride contaminated concretes with and without metakaolin," *Composites Part B: Engineering*, vol. 45, no. 1, pp. 1288-1295, 2013/02/01/ 2013, doi: <https://doi.org/10.1016/j.compositesb.2012.09.085>.
- [7] F. J. Molina, C. Alonso, and C. Andrade, "Cover cracking as a function of rebar corrosion: Part 2— Numerical model," *Materials and Structures*, journal article vol. 26, no. 9, pp. 532-548, November 01 1993, doi: 10.1007/bf02472864.
- [8] A. A. Almusallam, A. S. Al-Gahtani, A. R. Aziz, and Rasheeduzzafar, "Effect of reinforcement corrosion on bond strength," *Construction and Building Materials*, vol. 10, no. 2, pp. 123-129, 1996/03/01/ 1996, doi: [https://doi.org/10.1016/0950-0618\(95\)00077-1](https://doi.org/10.1016/0950-0618(95)00077-1).
- [9] W. Z. Taffese and E. Sistonon, "Machine learning for durability and service-life assessment of reinforced concrete structures: Recent advances and future directions," *Automation in Construction*, vol. 77, pp. 1-14, 2017/05/01/ 2017, doi: <https://doi.org/10.1016/j.autcon.2017.01.016>.
- [10] H. Nguyen, N.-M. Nguyen, M.-T. Cao, N.-D. Hoang, and X.-L. J. E. w. C. Tran, "Prediction of long-term deflections of reinforced-concrete members using a novel swarm optimized extreme gradient boosting machine," pp. 1-13, 2021.
- [11] S. Ghadimi and S. S. Kourehli, "Multiple crack identification in Euler beams using extreme learning machine," *KSCE Journal of Civil Engineering*, vol. 21, no. 1, pp. 389-396, 2017/01/01 2017, doi: 10.1007/s12205-016-1078-0.
- [12] Ł. Sadowski, M. Nikoo, M. Shariq, E. Joker, and S. Czarnecki, "The Nature-Inspired Metaheuristic Method for Predicting the Creep Strain of Green Concrete Containing Ground Granulated Blast Furnace Slag," *Materials*, vol. 12, no. 2, p. 293, 2019. [Online]. Available: <http://www.mdpi.com/1996-1944/12/2/293>.
- [13] N.-D. Hoang, "Estimating Punching Shear Capacity of Steel Fibre Reinforced Concrete Slabs Using Sequential Piecewise Multiple Linear Regression and Artificial Neural Network," *Measurement*, 2019/01/18/ 2019, doi: <https://doi.org/10.1016/j.measurement.2019.01.035>.
- [14] F. M. S. Al-Zwainy, R. I. K. Zaki, A. M. Al-saadi, and H. F. Ibraheem, "Validity of artificial neural modeling to estimate time-dependent deflection of reinforced concrete beams," *Cogent Engineering*, vol. 5, no. 1, pp. 1-15, 2018/01/01 2018, doi: 10.1080/23311916.2018.1477485.
- [15] D.-K. Bui, T. Nguyen, J.-S. Chou, H. Nguyen-Xuan, and T. D. Ngo, "A modified firefly algorithm-artificial neural network expert system for predicting compressive and tensile strength of high-performance concrete," *Construction and Building Materials*, vol. 180, pp. 320-333, 2018/08/20/ 2018, doi: <https://doi.org/10.1016/j.conbuildmat.2018.05.201>.
- [16] A. E. Kurtoglu, M. E. Gulsan, H. A. Abdi, M. A. Kamil, and A. Cevik, "Fiber reinforced concrete

corbels: Modeling shear strength via symbolic regression," *Computers and Concrete*, vol. 20, no. 1, pp. 065-75 2017.

- [17] T. Chen. "Story and lessons behind the evolution of xgboost." <https://homes.cs.washington.edu/~tqchen/2016/03/10/story-and-lessons-behind-the-evolution-of-xgboost.html> (accessed 03/02, 2020).
- [18] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," presented at the Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, California, USA, 2016. [Online]. Available: <https://doi.org/10.1145/2939672.2939785>.
- [19] M. Filz George and D. V. Griffiths, (Proceedings). 2000, p. 0.
- [20] T. Chen, "Introduction to Boosted Trees," University of Washington 2014. [Online]. Available: <http://homes.cs.washington.edu/~tqchen/pdf/BoostedTree.pdf>
- [21] J. Friedman, T. Hastie, and R. Tibshirani, "Additive logistic regression: a statistical view of boosting (With discussion and a rejoinder by the authors)," (in en), *Ann. Statist.*, vol. 28, no. 2, pp. 337-407, 2000/04 2000, doi: 10.1214/aos/1016218223.
- [22] Y. Auyeung, P. Balaguru, and L. Chung, "Bond Behavior of Corroded Reinforcement Bars," *Materials Journal*, vol. 97, no. 2, pp. 214-220, 3/1/2000 2000, doi: 10.14359/826.
- [23] H. Shima, "Local bond stress-slip relationship of corroded steel bars embedded in concrete," *In: Proceeding of the third international symposium on bond in concrete, Budapest, pp 153-158. Nov 2002, 2002*.
- [24] Y. Zhao and W. Jin, "Test study on bond behavior of corroded steel bars and concrete," *J Zhejiang Univ (Engineering Science Edition)*, vol. 36, no. 4, pp. 352-356, 2002.
- [25] C. Fang, K. Lundgren, L. Chen, and C. Zhu, "Corrosion influence on bond in reinforced concrete," *Cement and Concrete Research*, vol. 34, no. 11, pp. 2159-2167, 2004/11/01/ 2004, doi: <https://doi.org/10.1016/j.cemconres.2004.04.006>.
- [26] G. Hørrigmo, I. Sæther, R. Antonsen, and B. Arntsen, "Laboratory investigations of steel bar corrosion in concrete," *Background document SB3.10. Sustainable bridges: assessment for future traffic demands and longer lives. A project co-funded by the European Commission within the Sixth Framework Programme 2007, 2007*.
- [27] L. Chung, J.-H. Jay Kim, and S.-T. Yi, "Bond strength prediction for reinforced concrete members with highly corroded reinforcing bars," *Cement and Concrete Composites*, vol. 30, no. 7, pp. 603-611, 2008/08/01/ 2008, doi: <https://doi.org/10.1016/j.cemconcomp.2008.03.006>.
- [28] N.-D. Hoang, X.-L. Tran, and H. Nguyen, "Predicting ultimate bond strength of corroded reinforcement and surrounding concrete using a metaheuristic optimized least squares support vector regression model," *Neural Computing and Applications*, 2019/05/16 2019, doi: 10.1007/s00521-019-04258-x.