

Tối ưu hóa độ chính xác dự đoán kết cấu BTCT bị ăn mòn dựa trên so sánh các mô hình trí tuệ nhân tạo

Optimizing the prediction accuracy of corroded reinforced concrete structures based on a comparison of artificial intelligence models

> **VƯƠNG HOÀNG THẠCH¹, CAO NỮ KIM ANH¹, PGS.TS NGUYỄN THANH HƯNG^{2*}**

¹NCS Khoa Xây dựng, Trường ĐH Sư phạm Kỹ thuật TP.HCM

²GV Khoa Xây dựng, Trường ĐH Sư phạm Kỹ thuật TP.HCM, Email: nthung@hcmute.edu.vn

TÓM TẮT

Ăn mòn ảnh hưởng đáng kể đến độ bền của kết cấu bê tông cốt thép (BTCT) trong các tòa nhà. Nghiên cứu này đánh giá các mô hình dự đoán và tập hợp để dự đoán khả năng chịu lực của kết cấu BTCT bị ăn mòn, sử dụng các kỹ thuật như máy hỗ trợ vector (SVMs), mạng nơ-ron nhân tạo (ANNs), hồi quy tuyến tính (LR) và hồi quy tuyến tính tổng quát (GENLIN) cũng như các mô hình tập hợp kết hợp các phương pháp này. Sử dụng 100 bộ dữ liệu từ các tòa nhà dân cư tại TP.HCM, các mô hình đã được thử nghiệm, với mô hình (ANNs) và (LR) đạt được độ chính xác dự đoán cao nhất là 98% về khả năng chịu lực của kết cấu BTCT bị ăn mòn. Những mô hình này tỏ ra hiệu quả trong việc dự đoán sớm và chính xác về độ bền của kết cấu, rất quan trọng cho việc lập kế hoạch bảo trì kịp thời.

Từ khóa: Học máy; trí tuệ nhân tạo; ăn mòn; cường độ nén; bê tông.

ABSTRACT

Corrosion significantly affects the durability of reinforced concrete structures in buildings. This study evaluates prediction and ensemble models to predict on the bearing capacity of corroded reinforced concrete structures, utilizing techniques such as Support Vector Machines, Artificial Neural Networks, Linear Regression, Generalized linear model and ensemble models combining these methods. Using a dataset from 100 residential buildings in Ho Chi Minh City, Vietnam, the models were tested, with the (ANNs) and (LR) model achieving the highest prediction accuracy of 98% on the bearing capacity of corroded reinforced concrete structures. These models prove effective for early and accurate predictions of structural durability, crucial for timely maintenance planning.

Từ khóa: Machine learning; artificial intelligence; corrosion; compressive strength; concrete.

1. GIỚI THIỆU

Sự hư hỏng của kết cấu BTCT và bê tông dự ứng lực phần lớn là do sự ăn mòn của cốt thép, làm giảm tiết diện của thép, ăn mòn bê tông, làm suy giảm liên kết giữa bê tông và thép và dẫn đến mất khả năng sử dụng do nứt, vỡ và tách lớp bê tông bảo vệ. Ăn mòn bắt nguồn từ nhiều yếu tố khác nhau như điều kiện môi trường, loại thép được sử dụng, sự hiện diện của các chất ăn mòn, chất lượng bê tông và độ dày lớp bê tông bảo vệ, đặc biệt là các kết cấu gần môi trường biển hoặc chứa nhiều clorua [1]. Theo thời gian, sự ăn mòn trở thành một phần không thể tránh khỏi trong quá trình lão hóa của bê tông. Các nghiên cứu thực nghiệm đã cho thấy mức độ ảnh hưởng của sự ăn mòn đến hiệu suất của kết cấu BTCT, cho thấy sự giảm đáng kể về khả năng chịu tải và độ dịch chuyển ở các kết cấu bị ăn mòn so với các kết cấu không bị ăn mòn. Tỷ lệ ăn mòn ngày càng tăng này đòi hỏi phải sửa chữa và phục hồi các công trình hiện có, một lĩnh vực hiện đang được phân bổ hơn 100 tỷ USD hàng năm để sửa chữa các hư hỏng do ăn mòn kết cấu bê tông [2].

Nghiên cứu về ăn mòn cốt thép đã xem xét rộng rãi quá trình ăn mòn và cường độ dư của các thành phần BTCT bị ăn mòn thông qua các phương pháp mô hình số như phương pháp phần tử hữu hạn 3D [3, 4]. Tuy nhiên, các phương pháp này thường thiếu khả năng khái quát hóa và gặp khó khăn trong việc thể hiện chính xác các hiện tượng ăn mòn tự nhiên do đặc tính phi tuyến của chúng, đòi hỏi phải hiệu chỉnh lại thường xuyên với dữ liệu mới. Các nghiên cứu trong phòng thí nghiệm về dầm bê tông cũng phải đối mặt với những thách thức do chi phí cao và nhu cầu về thời gian để mô phỏng sự ăn mòn, thường sử dụng các quy trình nhân tạo không mô phỏng được quá trình ăn mòn tự nhiên xảy ra trong nhiều thập kỷ. Do đó, làm tăng mối lo ngại về tính chính xác và khả năng ứng dụng của dữ liệu đó. Nhu cầu về các phương pháp mô hình hóa chính xác, dễ thích ứng và tiết kiệm chi phí hơn đã dẫn đến việc khám phá trí tuệ tính toán và học máy như những giải pháp tiềm năng. Những mô hình này có thể giảm đáng kể thời gian và chi phí nghiên cứu đồng thời mang lại sự hiểu biết sâu sắc hơn về sức mạnh

còn lại của cấu kiện BTCT bị ăn mòn thông qua việc phân tích các mối quan hệ dữ liệu phi tuyến tính phức tạp.

Nghiên cứu này nhằm đánh giá hiệu quả của các mô hình dự đoán và mô hình tập hợp trong việc dự đoán khả năng chịu lực của kết cấu BTCT bị ăn mòn, sử dụng các phương pháp như Máy vectơ hỗ trợ, Mạng thần kinh nhân tạo, và cây phân loại và hồi quy. Các mô hình tập hợp này đã được phát triển bằng cách kết hợp các kỹ thuật trên. Bộ dữ liệu được thu thập từ các tòa nhà chung cư tại TP.HCM, Việt Nam đã được sử dụng để xây dựng và kiểm tra hiệu quả của các mô hình được đề xuất.

2. THU THẬP DỮ LIỆU

Các thông số của kết cấu RC bị ăn mòn phải được khảo sát, đo đạc để đánh giá chính xác khả năng chịu lực còn lại của kết cấu, phục vụ cho các phân tích, tính toán tiếp theo. Các bước tiến hành khảo sát, đo đạc bao gồm: kiểm tra kích thước kết cấu; lấy mẫu bê tông để xác định đặc tính vật liệu; tính toán, phân tích và kiểm tra sau đó tổng hợp dữ liệu. Các thông số của kết cấu RC thực tế được khảo sát và đo đạc trong các tòa nhà được xây dựng trước năm 1975 và sau năm 1975 tại TP.HCM theo quy trình sau:

Đo lường: Xác định các thông số hình học thực tế của kết cấu về nhịp của kết cấu; kích thước của mặt cắt ngang; chiều cao, độ vồng của kết cấu. Vị trí, số lượng và loại cốt thép, mức độ ăn mòn cốt thép, tình trạng của lớp bê tông bảo vệ cũng như hình dạng và chiều rộng của các vết nứt trong kết cấu. Khoan lấy mẫu bê tông kiểm tra xác định cường độ của bê tông. Các số liệu khảo sát được xử lý và tổng hợp để đưa vào các mô hình trí tuệ nhân tạo để đánh giá.

3. CÁC MÔ HÌNH TRÍ TUỆ NHÂN TẠO VÀ PHƯƠNG PHÁP ĐÁNH GIÁ

3.1 Máy hỗ trợ vectơ (SVM)

Vapnik là người đầu tiên giới thiệu về máy vectơ hỗ trợ (SVM-support vector machine) [5]. SVM được xây dựng dựa trên các hàm ánh xạ đầu vào-đầu ra từ một tập dữ liệu, giải quyết cả hai vấn đề phân loại và hồi quy. Đối với mô hình hồi quy, thường sử dụng phương pháp hồi quy hỗ trợ vectơ epsilon [6], nhằm tìm một hàm $f(x)$ sao cho sự lệch ϵ tối đa giữa các dữ liệu đầu ra y_i được giảm thiểu. Trong máy vectơ hỗ trợ hồi quy, dữ liệu đầu vào ban đầu được ánh xạ vào một không gian đặc trưng nhiều chiều bằng cách sử dụng hàm phi tuyến như sau:

$$f(x, \omega) = \langle \omega, x \rangle + b \text{ với } \omega \in \chi, b \in \chi$$

Chất lượng của hàm $f(x)$ có thể được ước tính dựa trên tổn thất của hàm $L(x)$ như sau:

$$L_\epsilon = [y, f(x, \omega)] = \begin{cases} 0 & \text{if } |y - f(x, \omega)| \leq \epsilon \\ |y - f(x, \omega)| & \text{otherwise} \end{cases}$$

3.2 Mạng thần kinh nhân tạo (ANNs)

Mô hình mạng thần kinh nhân tạo là công cụ hữu ích và mạnh mẽ để giải quyết các vấn đề phức tạp, hoạt động tương tự như các neuron trong bộ não người. Các neuron được sắp xếp theo từng lớp, từ lớp đầu vào đến lớp đầu ra, với một hoặc nhiều lớp ẩn ở giữa. Mạng thần kinh nhân tạo đã được áp dụng rộng rãi trong các nghiên cứu trước để dự đoán mức tiêu thụ năng lượng [7]. Trong một mạng nơ-ron đa lớp, lớp đầu tiên chứa các nút nhận dữ liệu đầu vào, ví dụ như thông tin về đặc điểm của căn phòng, tiếp theo là một hoặc nhiều lớp ẩn chứa các nút xử lý tính toán, và cuối cùng là lớp đầu ra, nơi có nút biểu diễn mức tiêu thụ năng lượng. Thuật toán được sử dụng phổ biến và hiệu quả nhất để huấn luyện các mạng thần kinh đa lớp này là thuật toán lan truyền ngược, trong đó ngưỡng kích hoạt của mỗi nơ-ron trong lớp ẩn được tính toán dựa trên dữ liệu đầu vào và kết quả mong muốn.

$$net_k = \sum w_{kj} o_j \text{ và } y_k = f(net_k)$$

Trong đó net_k là ngưỡng kích hoạt của nơ-ron thứ k , j là tập các nơ-ron ở lớp trước, w_{kj} là trọng số kết nối giữa nơ-ron k và nơ-ron j , o_j là đầu ra của nơ-ron j , và y_k là hàm truyền.

$$f(net_k) = \frac{1}{1 + e^{-net}}$$

Công thức huấn luyện và trọng số cập nhật w_{kj} trong từng chu kỳ t là

$$w_{kj}(t) = w_{kj}(t-1) + \Delta w_{kj}(t)$$

Giá trị thay đổi $\Delta w_{kj}(t)$ được tính như sau

$$\Delta w_{kj}(t) = \eta \delta_{pj} o_{pj} + \alpha w_{kj}(t-1)$$

Trong đó η là tham số tốc độ huấn luyện, δ_{pj} sai số lan truyền, o_{pj} là kết quả đầu ra của nơ-ron j cho lần thứ p , α là tham số khuếch đại, và $w_{kj}(t-1)$ là giá trị thay đổi cho w_{kj} trong chu kỳ trước.

3.3 Hồi quy tuyến tính (LR)

Mô hình hồi quy tuyến tính đa biến (LR - Linear Regression) là một sự phát triển từ hồi quy tuyến tính đơn giản, cho phép xác định và phân tích mối quan hệ giữa hai hoặc nhiều biến độc lập [8]. Công thức chung của mô hình là:

$$Y = \beta_0 + \sum_{i=1}^n \beta_i X_i + \epsilon$$

Trong mô hình đề xuất, Y là mức tiêu thụ năng lượng của căn hộ chung cư, β_0 là hằng số, β_i là hệ số hồi quy ($i = 1, 2, \dots, n$), ϵ là sai số, và X_i đại diện cho các nhân tố cụ thể. Mô hình hồi quy tuyến tính áp dụng bốn phương pháp hồi quy tuyến tính đa biến bằng cách sử dụng bình phương cực tiểu: stepwise, forward và backward.

3.4 Mô hình tuyến tính tổng quát (GENLIN)

Mô hình tuyến tính tổng quát được phát triển bởi Nelder and Wedderburn [9]. Mô hình có thể phân tích các phân phối xác suất khác nhau (như là phân phối chuẩn, nhị thức, Poisson và gamma) cho một biến phụ thuộc sử dụng hàm liên kết làm mô hình tính toán để xác định mối quan hệ giữa các yếu tố dự báo tuyến tính và hàm phân phối trung bình.

Mô hình tuyến tính tổng quát linh hoạt hơn và có mối quan hệ thực tế hơn so với hồi quy đơn. Mẫu phân phối giả định của các điểm dữ liệu và mối quan hệ giữa X và Y được xác định theo phương trình sau:

$$\eta = g(E(Y)) = X_i \beta_i + O, Y \sim F$$

Trong đó η là bộ dự đoán tuyến tính, O là biến bù, X_i là biến độc lập, β_i là hệ số độ dốc và F là phân phối của Y .

Ba thành phần của mô hình tuyến tính tổng quát là một biến kết quả Y với phân phối ngẫu nhiên cụ thể và giá trị kỳ vọng μ và phương sai σ^2 ($E(Y) = \mu$). Một hàm liên kết $g(\cdot)$ với giá trị kỳ vọng (μ) của Y để biến đổi các giá trị dự đoán của η ($\eta = g(\mu)$); và một mô hình cấu trúc tuyến tính.

3.5 Các mô hình kết hợp


Các mô hình được xếp hạng dựa vào quá trình dự đoán và sau đó các mô hình có tỷ lệ dự đoán tốt nhất được kết hợp lại tạo thành mô hình kết hợp. Phương pháp kết hợp được thể hiện bằng phép toán là $g: \mathbb{R}^d \rightarrow \mathbb{R}$ với một biến dự đoán X và biến phân hồi Y . Mỗi phương pháp sử dụng một thuật toán xác định để đưa ra một hàm ước tính $g(\cdot)$. Ước tính bằng một hàm kết hợp $g_{en}(\cdot)$ tạo ra được bằng cách kết hợp tuyến tính của các hàm riêng lẻ như sau. Trong đó c_j chứa các hệ số kết hợp tuyến tính, là giá trị trung bình của trọng số khác nhau.

$$g_{en}(\cdot) = \sum_{j=1}^n c_j * g(\cdot)$$

Nhìn chung, phương pháp mô hình kết hợp ước tính chính xác hơn so với những mô hình riêng lẻ thông thường [10, 11].

3.5 Phương pháp xác thực chéo

Các nghiên cứu thường áp dụng thuật toán xác thực chéo k lần để giảm thiểu sai số liên quan đến lấy mẫu ngẫu nhiên của việc huấn luyện. Kohavi đã xác nhận rằng thử nghiệm năm lần đem lại thời gian tính toán và phương sai tối ưu [12]. Phương pháp này phân chia tập mẫu dữ liệu thành 5 tập con, tiến hành xây dựng và xác thực mô hình 5 lần, chọn 1 tập dữ liệu khác để kiểm tra, huấn luyện mô hình bằng 4 tập dữ liệu và sử dụng tập còn lại để kiểm tra tính chính xác của mô hình được minh họa ở hình 1. Độ chính xác của mô hình được tính bằng độ chính xác trung bình của 5 mô hình trong 5 lần xác thực.



Hình 1. Phương pháp xác thực chéo năm lần

3.6 Phương pháp đánh giá hiệu suất

Để đánh giá độ chính xác của quá trình dự đoán của các mô hình đơn lẻ và mô hình kết hợp, các phương pháp sau đã được sử dụng:

- Hệ số xác định

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

- Phần trăm sai số trung bình tuyệt đối

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

- Sai số trung bình tuyệt đối

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

- Sai số toàn phương trung bình

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

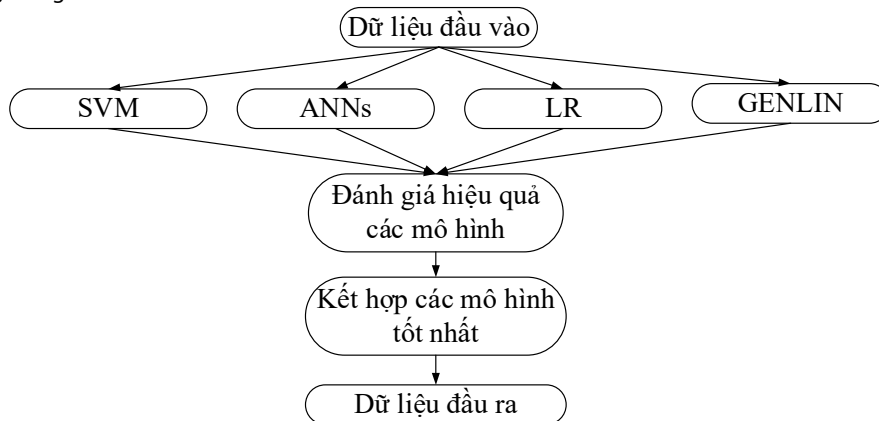
4. THIẾT LẬP THỰC NGHIỆM

Mục tiêu chính của khai phá dữ liệu là sử dụng sự kết hợp của các phương pháp công nghệ từ nhiều lĩnh vực khác nhau, bao gồm khoa học máy tính, thống kê, phân tích dữ liệu trực tuyến, máy học, và các hệ thống chuyên gia [13]. Công nghệ khai phá dữ liệu hiện nay được áp dụng rộng rãi trong quá trình dự đoán trong nhiều ngành. Hình 2 mô tả quy trình hoạt động của các mô hình dự đoán đơn, bao gồm sáu kỹ thuật khai phá dữ liệu như SVMs, ANNs, LR, và GENLIN. Các mô hình này được sử dụng để tự động sinh ra và so sánh các kết quả liên tục, giúp tăng cường khả năng phân tích và dự đoán.

Trong quá trình so sánh thử nghiệm các kỹ thuật khai phá dữ liệu, các tham số của mô hình được đặt mặc định để đảm bảo mô hình hoạt động một cách khách quan, hiệu quả và chính xác. Hình 3 minh họa quy trình sử dụng các mô hình để dự đoán khả năng chịu lực của kết cấu bê tông cốt thép bị ăn mòn bằng phần mềm SPSS của IBM [14]. Quy trình bao gồm các bước sau: Bước 1: Nhập dữ liệu đầu vào dựa trên thuật toán xác thực chéo. Bước 2: Dùng nút dự đoán số để huấn luyện dữ liệu. Bước 3: Sử dụng mô hình đơn để kiểm tra dữ liệu. Bước 4: Kết hợp các mô hình thông qua nút kết hợp. Bước 5: Đánh giá kết quả phân tích thông qua bảng kết quả, giúp nhận định chính xác hơn về hiệu quả của các mô hình.

5. KẾT QUẢ THỰC NGHIỆM

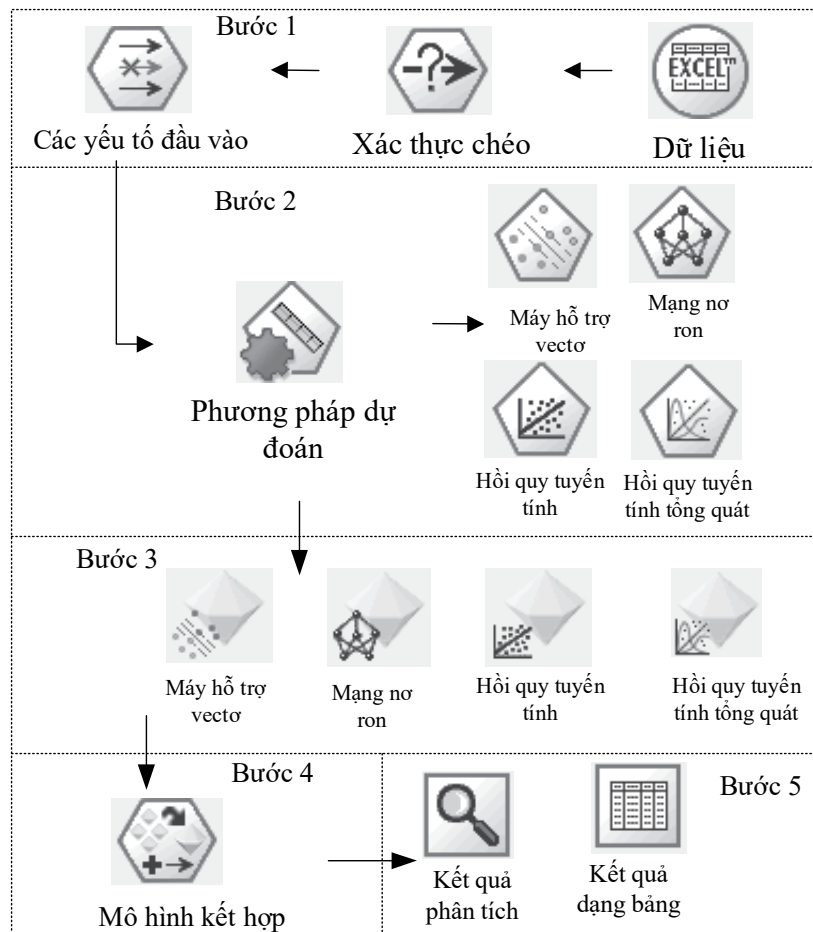
Tổng hợp kết quả các chỉ số đánh giá của những mô hình đơn cho thấy, hiệu quả của các mô hình: máy hỗ trợ vectơ (SVMs), mạng nơ-ron nhân tạo (ANNs), hồi quy tuyến tính (LR) và hồi quy tuyến tính tổng quát (GENLIN). Trong đó hiệu suất tốt nhất trong quá trình dự đoán là (ANNs) và (LR) và tiếp đó là mô hình (GENLIN) và (SVMs). Mô hình tổng hợp (COMBO3) giữa SVMs, ANNs, LR và GENLIN cho thấy hiệu suất là tốt nhất (Bảng 1).



Hình 2. Sơ đồ khối mô hình dự đoán cường độ

Bảng 1. Tổng hợp kết quả chỉ số đánh giá của các mô hình

Model	RMSE	MAE	MAPE	R ²
SVMs	358.495	273.468	36.027	0.790
ANNs	73.792	44.358	11.777	0.980
LR	66.279	19.603	12.106	0.980
GENLIN	103.687	48.740	13.058	0.967
COMBO1	210.047	164.235	17.222	0.889
COMBO2	119.918	78.795	16.543	0.965
COMBO3	115.154	36.656	15.335	0.970



Hình 3. Cấu trúc mô hình dự đoán cường độ trong Clementine

6. KẾT LUẬN

Bài báo này trình bày đề xuất về việc áp dụng các mô hình dựa trên thuật toán trí tuệ nhân tạo như máy hỗ trợ vectơ (SVMs), mạng nơ-ron nhân tạo (ANNs), hồi quy tuyến tính (LR) và hồi quy tuyến tính tổng quát (GENLIN) trong phần mềm Clementine của IBM để dự đoán về khả năng chịu lực của kết cấu BTCT bị ăn mòn trong các tòa nhà chung cư. Các mô hình này được sử dụng để xây dựng một mô hình tổng hợp nhằm tối ưu hóa quá trình dự đoán và khắc phục nhược điểm của các mô hình riêng lẻ. Dữ liệu là 100 kết cấu dầm được khảo sát ở các chung cư tại TP.HCM được dùng để huấn luyện mô hình, với việc áp dụng thuật toán xác thực chéo năm lần nhằm giảm thiểu sai số.

Kết quả nghiên cứu cho thấy mô hình mạng thần kinh nhân tạo (ANNs) và mô hình hồi quy tuyến tính (LR) có hiệu quả tốt nhất trong dự đoán khả năng chịu lực còn lại của kết cấu bê tông cốt thép bị ăn mòn với hệ số tương quan rất cao ($R = 98\%$). Các mô hình tổng hợp cũng đạt được hệ số tương quan tương tự ($R \geq 88\%$), trong đó mô hình tổng hợp giữa SVMs, ANNs, LR và GENLIN cho thấy hiệu suất là tốt nhất ($R = 97\%$).

Lời cảm ơn

Công trình này thuộc đề tài cấp Bộ có mã số B2023-SPK-06 do Bộ Giáo dục và đào tạo tài trợ, Trường Đại học Sư phạm kỹ thuật TP.HCM chủ trì.

TÀI LIỆU THAM KHẢO

1. Meda, A., et al., *Experimental evaluation of the corrosion influence on the cyclic behaviour of RC columns*. Engineering Structures, 2014. **76**: p. 112-123.

2. Ma, Y., Y. Che, and J. Gong, *Behavior of corrosion damaged circular reinforced concrete columns under cyclic loading*. Construction and Building Materials, 2012. **29**: p. 548-556.

3. Fernandez, I., J.M. Bairán, and A.R. Mari, *3D FEM model development from 3D optical measurement technique applied to corroded steel bars*. Construction and Building Materials, 2016. **124**: p. 519-532.

4. Ou, Y.-C., L.-L. Tsai, and H.-H. Chen, *Cyclic performance of large-scale corroded reinforced concrete beams*. Earthquake Engineering & Structural Dynamics, 2012. **41**(4): p. 593-604.

5. Vapnik, V.N., *The nature of statistical learning theory*. (New York: Springer-Verlag, 1995.

6. *SPSS. Clementine 12.0 Algorithm Guide*. Chicago, USA: Integral Solutions Limited, 2007.

7. Ekici, B.B. and U.T. Aksoy, *Prediction of building energy consumption by using artificial neural networks*. Advances in Engineering Software, 2009.

8. Neter, J., W. Wasserman, and M.H. Kutner, *Applied Linear Statistical Models*. Journal of the American Statistical Association, 1986. **81**.

9. Nelder, J.A. and R.W.M. Wedderburn, *Generalized Linear Models*. Journal of the Royal Statistical Society. Series A (General), 1972. **135**.

10. Adeodato, P.J.L., et al., *MLP ensembles improve long term prediction accuracy over single networks*. International Journal of Forecasting, 2011.

11. Wezel, M.C.v. and R. Potharst, *Improved Customer Choice Predictions using Ensemble Methods*. 2007.

12. Kohavi, R., *A study of cross-validation and bootstrap for accuracy estimation and model selection*. 1995.

13. Liao, S.-H., P.-H. Chu, and P.-Y. Hsiao, *Data mining techniques and applications – A decade review from 2000 to 2011*. Expert Systems with Applications, 2012. **39**(12): p. 11303-11311.

14. *IBM. PASW Modeler*. NY: IBM Cororation. USA, 2010.