

# Dự báo khả năng chịu lực còn lại của dầm bê tông cốt thép bị ăn mòn dựa trên mô hình mạng nơ ron hồi quy tổng quát

Prediction of the residual strength capacity of corroded reinforced concrete beams based on generalized regression neural network (GRNN) model

Đặng Vũ Hiệp<sup>(1)</sup>, Vũ Hoàng Hiệp<sup>(2)</sup>, Nguyễn Ngọc Tân<sup>(3)</sup>, Nguyễn Ngọc Phương<sup>(4)</sup>

## Tóm tắt

Nghiên cứu này tập hợp số liệu thực nghiệm từ 123 dầm bê tông cốt thép bị ăn mòn cốt thép dọc từ các tài liệu đã công bố trước đây có cập nhật đến năm 2020. Các dầm chịu uốn bị ăn mòn bởi phương pháp thúc đẩy ăn mòn bằng dòng điện. Khả năng chịu lực của dầm bị ăn mòn được dự báo bằng cách sử dụng mạng nơ ron hồi quy tổng quát (GRNN). Các tham số ảnh hưởng đến khả năng chịu lực coi như biến độc lập đầu vào, trong khi biến phụ thuộc đầu ra là khả năng chịu lực (mô men uốn giới hạn). Mô hình mạng nơ ron để xuất cho phép dự báo khả năng chịu uốn của dầm bê tông cốt thép bị ăn mòn có xét đến thời gian và tỷ lệ ăn mòn cốt thép. Kết quả dự báo được so sánh với các kết quả thực nghiệm cho thấy mô hình có độ chính xác cao.

**Từ khóa:** Ăn mòn, dầm bê tông cốt thép, mạng nơ ron hồi quy tổng quát, khả năng chịu lực

## Abstract

This study gathered the experimental data from 123 reinforced concrete (RC) beams with corroded longitudinal reinforcement from previous studies up to 2020. The flexural beams were electrochemically corroded by the accelerated corrosion method. The load-carrying capacity of corroded beams has been predicted using a generalized regression neural network (GRNN). The parameters affecting the capacity are considered as independent input variables, while the output variable is the ultimate bending moment of the beam. The proposed neural network model allows for predicting the flexural capacity of corroded RC beams taking into account the time and corrosion degree of steel reinforcement. The predicted results indicate that the proposed model has high accuracy compared to the experimental results.

**Keywords:** Corrosion, reinforced concrete beam, generalized regression neural network (GRNN), loading capacity

(1) PGS.TS, Giảng viên, Khoa Xây dựng, Trường Đại học Kiến trúc Hà Nội, [hiepdv@hau.edu.vn](mailto:hiepdv@hau.edu.vn)

(2) PGS.TS, Giảng viên, Khoa Xây dựng, Trường Đại học Kiến trúc Hà Nội

(3) TS, Giảng viên, Khoa Xây dựng Dân dụng và Công nghiệp, Trường Đại học Xây dựng Hà Nội

(4) PGS.TS, Giảng viên, Khoa Xây dựng, Trường Đại học Kiến trúc Hà Nội

Ngày nhận bài: 11/03/2022

Ngày sửa bài: 01/04/2022

Ngày duyệt đăng: 5/7/2022

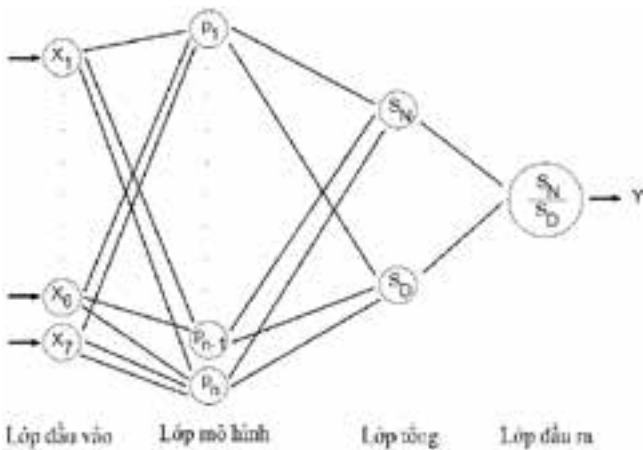
## 1. Đặt vấn đề

Độ bền kết cấu bê tông cốt thép (BTCT) theo thời gian là một trong những vấn đề được nhiều nhà khoa học quan tâm. Trong số nhiều nguyên nhân làm suy giảm độ bền kết cấu BTCT, ăn mòn cốt thép là một trong những nguyên nhân chính [1]. Nguyên nhân ăn mòn cốt thép chủ yếu là do bê tông bị cacbonat hóa làm thay đổi độ pH, mất chức năng bảo vệ cốt thép thụ động, do chất lượng bê tông kém, chiều dày lớp bê tông bảo vệ chưa đủ, sự xuất hiện các vết nứt trước trong bê tông tạo điều kiện cho ion clorua xâm nhập dễ dàng vào cốt thép bên trong. Khi hàm lượng ion clorua tích lũy trên bề mặt cốt thép vượt quá ngưỡng giới hạn, ăn mòn sẽ bắt đầu phát triển. Hậu quả của ăn mòn sẽ làm xuất hiện các vết nứt dọc theo cốt thép do sự dãn nở thể tích của sản phẩm ăn mòn, làm giảm khả năng chịu lực cũng như tuổi thọ của kết cấu [2].

Nhiều nghiên cứu về dự báo khả năng chịu lực còn lại của dầm BTCT bị ăn mòn đã được công bố trong 3 thập kỷ qua [3,4,5,6,7]. Nói chung, các nhà nghiên cứu đã cung cấp các mô hình giải tích kết hợp thực nghiệm kể đến ảnh hưởng của ăn mòn của cốt thép. Tuy nhiên chỉ một số ít nhân tố được đồng thời tích hợp trong các mô hình trên do tính phức tạp của quá trình ăn mòn cốt thép. Chẳng hạn thời gian cốt thép bị ăn mòn tính từ lúc khởi phát ăn mòn đến thời điểm dự báo chưa được tính đến. Hơn nữa, các mô hình trên chỉ được các tác giả kiểm chứng với số lượng dầm hạn chế hoặc trên chính các dầm do nhóm tác giả thực hiện. Với lượng dữ liệu thực nghiệm ngày càng tăng, độ chính xác khi kiểm chứng các mô hình đó cần phải được xem xét thêm.

Ứng dụng mạng thần kinh nhân tạo (ANN) để dự báo khả năng chịu lực của dầm BTCT bị ăn mòn đã được Inam và Kazmi [8] đề xuất. Nhóm tác giả chỉ sử dụng hai biến đầu vào là đường kính cốt thép dọc bán đầu (D) và chỉ số ăn mòn là tích của tỷ lệ ăn mòn ( $I_{corr}$ ) và thời gian ăn mòn (T) để dự báo mô men giới hạn. Do các dầm kiểm chứng đều cùng một kích thước và sử dụng cùng một loại cốt thép dọc nên các tham số này không được đề cập đến trong mô hình dự báo. Ngoài ra mô hình do Inam và Kazmi đề xuất chưa xem xét ảnh hưởng của chiều dày lớp bê tông bảo vệ đến khả năng chịu lực còn lại của dầm BTCT ăn mòn. Mặc dù phương pháp ANN đã được ứng dụng thành công vào bài toán dự báo trong nhiều lĩnh vực khác nhau nhưng nó vẫn tồn tại một số nhược điểm không dễ khắc phục. Nhược điểm chính của ANN là cần phải tìm ra một cấu trúc mạng tối ưu để giảm sai số biến phụ thuộc (biến dự báo), quá trình học để tìm trọng số tối ưu đôi khi khó hội tụ do có nhiều điểm cực tiểu cục bộ trên mặt sai số. Nếu không gian dữ liệu có tính phi tuyến cao, kết quả thu được từ phương pháp ANN có thể cho độ chính xác không cao [9]. Trong khi đó ưu điểm của phương pháp GRNN là không sử dụng lan truyền ngược để tối ưu trọng số nên kết quả luôn hội tụ và tránh được bẫy cực tiểu cục bộ trên những mặt sai số có tính phi tuyến cao. Ứng dụng GRNN để giải quyết các bài toán thực tế trong nhiều ngành khác nhau như dầu mỏ [10], khí hậu [11], thủy lực [12]... đã thu hút nhiều nhà khoa học quan tâm. Tuy nhiên ứng dụng GRNN trong các bài toán thuộc ngành kỹ thuật xây dựng còn rất hạn chế.

Xuất phát từ nhu cầu thực tế bài báo này giới thiệu một mô hình



Hình 1: Cấu trúc mạng GRNN [19]

dự báo khả năng chịu lực của dầm bê tông cốt thép bị ăn mòn điện hóa dựa trên phương pháp GRNN. Một bộ dữ liệu thí nghiệm các dầm bị ăn mòn điện hóa đến khi bị phá hủy được nhóm tác giả tập hợp và biên tập để xây dựng mô hình. Các biến đầu vào bao gồm: kích thước tiết diện ngang dầm (b x h), diện tích cốt thép dọc ( $A_s$ ), chiều dày lớp bê tông bảo vệ (C), giới hạn chảy cốt thép dọc ( $f_y$ ), cường độ chịu nén bê tông mẫu trụ ( $f_c$ ), chỉ số ăn mòn ( $I_{corr \times T}$ ). Biến đầu ra là mô men uốn giới hạn của dầm ( $M_{u,corr}$ ). Chất lượng của mô hình sau đó được đánh giá qua các chỉ số thống kê như hệ số tương quan Pearson ( $r$ ), căn bậc hai của trung bình bình phương sai số (RMSE), sai số tuyệt đối trung bình (MAE).

## 2. Dữ liệu và phương pháp GRNN

### 2.1. Chuẩn bị dữ liệu

Tổng cộng có 123 dữ liệu được thu thập từ các nghiên cứu độc lập đã được công bố trước đây từ các nhóm tác giả Abul K. Azad và cộng sự [13,14] (60 dầm), Jin Xia và cộng sự [15] (18 dầm), H. Yalciner và cộng sự [16, 17] (11 dầm), O'Flaherty và cộng sự [18] (34 dầm). Quá trình ăn mòn được thúc đẩy bởi dòng điện một chiều trong môi trường dung dịch điện ly có chứa NaCl được duy trì không đổi trong suốt quá trình thí nghiệm. Bảng 1 tóm tắt thông tin về dữ liệu sử dụng trong nghiên cứu, chi tiết dữ liệu thực nghiệm có thể xem trong các tài liệu trích dẫn bên trên.

Có thể nhận thấy trong bảng 1 phạm vi thay đổi độ lớn ăn mòn cốt thép thông qua tích số  $I_{corr \times T}$  là rất lớn, tương ứng với tình trạng ăn mòn từ rất nhẹ (~1% mất mát diện tích cốt

đọc) đến nặng (~29% mất mát diện tích cốt dọc). Tương tự, mô men uốn giới hạn còn lại  $M_{u,corr}$  cũng thay đổi trong một phạm vi rất rộng, tùy thuộc vào đặc tính vật liệu, kích thước tiết diện ngang dầm và độ lớn ăn mòn cốt dọc.

Bảng 1: Tóm tắt các dữ liệu thực nghiệm

Biến số	Giá trị		
	Nhỏ nhất	Lớn nhất	Trung bình
Bề rộng, b (mm)	100	250	159,75
Chiều cao, h (mm)	150	400	215,28
Bê tông bảo vệ, C (mm)	25	56	34,95
Cốt thép dọc, $A_s$ (mm <sup>2</sup> )	100,5	804,24	312,10
Giới hạn chảy, $f_y$ (MPa)	411	593	531,21
Cường độ nén, $f_c$ (MPa)	20,98	48,94	34,66
Độ lớn ăn mòn, $I_{corr \times T}$ (mA/cm <sup>2</sup> .ngày)	1,041	32	12,32
Khả năng chịu lực, $M_{u,corr}$ (kN.mm)	1262,5	170130	28353,62

### 2.2. Phương pháp GRNN

Cấu trúc mạng GRNN bao gồm 4 lớp: lớp đầu vào, lớp mô hình (lớp ẩn), lớp tổng và lớp đầu ra. Đối với bài báo này, lớp đầu vào có 7 nơ ron tương ứng với 7 biến độc lập, lớp mô hình có số lượng nơ ron tương ứng với số lượng mẫu trên tập huấn luyện, lớp mô hình luôn bao gồm 2 nơ ron và lớp đầu ra có 1 nơ ron ứng với số lượng biến cần dự báo như minh họa trên hình 1 [19].


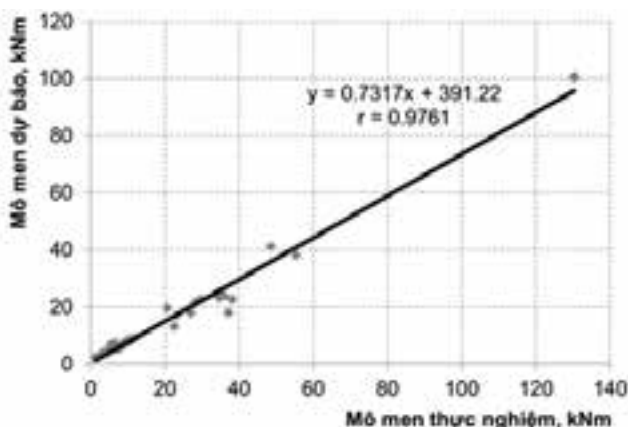
Dữ liệu đầu vào được chuyển qua lớp đầu vào đến lớp mô hình. Tại lớp mô hình dữ liệu trong tập huấn luyện hàm truyền hay còn gọi là hàm kích hoạt có dạng phân bố Gauss để chuyển đổi dữ liệu đầu vào:

$$p_i = e^{-\left[\frac{D_i^2}{2\sigma^2}\right]} \quad (1)$$

trong đó:  $D_i^2 = (X - X_i)^T (X - X_i)$ ;  $\sigma$  là hệ số xác định hình dạng của phân bố.

Sau khi được huấn luyện trong lớp mô hình, một dữ liệu đầu ra mới được tạo ra. Trong lớp tổng, tổng dữ liệu đầu ra có trọng số và không có trọng số được tính:

$$S_N = \sum_{i=1}^n y_i p_i \quad (2)$$



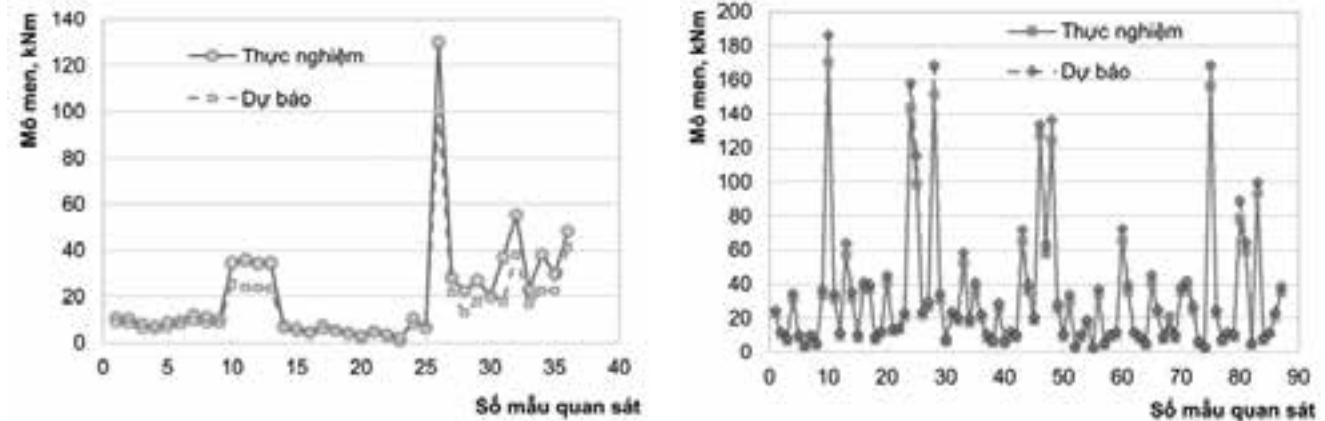
Hình 2: Kết quả đạt được từ mô hình GRNN: a) Trên tập kiểm tra, b) Trên tập huấn luyện

**Bảng 2: Hệ số r sau 10 fold-cv**

Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	Fold 8	Fold 9	Fold 10
0,9949	0,9988	0,9989	0,9979	0,9993	0,9989	0,9992	0,9997	0,9994	0,9971

**Bảng 3: Các chỉ số thống kê**

Phương pháp	Trên tập huấn luyện			Trên tập kiểm tra		
	r	NRMSE	MAE (kNm)	r	NRMSE	MAE (kNm)
GRNN Đề xuất	0,9985	0,1431	3,5197	0,9761	0,5487	5,5037
ANN [8]	0,67	0,3649	-	0,92	0,6772	-



**Hình 3: So sánh kết quả dự báo với kết quả thực nghiệm: a) Trên tập kiểm tra, b) Trên tập huấn luyện**

$$S_D = \sum_{i=1}^n p_i \tag{3}$$

Từ đó kết quả đầu ra của mô hình xác định theo công thức:

$$\hat{Y}_i(X) = \frac{S_N}{S_D} \tag{4}$$

Để tránh hiện tượng quá khớp trong quá trình huấn luyện mạng GRNN, dữ liệu được chia ngẫu nhiên thành 2 tập: tập huấn luyện với lượng dữ liệu chiếm 70%, tập kiểm tra với 30% lượng dữ liệu còn lại. Tập huấn luyện mạng được sử dụng liên tục trong quá trình huấn luyện và được tinh chỉnh sao cho sai số là nhỏ nhất trên bộ dữ liệu huấn luyện. Tập kiểm tra dùng để kiểm tra xem mạng đã huấn luyện có bị hiện tượng quá khớp hay không. Ngoài ra để lựa chọn mô hình huấn luyện tốt nhất, kỹ thuật k-fold được sử dụng. Theo đó, dữ liệu trong tập huấn luyện lại được chia thành k phần (thông thường là 10 phần, nên kỹ thuật này còn được gọi là 10-fold), sau đó huấn luyện mô hình 10 lần. Mỗi lần huấn luyện sẽ chọn (k-1) phần dữ liệu dùng cho huấn luyện, phần còn lại dùng để kiểm tra chéo. Sau 10 lần huấn luyện, mô hình được chọn là trung bình cộng của kết quả đánh giá.

Kế thừa từ những nghiên cứu ứng dụng mô hình GRNN trong bài toán dự báo của các nhà khoa học trước đây, trong bài báo này nhóm tác giả sử dụng ngôn ngữ lập trình có mã nguồn mở R để giải quyết bài toán.

**2.3. Đánh giá chất lượng mô hình**

Trong phạm vi bài báo này, nhóm tác giả sử dụng ba tiêu chí để đánh giá chất lượng mô hình dự báo GRNN: hệ số tương quan Pearson (r), căn bậc hai của trung bình bình phương sai số được chuẩn hóa (NRMSE), sai số tuyệt đối

trung bình (MAE). Các chỉ số này được xác định như sau:

$$r = \frac{\sum_{i=1}^N (y_i - \bar{y}_i)(t_i - \bar{t}_i)}{\sqrt{\sum_{i=1}^N (y_i - \bar{y}_i)^2 \sum_{i=1}^N (t_i - \bar{t}_i)^2}} \tag{5}$$

$$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2}}{\bar{y}} \tag{6}$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - t_i| \tag{7}$$

trong đó: N là số lượng mẫu quan sát được;  $t_i$  và  $\bar{t}_i$  là các giá trị thực tế (thí nghiệm) và giá trị trung bình của các giá trị thực tế;  $y_i$  và  $\bar{y}_i$  là các giá trị dự báo và trung bình của các giá trị dự báo tương ứng.

**3. Kết quả và bàn luận**

Bảng 2 thể hiện kết quả hệ số tương quan r sau 10 lần phân chia tập huấn luyện để hiệu chỉnh mô hình. Hệ số r cuối cùng là trung bình cộng của 10 kết quả đạt được.

Kết quả dự báo  $M_{u,corr}$  được thể hiện trên hình 2. Hệ số tương quan đạt được trên tập kiểm tra (36 quan sát) đạt giá trị rất cao, bằng 0,9761 chứng tỏ mối quan hệ rất tốt giữa kết quả dự báo và kết quả thực tế. Trong khi đó hệ số tương quan đạt được trên tập huấn luyện (87 quan sát) là 0,9985. Các hệ số này đều tốt hơn các hệ số đạt được trên mô hình ANN do Imam và Kazmi [8] đề xuất (Bảng 3).

Hình 3 so sánh kết quả dự báo của mô hình đề xuất trên các tập kiểm tra và huấn luyện. Kết quả dự báo từ mô hình

GRNN so với kết quả thí nghiệm trên tập kiểm tra thể hiện đúng xu hướng và nhỏ hơn kết quả thí nghiệm với sai số MAE là 5,5037 kNm. Hơn nữa, có thể thấy trên cả hai tập kiểm tra và huấn luyện kết quả dự báo từ mô hình GRNN cho căn bậc hai của trung bình bình phương sai số được chuẩn hóa (NRMSE) đều nhỏ so với mô hình ANN do Imam và Kazmi [8] đề xuất. Cũng cần lưu ý rằng số lượng quan sát và phạm vi thay đổi các tham số đầu vào trong mô hình ANN của Imam và Kazmi đều nhỏ hơn so với bài báo này.

#### 4. Kết luận

Bài báo này đã trình bày một mô hình mạng nơ ron hồi quy tổng quát, GRNN để dự báo khả năng chịu lực còn lại của dầm BTCT bị ăn mòn trong môi trường clorua. Một bộ dữ liệu gồm 123 dầm BTCT bị ăn mòn được thu thập từ nhiều nghiên cứu độc lập trong thời gian gần đây được sử dụng để huấn luyện và kiểm tra chéo mô hình GRNN. Để tăng thêm độ chính xác cũng như phản ánh tính phức tạp của dữ liệu,

kỹ thuật 10-fold đã được sử dụng. Mô hình GRNN hứa hẹn là một công cụ mạnh để đưa ra dự báo khả năng chịu lực không chỉ cho bài toán trong nghiên cứu này mà còn cho nhiều bài toán khác trong ngành kỹ thuật xây dựng. Một số kết luận từ kết quả nghiên cứu như sau:

- Từ dữ liệu cho thấy khả năng chịu lực còn lại của dầm BTCT bị ăn mòn phụ thuộc nhiều vào độ lớn ăn mòn cốt thép (IcorrXT), do đó sử dụng tích số IcorrXT như là một biến đầu vào là phù hợp;

- Nói chung, mô hình GRNN dự báo kết quả chính xác hơn so với mô hình ANN được phát triển bởi Imam và Kazmi [8].

Mô hình GRNN đề nghị trong nghiên cứu này còn sử dụng lượng dữ liệu chưa đủ lớn nên tính đại diện cho một vài trường hợp thực tế còn hạn chế. Trong tương lai gần, nhóm nghiên cứu sẽ tiếp tục xử lý thêm các dữ liệu mới và cải tiến để thu được một mô hình dự báo tốt hơn./

#### Tài liệu tham khảo

1. P.K. Mehta, *Durability of concrete-Fifty years progress*, ACI Special Publication, 1991, 126(1): 1–32.
2. J. Rodriguez, L.M. Ortega and J. Casal, *Load carrying capacity of concrete structures with corroded reinforcement*, Construction and Building Materials, Vol. 11 No. 4, pp. 239-248, 1997.
3. M.A. Nokhasteh, J.R. Eyre and A. McLeish, *The effect of reinforcement corrosion on the strength of reinforced concrete members*, Proceedings of the Structural Integrity Assessment, Elsevier Applied Science, London, pp. 314-325, 1992.
4. P.S. Mangat and M.S. Elgarf, *Flexural strength of concrete beams with corroding reinforcement*, ACI Structural Journal, Vol. 96 No. 1, pp. 149-158, 1999.
5. X.H. Wang and X.L. Liu, *Simplified methodology for the evaluation of the residual strength of corroded reinforced concrete beams*, ASCE Journal of Performance of Constructed Facilities, Vol. 24 No. 2, pp. 108-119, 2010.
6. X.P. Zhong, W.L. Jin, J. Xia, *A time-varying model for predicting the life-cycle flexural capacity of reinforced concrete beams*, Adv. Struct. Eng. 2016;18(1):21–32.
7. C. Dario, F. Raoul, D. Hiep and Z. Wenjun, *Strength of corroded RC beams with bond deterioration*, J. Struct. Eng., 2019, 145(10): 04019097.
8. A. Imam, Z.A. Kazmi, *Modified regression and ANN model for load carrying capacity of corroded reinforced concrete beam*, AIMS Materials Science, 4(5): 1140-1164.
9. D. Rumelhart, G.E. Hinton, R.J. Williams, *Learning representations by back-propagating errors*, Nature, volume 323, 533–536 (1986).
10. R. Rooki, *Application of general regression neural network (GRNN) for indirect measuring pressure loss of Herschel–Bulkley drilling fluids in oil drilling*, Measurement, 85 (2016) 184–191.
11. G. Kumar and H. Malik, *Generalized Regression Neural Network Based Wind Speed Prediction Model For Western Region Of India*, Procedia Computer Science, 93 (2016) 26 – 32.
12. A. Benabdesselam, L. Houichi and B. Achour, *GRNN-based models for hydraulic jumps in a straight rectangular compound channel*, Modeling Earth Systems and Environment, 2021.
13. A.K. Azad, S. Ahmad and S.A. Azher, *Residual strength of corrosion-damaged reinforced concrete beams*, ACI Materials Journal, V. 104, No. 1, January-February 2007.
14. A.K. Azad, S. Ahmad and B.H.A. Al-Gohi, *Flexural strength of corroded reinforced concrete beams*, Magazine of Concrete Research, 2010, 62, No. 6, June, 405–414.
15. J. Xia, W.-L. Jin, L.-Y. Li, *Effect of chloride-induced reinforcing steel corrosion on the flexural strength of reinforced concrete beams*, Magazine of Concrete Research, 2012, 64(6), 471–485.
16. H. Yalciner, A. Kumbasaroglu, A.K. El-Sayed, A. Pekrioglu Balkis, E. Dogru, A.I. Turan, A. Karimi, R. Kohistani, M. F. Mermit and K. Bicer, *Flexural strength of corroded reinforced concrete beams*, ACI Structural Journal, V. 117, No. 1, January 2020.
17. H. Yalciner, A. Kumbasaroglu, İ. Ertuc, A.İ. Turan, *Confinement effect of geo-grid and conventional shear reinforcement bars subjected to corrosion*, Structures, 13 (2018) 139–152.
18. F. O'Flaherty, E. Browne, *A proposal to modify the moment coefficient in Eurocode 2 for predicting the residual strength of corroded reinforced concrete beams*, Engineering Structures, 193 (2019) 324–339.
19. D.F. Specht, *A General Regression Neural Network*. IEEE Transactions on Neural Networks, Vol. 2, No. 6, November 1991.