

# Dự đoán sức chịu tải của cọc bê tông cốt thép bằng thuật toán LightGBM

## Prediction of pile bearing capacity using LightGBM algorithm

Trần Xuân Linh<sup>a,b\*</sup>  
Tran Xuan Linh<sup>a,b\*</sup>

<sup>a</sup>Khoa Xây dựng, Trường Đại học Duy Tân, Đà Nẵng, Việt Nam

<sup>a</sup>Faculty of Civil Engineering, Duy Tan University, Da Nang, 550000, Vietnam

<sup>b</sup>Viện Nghiên cứu và Phát triển Công nghệ Cao, Trường Đại học Duy Tân, Đà Nẵng, Việt Nam

<sup>b</sup>Institute of Research and Development, Duy Tan University, Da Nang, 550000, Vietnam

(Ngày nhận bài: 01/7/2023, ngày phản biện xong: 07/7/2023, ngày chấp nhận đăng: 10/8/2023)

### Tóm tắt

Móng cọc thường được sử dụng trong các công trình cao tầng xây dựng trên nền đất yếu. Sức chịu tải của cọc là một trong những yếu tố quan trọng trong quá trình thiết kế và thi công móng cọc. Nghiên cứu này ứng dụng thuật toán LightGBM để đánh giá sức chịu tải của cọc bê tông cốt thép. Mô hình được huấn luyện và kiểm nghiệm dựa trên bộ dữ liệu gồm 472 mẫu thí nghiệm su rầm từ tài liệu hiện có. Kết quả tính toán sau 30 lần chạy ngẫu nhiên mô hình cho thấy thuật toán LightGBM có thể đạt được hiệu quả dự đoán tốt với căn bậc hai của sai số toàn phương trung bình là 90.94 (kN), sai số tuyệt đối trung bình là 68.15 (kN), sai số phần trăm tuyệt đối trung bình là 7.41% và hệ số xác định là 0.93. Các chỉ số này cũng tỏ ra vượt trội so với các mô hình khác. Do đó, mô hình LightGBM có thể là công cụ hữu ích hỗ trợ các kỹ sư trong bài toán dự đoán sức chịu tải của cọc bê tông.

*Từ khóa:* sức chịu tải; cọc bê tông cốt thép; học máy có giám sát; thuật toán LightGBM; trí tuệ nhân tạo.

### Abstract

Pile foundations are frequently used for high-rise structures constructed in weak ground. The bearing capacity of pile is an important factor required during the design and construction processes of pile foundations. This study applies the LightGBM algorithm to estimate the bearing capacity of reinforced concrete piles. The model is trained and tested based on a dataset of 472 samples collected from existing literature. The calculation results after 30 random runs of the model show that the LightGBM algorithm can achieve good prediction performance with average root mean square error of 90.94 (kN), average mean absolute error of 68.15 (kN), average mean absolute percentage error of 7.41% and average coefficient of determination of 0.93. These parameters are much better than those of other models. The proposed model can be a potential alternative to assist civil engineers in the task of reinforced concrete pile bearing capacity prediction.

*Keywords:* bearing capacity; concrete pile; supervised machine learning; LightGBM algorithm; artificial intelligence.

\*Tác giả liên hệ: Trần Xuân Linh

Email: tranxuanlinh@duytan.edu.vn

## 1. Giới thiệu

Móng cọc là một thành phần quan trọng trong thiết kế và thi công các công trình nhà cao tầng. Có nhiều loại cọc khác nhau như cọc đóng bằng gỗ, cọc thép, cọc bê tông đúc sẵn, cọc khoan nhồi, cọc làm từ các vật liệu tổng hợp (*composites*)... Móng cọc có vai trò truyền tải trọng đến lớp đất có tính chất cơ lý tốt (đất đá cứng), góp phần vào việc đảm bảo độ bền và tính ổn định tổng thể của công trình. Do đó, sức chịu tải của cọc luôn là một thông số được các kỹ sư và các nhà khoa học quan tâm.

Hiện nay, có nhiều phương pháp đánh giá khả năng chịu tải của cọc đã được áp dụng trên thực tế. Thí nghiệm nén tĩnh cọc được công nhận rộng rãi là phương pháp đáng tin cậy và có độ chính xác cao để xác định sức chịu tải của cọc. Phương pháp này mô phỏng lại gần đúng quá trình làm việc và ứng xử của cọc. Tuy nhiên, phương pháp thí nghiệm này thường đòi hỏi quy trình chuẩn bị phức tạp, tốn thời gian và chi phí tương đối cao. Vì vậy, thí nghiệm nén tĩnh cọc chỉ khả thi đối với các dự án có quy mô lớn.

Đối với các dự án ở quy mô nhỏ và tài chính có hạn, thí nghiệm xuyên tiêu chuẩn (*the standard penetration test* (SPT)) là một phương án khả thi cho việc xác định sức chịu tải của cọc [1, 2]. Các bộ dữ liệu thu được từ thí nghiệm xuyên tiêu chuẩn SPT đã được sử dụng trong một số nghiên cứu để dự đoán sức chịu tải của cọc [3, 4]. Ngoài ra, còn có một số phương pháp khác để xác định khả năng chịu tải của cọc như phương pháp phân tích tĩnh học, phân tích động học, thí nghiệm động lực học [5]...

Hiện nay, việc ứng dụng trí tuệ nhân tạo và các mô hình học máy đang ngày càng trở nên phổ biến hơn trong hầu hết mọi lĩnh vực như kinh tế, kỹ thuật, xã hội nói chung và lĩnh vực xây dựng nói riêng. Cách tiếp cận này có một số ưu điểm như tính hiện đại, nhiều mô hình

hiệu quả, có thể áp dụng cho các bộ dữ liệu với những quy mô khác nhau, tính kinh tế cao... Có thể kể ra một số nghiên cứu gần đây như: dự báo khuyết tật mặt đường [6]; dự đoán cường độ liên kết giữa cốt thép bị ăn mòn và lớp bê tông xung quanh [7]; dự đoán độ võng của dầm bê tông [8]; dự đoán hiện tượng bong tróc của bê tông [9]; dự báo biến dạng từ biến của bê tông xanh [10]; dự đoán biến dạng từ biến của các dầm và sàn bê tông cốt thép (BTCT) sử dụng mô hình học máy XGBoost [11]; đánh giá khả năng chọc thủng sàn BTCT [12]; dự đoán vết nứt trong dầm BTCT [13]; dự đoán cường độ chịu cắt của các kết cấu BTCT [14]...

Trong bài báo này, tác giả ứng dụng mô hình học máy có giám sát LightGBM để dự đoán khả năng chịu tải của cọc dựa trên bộ dữ liệu gồm 472 mẫu thí nghiệm được sưu tầm từ tài liệu nghiên cứu thử nghiệm trước đó [15].

Các phần tiếp theo của bài báo bố trí theo thứ tự sau: mục 2 trình bày phương pháp nghiên cứu, giới thiệu về mô hình LightGBM và mô tả tập dữ liệu thực nghiệm; mục tiếp theo trình bày các kết quả tính toán, so sánh và thảo luận; một số kết luận và hướng nghiên cứu mở rộng của đề tài là nội dung của phần cuối bài báo.


## 2. Phương pháp nghiên cứu

### 2.1. Mô hình LightGBM


LightGBM là một mô hình được phát triển bởi tổ chức Microsoft Research Asia [16] dựa trên phương pháp cây quyết định tăng cường (*Gradient Boosting Decision Tree* (GBDT)). Mô hình này được biết đến nhờ hiệu quả tính toán cao, đặc biệt đối với các bài toán dự đoán có số lượng dữ liệu lớn. Nhằm mục đích giải bài toán chọn và phân tách các chỉ số, mô hình GBDT áp dụng phương pháp sắp xếp trước. Phương pháp này có ưu điểm là có thể xác định chính xác điểm phân tách. Tuy nhiên, nó có nhược điểm là tiêu tốn khá nhiều thời gian tính toán và bộ nhớ lưu trữ.

Trong khi hầu hết các thuật toán cây quyết định đều phát triển cây theo cấp độ (độ sâu) (*Level-wise tree growth*) (Hình 1). Tuy nhiên, quá trình tìm kiếm và phân tách nhiều lá có mức độ thu thập thông tin thấp là không cần thiết, điều này làm tăng mức tiêu thụ bộ nhớ bổ sung và khiến phương pháp này không hiệu quả. Thuật toán LightGBM là phương pháp dựa trên biểu đồ và chiến lược tăng trưởng theo chiều lá của cây (*trees leaf-wise growth strategy*) (Hình 2) với giới hạn độ sâu tối đa nhằm tăng tốc độ huấn luyện mô hình và giảm

mức tiêu thụ bộ nhớ [17, 18]. Chiến lược tăng trưởng theo chiều lá chỉ tách lá có mức thu thập thông tin lớn nhất trên cùng một lớp nên sẽ mang lại hiệu quả cao hơn. Trong phương pháp LightGBM, độ sâu tối đa của cây được giới hạn trong quá trình sinh trưởng của cây nhằm mục đích hạn chế hiện tượng khớp quá mức (*overfitting*) [17]. Trong nghiên cứu này chúng tôi sử dụng các tham số sau cho mô hình LightGBM: đối tượng '*objective*' = '*regression*'; phương pháp '*boosting*' = '*gbdt*' và số lá tối đa trên một cây '*num\_leaves*' = 10.



Hình 1. Chiến lược tăng trưởng theo độ sâu của cây



Hình 2. Chiến lược tăng trưởng theo chiều lá của cây

**2.2. Bộ dữ liệu thực nghiệm**

Trong nghiên cứu này, chúng tôi sử dụng một bộ dữ liệu thực nghiệm gồm 472 mẫu thí nghiệm cọc bê tông cốt thép được thu thập từ tài liệu nghiên cứu thử nghiệm trước đó [15] để dự đoán sức chịu tải của cọc. Sơ đồ bố trí thí nghiệm được minh họa trên Hình 3. Các yếu tố ảnh hưởng đến sức chịu tải của cọc được chọn làm biến đầu vào của mô hình LightGBM gồm: đường kính cọc ( $X_1$ ); độ dày lớp đất thứ nhất


( $X_2$ ); độ dày lớp đất thứ hai ( $X_3$ ); độ dày lớp đất thứ ba ( $X_4$ ); các biến từ  $X_5$  đến  $X_8$  lần lượt là các mốc cao độ của đỉnh cọc, độ cao của nền đất tự nhiên, độ cao đoạn đỉnh cọc và độ sâu chôn cọc được thể hiện rõ trên Hình 4;  $X_9$  đến  $X_{10}$  là giá trị trung bình của số búa SPT đếm dọc trục cọc và đỉnh cọc. Giá trị đặc trưng cho sức chịu tải của cọc được ký hiệu là  $Y$ . Bảng 1 trình bày các số liệu thống kê của các biến đầu vào và biến đầu ra.

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


| Biến số                     | Ký hiệu | Min    | TB     | ĐLC   | Max    |
|-----------------------------|---------|--------|--------|-------|--------|
| Đường kính cọc (mm)         | $X_1$   | 300.00 | 363.77 | 48.12 | 400.00 |
| Độ dày lớp đất thứ nhất (m) | $X_2$   | 3.40   | 3.83   | 0.48  | 5.72   |
| Độ dày lớp đất thứ hai (m)  | $X_3$   | 1.50   | 6.58   | 1.64  | 8.00   |
| Độ dày lớp đất thứ ba (m)   | $X_4$   | 0.00   | 0.33   | 0.46  | 1.69   |
| Độ cao đỉnh cọc (m)         | $X_5$   | 0.68   | 2.80   | 0.62  | .40    |

|  |          |        |        |        |         |
|--|----------|--------|--------|--------|---------|
| Độ cao nền đất tự nhiên (m)                        | $X_6$    | 3.04   | 3.50   | 0.08   | 4.12    |
| Độ cao đoạn đỉnh cọc (m)                           | $X_7$    | 1.03   | 2.92   | 0.60   | 4.35    |
| Độ sâu chôn cọc (m)                                | $X_8$    | 8.30   | 13.54  | 1.80   | 16.09   |
| Giá trị trung bình của số búa SPT đếm dọc trục cọc | $X_9$    | 5.60   | 10.74  | 2.26   | 15.41   |
| Giá trị trung bình của số búa SPT đếm tại đỉnh cọc | $X_{10}$ | 4.38   | 7.06   | 0.66   | 7.75    |
| Sức chịu tải của cọc (kN)                          | $Y$      | 407.20 | 984.20 | 353.21 | 1551.00 |

(chú ý: TB - trung bình; ĐLC - độ lệch chuẩn)



**Hình 3.** Sơ đồ thí nghiệm đo sức chịu tải của cọc bê tông cốt thép



**Hình 4.** Kết cấu cọc bê tông cốt thép và lát cắt địa chất

### 3. Kết quả tính toán và thảo luận

Trước khi huấn luyện mô hình, bộ dữ liệu sẽ được xử lý bằng phương pháp biến đổi dữ liệu điểm  $Z$  ( $Z$ -score data transformation) (công thức (1)). Thao tác này có tác dụng giảm tác động tiêu cực của các biến số có giá trị lớn. Sau khi có kết quả tính toán bằng mô hình LightGBM, chúng tôi sử dụng các thông số sau để đánh giá hiệu suất tính toán của mô hình: căn bậc hai của sai số toàn phương trung bình ( $RMSE$ ), sai số tuyệt đối trung bình ( $MAE$ ), sai số phần trăm tuyệt đối trung bình ( $MAPE$ ) và hệ số xác định ( $R^2$ ) (các công thức (2-5)). Sử dụng các thông số này sẽ giúp đánh giá hiệu quả của mô hình ở nhiều khía cạnh khác nhau.

$$X_N = \frac{X_O - m_X}{s_X} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{A,i} - Y_{P,i})^2} \quad (2)$$


$$MAE = \frac{1}{N} \sum_{i=1}^N \frac{|Y_{A,i} - Y_{P,i}|}{Y_{A,i}} \quad (3)$$

$$MAPE = \frac{100\%}{N} \sum_{t=1}^N \frac{|Y_{A,i} - Y_{P,i}|}{Y_{A,i}} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_{A,i} - Y_{P,i})^2}{\sum_{i=1}^N (Y_{A,i} - \bar{Y})^2} \quad (5)$$

trong đó  $X_N$  và  $X_O$  lần lượt là ký hiệu các biến đã chuẩn hóa và biến ban đầu;  $m_X$  và  $s_X$  là giá trị trung bình và độ lệch chuẩn của biến ban đầu;  $Y_{A,i}$  và  $Y_{P,i}$  là biến đầu ra thực tế và dự đoán của mẫu dữ liệu thứ  $i^{th}$ ;  $\bar{Y}$  là giá trị trung bình của các biến phụ thuộc thực tế;  $N$  là số mẫu dữ liệu.

Trong nghiên cứu này chúng tôi ứng dụng ngôn ngữ *Python* và thư viện *scikit-learn* để huấn luyện và thử nghiệm thuật toán LightGBM. Tập dữ liệu được chia ngẫu nhiên thành tập thử nghiệm 10% và tập huấn luyện 90%. Mô hình được chạy 30 lần. Kết quả dự đoán khả năng chịu tải của cọc bê tông ( $kN$ ) bằng mô hình LightGBM trong hai giai đoạn huấn luyện (training) và thử nghiệm (testing) sau 30 lần chạy thể hiện trên Hình 5. Các điểm dữ liệu dự đoán (các chấm màu xanh) nằm trên hoặc phân bố càng gần đường thẳng thì mô hình dự đoán càng chính xác. Giá trị trung bình của hệ số xác định  $R^2$  sau 30 lần chạy trong hai giai đoạn huấn luyện và thử nghiệm lần lượt bằng 0.96 và 0.93. Độ chính xác của mô hình càng cao khi giá trị này tiến dần đến 1.



**Hình 5.** Kết quả dự đoán của mô hình trong các giai đoạn huấn luyện (training) và thử nghiệm (testing).

**Bảng 2.** So sánh kết quả tính toán của mô hình LightGBM với các mô hình khác

| Giai đoạn  | Thông số             | ODFP-LSSVR |       | BPANNR |       | RTR    |       | RVMR   |       | LightGBM |       |
|------------|----------------------|------------|-------|--------|-------|--------|-------|--------|-------|----------|-------|
|            |                      | TB         | ĐLC   | TB     | ĐLC   | TB     | ĐLC   | TB     | ĐLC   | TB       | ĐLC   |
| Huấn luyện | <b>RMSE</b><br>(kN)  | 76.99      | 1.26  | 96.95  | 6.62  | 72.13  | 1.82  | 75.62  | 1.38  | 77.29    | 5.89  |
|            | <b>MAPE</b><br>(%)   | 6.12       | 0.11  | 7.88   | 0.39  | 5.57   | 0.16  | 5.97   | 0.09  | 6.21     | 0.44  |
|            | <b>MAE</b><br>(kN)   | 57.22      | 1.15  | 75.29  | 4.09  | 51.61  | 1.41  | 55.55  | 1.00  | 56.60    | 4.02  |
|            | <b>R<sup>2</sup></b> | 0.95       | 0.00  | 0.92   | 0.01  | 0.96   | 0.00  | 0.95   | 0.00  | 0.96     | 0.01  |
| Thử nghiệm | <b>RMSE</b><br>(kN)  | 92.19      | 11.39 | 103.09 | 15.33 | 105.52 | 20.32 | 102.59 | 14.59 | 90.94    | 10.61 |
|            | <b>MAPE</b><br>(%)   | 7.38       | 0.82  | 8.56   | 1.13  | 7.89   | 1.27  | 7.89   | 1.29  | 7.41     | 0.87  |
|            | <b>MAE</b><br>(kN)   | 68.97      | 9.28  | 80.45  | 11.54 | 73.92  | 11.91 | 73.02  | 9.34  | 68.15    | 8.30  |
|            | <b>R<sup>2</sup></b> | 0.93       | 0.02  | 0.90   | 0.03  | 0.90   | 0.04  | 0.91   | 0.03  | 0.93     | 0.02  |

(chú ý: TB - trung bình; ĐLC - độ lệch chuẩn)

Ngoài ra, kết quả tính toán trong bài báo này cũng được so sánh với một số mô hình khác trong nghiên cứu [19]. Các mô hình dùng để so sánh gồm: mô hình hồi quy véc tơ hỗ trợ kết hợp công cụ tối ưu hóa ODFP-LSSVR (*Opposition-based DFP Least Squares Support Vector Regression*); mô hình hồi quy mạng nơ ron nhân tạo lan truyền ngược BPANNR (*Backpropagation Artificial Neural Network Regression*); mô hình cây hồi quy RTR (*Regression Tree*) và thuật toán hồi quy máy véc tơ liên quan RVMR (*Relevance Vector Machine Regression*) [19] (Bảng 2). Điều này nhằm mục đích đánh giá tương quan hiệu suất tính toán của mô hình LightGBM so với các mô hình khác trên nhiều khía cạnh khác nhau. Dựa vào Bảng 2 có thể rút ra một số nhận định sau:

i) **Giai đoạn huấn luyện:** mô hình LightGBM tốt hơn các mô hình ODFP-LSSVR, BPANNR, và RVMR ở chỉ số  $R^2$ .

ii) **Giai đoạn thử nghiệm:** mô hình LightGBM tốt hơn so với tất cả các mô hình còn lại ở các thông số RMSE và MAE. Dựa vào giá trị hệ số xác định  $R^2$ , mô hình

LightGBM tương đương với mô hình ODFP-LSSVR và tốt hơn các mô hình BPANNR, RTR và RVMR. Cụ thể, các chỉ số trung bình sau 30 lần chạy của mô hình LightGBM ở giai đoạn kiểm nghiệm lần lượt là:  $RMSE = 90.94$  (kN),  $MAE = 68.15$  (kN),  $MAPE = 7.41\%$  và  $R^2 = 0.93$ .

Do đó, mô hình LightGBM có thể được xem là công cụ phù hợp để ứng dụng vào bài toán dự đoán khả năng chịu tải của cọc bê tông cốt thép.

#### 4. Kết luận

Trong nghiên cứu này, sức chịu tải của cọc bê tông cốt thép được dự đoán bằng mô hình học máy LightGBM. Mô hình được huấn luyện và kiểm nghiệm dựa trên bộ dữ liệu gồm 472 mẫu thí nghiệm su rầm từ các nghiên cứu thực nghiệm trước đó. Mười yếu tố có ảnh hưởng đến khả năng chịu tải của cọc được chọn làm các biến độc lập của mô hình. Mô hình được chạy ngẫu nhiên 30 lần và so sánh kết quả với 4 mô hình học máy khác. Kết quả tính toán cho thấy mô hình LightGBM có khả năng dự đoán với độ chính xác tương đối cao thể hiện ở các

thông số  $RMSE$ ,  $MAE$ ,  $MAPE$  và  $R^2$  ở cả hai giai đoạn huấn luyện và thử nghiệm. Do đó, có thể sử dụng mô hình LightGBM như là một công cụ hữu ích giúp các kỹ sư dự đoán khả năng chịu tải của kết cấu cọc bê tông cốt thép trong quá trình thiết kế và thi công các công trình.

Bên cạnh bài toán dự báo khả năng chịu tải của cọc bê tông cốt thép, ứng dụng thuật toán LightGBM để giải các bài toán khác trong lĩnh vực xây dựng là hướng nghiên cứu khả thi tiếp theo. Ngoài ra, việc phát triển mô hình LightGBM kết hợp với các công cụ tối ưu hóa quá trình chia tập dữ liệu và các tham số của thuật toán cũng là một hướng mở rộng của nghiên cứu này.

### Tài liệu tham khảo

- [1] Bouafia A., & Derbala A. (2002). Assessment of SPT-based method of pile bearing capacity—analysis of a database. *Paper presented at the Proceedings of the International Workshop on Foundation Design Codes and Soil Investigation in View of International Harmonization and Performance-Based Design*.
- [2] Kozłowski W., & Niemczynski D. J. P. e. (2016). Methods for estimating the load bearing capacity of pile foundation using the results of penetration tests—case study of road viaduct foundation. *Procedia Engineering* (161), 1001-1006.
- [3] Meyerhof G. G. J. J. (1976). Bearing capacity and settlement of pile foundations. *Journal of the Geotechnical Engineering Division* 102(3), 197-228. DOI: <https://doi.org/10.1061/AJGEB6.0000243>
- [4] Robert Y. J. C. G. J. (1997). A few comments on pile design. *Canadian Geotechnical Journal* 34(4), 560-567.
- [5] Pham K., Kim D., Park S., & Choi H. J. C. (2021). Ensemble learning-based classification models for slope stability analysis. *Catena* (196), 104886.
- [6] Cao M.-T., Chang K.-T., Nguyen N.-M., Tran V.-D., Tran X.-L., & Hoang N.-D. (2021). Image processing-based automatic detection of asphalt pavement rutting using a novel metaheuristic optimized machine learning approach. *Data analytics and machine learning* 25(20), 12839-12855.
- [7] Hoang N.-D., Tran X.-L., Nguyen H. (2020). Predicting ultimate bond strength of corroded reinforcement and surrounding concrete using a metaheuristic optimized least squares support vector regression model. *Neural Computing and Applications* (32), 7289-7309.
- [8] Al-Zwainy F. M. S., Zaki R. I. K., Al-saadi A. M., & Ibraheem H. F. (2018). Validity of artificial neural modeling to estimate time-dependent deflection of reinforced concrete beams. *Cogent Engineering*, 5(1), 1-15. doi:10.1080/23311916.2018.1477485
- [9] Cao M.-T., Nguyen N.-M., Chang K.-T., Tran X.-L., & Hoang N.-D. (2021). Automatic recognition of concrete spall using image processing and metaheuristic optimized LogitBoost classification tree. *Advances in Engineering Software* (159), 103031.
- [10] Sadowski Ł., Nikoo M., Shariq M., Joker E., & Czarnecki S. (2019). The Nature-Inspired Metaheuristic Method for Predicting the Creep Strain of Green Concrete Containing Ground Granulated Blast Furnace Slag. *Materials*, 12(2), 293.
- [11] Nguyen, H., Nguyen, N.-M., Cao, M.-T., Hoang, N.-D., & Tran, X.-L. J. E. w. C. (2021). Prediction of long-term deflections of reinforced-concrete members using a novel swarm optimized extreme gradient boosting machine. *Engineering with Computers* (38), 1-13.
- [12] Hoang N.-D. (2019). Estimating Punching Shear Capacity of Steel Fibre Reinforced Concrete Slabs Using Sequential Piecewise Multiple Linear Regression and Artificial Neural Network. *Measurement* (137), 58-70. doi:<https://doi.org/10.1016/j.measurement.2019.01.035>
- [13] Ghadimi S., & Kourehli S. S. (2017). Multiple crack identification in Euler beams using extreme learning machine. *KSCE Journal of Civil Engineering*, 21(1), 389-396. doi:10.1007/s12205-016-1078-0
- [14] Kurtoglu A. E., Gulsan M. E., Abdi H. A., Kamil M. A., & Cevik A. (2017). Fiber reinforced concrete corbels: Modeling shear strength via symbolic regression. *Computers and Concrete*, 20(1), 065-075
- [15] Pham T. A., Tran V. Q., Vu H.-L. T., & Ly H.-B. (2020). Design deep neural network architecture using a genetic algorithm for estimation of pile bearing capacity. *PLoS One* 15(12), e0243030.
- [16] G. Ke, Qi M. et al (2017). LightGBM: A highly efficient gradient boosting decision tree [C]. 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA
- [17] Retrieved from <https://lightgbm.readthedocs.io/en/latest/Features.html>
- [18] Shi H. (2007). *Best-first decision tree learning*. The University of Waikato, Hamilton, New Zealand.
- [19] Hoang N.-D., Tran X.-L., & Huynh T.-C. (2022). Prediction of Pile Bearing Capacity Using Opposition-Based Differential Flower Pollination-Optimized Least Squares Support Vector Regression (ODFP-LSSVR). *Advances in Civil Engineering (Special Issue - Volume 2022)*. DOI:10.1155/2022/7183700.