

Ứng dụng mạng thần kinh nhân tạo trong dự báo sức chịu tải móng nông

Application of artificial neural network in the forecast the ultimate bearing capacity of shallow foundations

> TS PHẠM TUẤN ANH^[1], TH.S NGUYỄN THANH TÂM^[2]

^[1]Trường Đại học Công nghệ GTVT, Email: Anhpt@utt.edu.vn

^[2]Trường Đại học Thủ đô Hà Nội, Email: nttam@hnmu.edu.vn

TÓM TẮT

Bài báo trình bày kết quả ứng dụng mô hình mạng thần kinh nhân tạo trong việc xác định sức chịu tải móng nông. Một mô hình mạng thần kinh nhân tạo đã được xây dựng và tối ưu kiến trúc bằng thuật toán di truyền để xác định sức chịu tải móng nông. Một bộ số liệu gồm 112 kết quả thí nghiệm sức chịu tải móng nông với các kích thước khác nhau, được sử dụng để đào tạo và kiểm tra mô hình. Kết quả của nghiên cứu được so sánh với mô hình hồi quy tuyến tính, cho thấy mạng thần kinh nhân tạo được tối ưu tốt, cho phép dự đoán sức chịu tải móng nông sát với kết quả thí nghiệm hơn. Kết quả của nghiên cứu là một tiền đề cho việc ứng dụng mạng thần kinh nhân tạo trong việc giải quyết các bài toán khác trong lĩnh vực xây dựng.

Từ khóa: sức chịu tải móng nông; thuật toán di truyền; mạng thần kinh nhân tạo.

ABSTRACT

This paper presents the results of applying an artificial neural network model in determining the load-bearing capacity of shallow foundations. An artificial neural network model has been built and optimized architecture, using genetic algorithms to determine shallow foundation resistance. A dataset consisting of 112 results of shallow foundation load tests with different dimensions is used to train and test the model. The results of the study were compared with the linear regression model, showing that the artificial neural network is well optimized, allowing to predict the shallow foundation load more closely with the experimental results. The results of the study are a premise for the application of artificial neural networks in solving other problems in the field of construction.

Keywords: shallow foundation bearing capacity; genetic algorithm; artificial neural network.

1. ĐẶT VẤN ĐỀ

Các công trình xây dựng dân dụng và công nghiệp có quy mô vừa và nhỏ hiện nay thông thường đều chọn giải pháp móng nông để tiết kiệm chi phí. Giải pháp móng này tương đối đơn giản về mặt thiết kế, thi công, đồng thời giúp giảm thiểu chi phí về kết cấu móng cho các công trình xây dựng. Khi thiết kế móng nông, có hai tiêu chí mà các kỹ sư quan tâm là sức chịu tải cực hạn và độ lún cuối cùng của móng. Trong đó, thông số sức chịu tải cực hạn của móng đã được nhiều nhà khoa học trên thế giới quan tâm nghiên cứu. Sức chịu tải này thường được ước lượng dựa vào khả năng chống cắt của đất dựa trên mặt trượt phá hoại. Có thể kể đến các nghiên cứu như của Terzaghi [9], Vesic [15], Hansen [11] hay Meyerhof [13]. Các nghiên cứu này đều có chung nguyên lý là xem mặt phá hoại là các cung tròn, tùy theo hình dáng các mặt phá hoại mà xác định được các công thức xác định sức chịu tải của móng nông thông qua khả năng chống cắt của đất dọc theo các mặt phá hoại đó. Tuy vậy, do dựa trên nhiều giả thiết gần đúng như giả thiết mặt trượt, giả thiết bỏ qua trọng lượng bản thân đất v.v. dẫn đến việc kết quả thực nghiệm và lý thuyết chưa hoàn toàn phù hợp. Ngoài ra, việc xác định sức chịu tải của móng có thể dựa vào kết quả thực nghiệm.

Để tránh chi phí tốn kém, những thí nghiệm trong phòng được tiến hành với móng có kích thước thu nhỏ (kích thước móng khoảng vài cm), sau đó ngoại suy cho móng có kích thước thật. Tuy vậy, nhiều nghiên cứu cho thấy rằng sẽ có những sai lệch khi ngoại suy sức chịu tải từ những móng nhỏ cho móng kích thước lớn. Lý do là bởi tỷ lệ kích thước hạt so với bề rộng móng là không giống nhau trong các trường hợp [2].

Khoảng 2 thập kỷ vừa qua, các tiến bộ về trí tuệ nhân tạo đã tạo ra các bước tiến mạnh mẽ trong mọi lĩnh vực nghiên cứu nói chung và trong địa kỹ thuật nói riêng. Có thể kể đến Phạm và các cộng sự (2020) [7], Lee (1996) [5], Momeni và cộng sự [14] đã sử dụng mô hình ANN và RF để nghiên cứu tính toán sức chịu tải của cọc. Al-hamed và cộng sự (2014) [10] sử dụng mô hình ANN để dự đoán góc ma sát trong của đất. Habib Shahnazari và Mohammad A. Tutunchian (2012) [8] sử dụng thuật toán di truyền để xây dựng công thức hồi quy để xác định sức chịu tải cực hạn của móng nông. Baginska (2019) [3] tìm cách tối ưu các tham số của mô hình ANN bằng cách khảo sát nhiều trường hợp khác nhau nhằm dự báo sức chịu tải của móng nông.

Các nghiên cứu kể trên cho thấy tính khả thi khi áp dụng các mô hình máy học vào giải quyết các bài toán địa kỹ thuật. Các phân tích

trên đã cho thấy được các điểm hạn chế của các phương pháp truyền thống cũng như các ưu điểm của phương pháp máy học, ứng dụng trí tuệ nhân tạo. Tuy vậy, việc tối ưu và chính xác hóa mô hình trong địa kỹ thuật vẫn còn nhiều hạn chế. Ngoài ra, với kiến trúc mô hình phức tạp với rất nhiều tham số, việc tìm kiếm một kiến trúc tối ưu cho mạng thần kinh học sâu để đạt được hiệu suất cao trong việc dự đoán sức chịu tải của móng nông là một thách thức chưa được giải quyết triệt để. Việc ứng dụng trí tuệ nhân tạo trong giải quyết các vấn đề phức tạp nói chung và các bài toán địa kỹ thuật nói riêng đang là một xu thế tất yếu tại Việt Nam và trên thế giới.

2. CÁC THUẬT TOÁN SỬ DỤNG TRONG NGHIÊN CỨU.

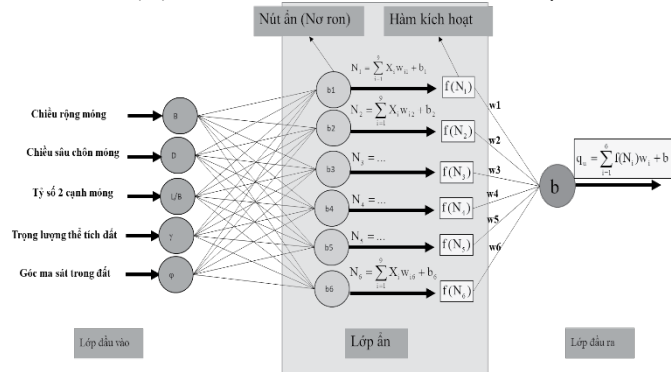
2.1. Mô hình mạng thần kinh nhân tạo

Mô hình mạng thần kinh nhân tạo là một trong những thuật toán phổ biến nhất và mạnh mẽ nhất trong họ các thuật toán máy học. Mô hình này được đề xuất bởi McCulloch và Pitts (1943) [6]. Trải qua quá trình phát triển và hoàn thiện, ngày nay, mạng thần kinh nhân tạo đã phát triển vượt bậc và được ứng dụng trong mọi lĩnh vực của khoa học kỹ thuật. Mô hình điển hình của mạng thần kinh nhân tạo điển hình được thể hiện trên Hình 1.

Có thể thấy, mô hình mạng thần kinh nhân tạo là một mạng lưới mô phỏng hoạt động của não bộ con người. Mô hình này bao gồm các nút được liên kết với nhau bằng các trọng số. Một mạng thần kinh nhân tạo điển hình gồm ít nhất 3 lớp: lớp đầu vào, lớp ẩn và lớp đầu ra. Tín hiệu đầu ra của một nút ẩn thứ j bất kỳ trong mạng được tính như sau:

$$N_j = f\left(\sum_{i=1}^n X_i w_{ij} + b_j\right) \quad (1)$$

Trong đó, N_j là đầu ra của một nút; X_i là biến đầu vào thứ i; w_{ij} là trọng số kết nối giữa biến đầu vào i và nút j; b_j là độ lệch của nút j và $f()$ là hàm kích hoạt của nút ẩn; w_j là trọng số kết nối nút ẩn j và đầu ra; b là độ lệch của nút đầu ra; n là số nút ẩn của lớp.



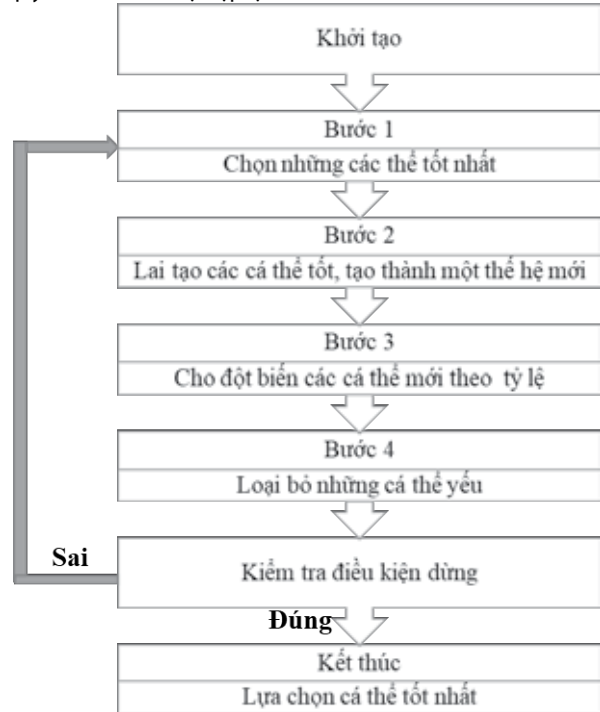
Hình 1. Sơ đồ thuật toán mạng thần kinh nhân tạo 1 lớp ẩn, 6 nút ẩn và 1 nút đầu ra

Mạng thần kinh nhân tạo có khả năng biểu diễn mối quan hệ phi tuyến giữa lớp đầu vào và đầu ra, thông qua các hàm kích hoạt phi tuyến của nút ẩn, các hàm kích hoạt thông dụng cho mạng thần kinh nhân tạo là relu, tanh và sigmoid. Thông thường, mạng thần kinh nhân tạo cần phải được đào tạo trước khi có thể sử dụng, việc đào tạo là quá trình khá phức tạp tối ưu các trọng số và độ lệch của mô hình, giúp mô hình khái quát quá được quan hệ giữa các biến đầu vào và đầu ra. Trong nghiên cứu này, giải thuật đào tạo được sử dụng là thuật toán lan truyền ngược. Trong đó, sai số được truyền ngược từ lớp đầu ra đến lớp đầu vào và được giảm dần thông qua các bước lặp.

2.2. Thuật toán di truyền

Thuật toán di truyền là một thuật toán nằm trong họ thuật toán tiến hóa được giới thiệu lần đầu bởi Holland (1992) [4]. Thuật toán này sử dụng học thuyết tiến hóa của Darwin làm nền tảng. Thuật toán cho

phép tối ưu các hàm đa biến bằng cách xem xét các biến số của hàm như là các nhiễm sắc thể của một quần thể. Quần thể này liên tục tiến hóa qua các thế hệ, bằng cách lựa chọn những gen tốt nhất và truyền lại cho thế hệ sau. Những cá thể yếu sẽ bị đào thải ra khỏi quần thể để các gen của nó không thể tiếp tục được di truyền. Về tổng quan, thuật toán di truyền trải qua các vòng lặp (gọi là các thế hệ), và trong mỗi thế hệ, quy trình sau sẽ được lặp lại (Hình 2):



Hình 2. Sơ đồ thuật toán di truyền

Trong nghiên cứu này, các tham số liên quan đến kiến trúc mô hình mạng thần kinh nhân tạo, được coi là các gen của quần thể. Cá thể có gen tốt nhất ở thế hệ cuối cùng sẽ được sử dụng như mô hình tốt nhất, được sử dụng để đào tạo và kiểm chứng.

2.3. Dữ liệu đầu vào cho bài toán

Trong nghiên cứu này, dữ liệu được sử dụng để đào tạo và thử nghiệm mô hình mạng thần kinh nhân tạo được thu thập từ các tài liệu có độ tin cậy cao, bao gồm dữ liệu thử tải trên nền móng thực, cũng như các thông tin tương ứng liên quan đến móng và đất. Cơ sở dữ liệu chứa 112 bộ dữ liệu, bao gồm các móng có kích thước và hình dạng khác nhau được thử nghiệm thử tải trong các lớp cát có tính chất khác nhau do Kohenstani (2017) [12] tổng hợp. Các tham số đầu vào được chọn theo các khuyến cáo của các công trình nghiên cứu đã có như: TCVN 9386:2012 [1], và các nghiên cứu đã khuyến nghị [9], [15], [11]. Cụ thể hơn, các thông số đầu vào bao gồm chiều rộng móng (B , m), chiều sâu chôn móng (D , m), tỷ lệ chiều dài trên chiều rộng móng (L/B), trọng lượng đơn vị của đất (γ , kN/m³) và góc nội ma sát của đất (ϕ , °). Khả năng chịu lực cực hạn của móng (q_u , kPa) là giá trị dự đoán đầu ra duy nhất. Tập dữ liệu được minh họa qua các thông số thống kê được thể hiện trong Bảng 1. Có thể thấy rằng chiều rộng móng thay đổi trong phạm vi rộng móng có kích thước thu nhỏ đến móng có kích thước lớn, cụ thể B thay đổi từ 0,03m đến 3 m. Chiều sâu chôn móng cũng thay đổi từ 0 đến 0,89m. Tỷ lệ L/B dao động từ 1 đến 6. Trọng lượng đơn vị thay đổi từ 9,85 kN/m³ đến 17,2 kN/m³ và góc ma sát thay đổi trong phạm vi nhỏ, từ 32 đến 44,8 (°). Trong khi đó, khả năng chịu lực cực hạn của móng thay đổi từ 14 đến 2847 kPa.

Bảng 1. Thống kê các thông số về móng và đất sử dụng trong nghiên cứu

Thông số	B	D	L/B	γ	φ	qu
Đơn vị	(m)	(m)	-	(kN/m ³)	(°)	(kPa)
Số mẫu	112	112	112	112	112	112
Nhỏ nhất	0.03	0.00	1.00	9.85	32.00	14.00
Trung bình	0.36	0.14	2.82	14.47	38.99	402.33
Lớn nhất	3	0.89	6.00	17.20	44.80	2847
Độ lệch chuẩn	0.49	0.19	2.12	2.58	3.39	504.31

Với các kỹ thuật máy học và trí tuệ nhân tạo, bộ dữ liệu cần được phân chia ngẫu nhiên thành 2 phần với tỷ lệ được lựa chọn là 75/25%. Trong đó, phần 75% được sử dụng để đào tạo mô hình và phần 25% dùng để kiểm tra độ chính xác của mô hình. Phần kiểm tra 25% được ẩn đi khỏi quá trình đào tạo, hiệu chỉnh mô hình và chỉ được sử dụng ở bước đánh giá cuối cùng.

2.4. Các chỉ tiêu hiệu suất Trong nghiên cứu này, các chỉ tiêu hiệu suất gồm hệ số tương quan bình phương (R²), lỗi bình phương trung bình gốc (RMSE) được sử dụng để đánh giá và so sánh các mô hình, cụ thể như sau:

$$RMSE = \sqrt{\frac{1}{k} \sum_{i=1}^k (y_i - \bar{y}_i)^2} \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^k (y_i - \bar{y}_i)^2}{\sum_{i=1}^k (y_i - \bar{y})^2} \quad (3)$$

Với, k là số lượng mẫu dữ liệu, y_i và \bar{y}_i là kết quả dự báo theo thí nghiệm và theo mô hình, \bar{y} là giá trị trung bình của y_i.

Cụ thể, R² đặc trưng cho tương quan giữa 2 kết quả tính. R² càng gần đến 1, hai kết quả tính càng sát nhau. RMSE đặc trưng cho sai số trung bình giữa 2 kết quả, RMSE càng nhỏ, độ chính xác dự đoán càng cao. Một mô hình được coi là tốt hơn khi đồng thời đảm bảo tốt cả hai tiêu chí này.

3. KẾT QUẢ TÍNH TOÁN

3.1. Kết quả tối ưu mạng thần kinh nhân tạo bằng thuật toán di truyền

Trong phần này, thuật toán di truyền được sử dụng để tối ưu kiến trúc của mạng thần kinh nhân tạo. Hình 2 thể hiện cấu tạo của một nhiệm sắc thể điển hình trong quần thể. Có thể thấy rằng, nhiệm sắc thể này có độ dài 5 gen, mỗi gen ứng với một tham số kiến trúc của mạng thần kinh nhân tạo.



Hình 3. Cấu tạo nhiệm sắc thể và gen trong thuật toán di truyền

Nghiên cứu này lựa chọn 5 tham số quan trọng nhất của kiến trúc mạng là: số nơ ron ẩn, thuật toán đào tạo, hàm kích hoạt, tốc độ học tập và số chu kì đào tạo. Tất cả ý nghĩa tham số cũng như khoảng giá trị được đề cập trong Bảng 2. Có thể thấy rằng, nếu lựa chọn thủ công các tham số, số lượng mô hình cần kiểm tra có thể lên đến hàng nghìn trường hợp. Điều này gây tốn kém về mặt thời gian và tài nguyên để thực hiện. Trong trường hợp này, thuật toán di truyền cho phép tìm kiếm được mô hình tốt với thời gian và tài nguyên ít hơn nhiều.


Bảng 2. Bảng giá trị các tham số mô hình

Tham số	Giải thích	Khoảng giá trị
Số nơ ron ẩn	Số lượng nút ẩn trong mạng	2÷100
Thuật toán đào tạo	Thuật toán sử dụng để tối ưu	Quasi-Newton, SGD, Adam
Hàm kích hoạt	Kiểu hàm kích hoạt của nút ẩn	'sigmoid', 'tanh', 'relu'
Tốc độ học tập	Hệ số khởi tạo tốc độ đào tạo của lan truyền ngược	0.001, 0.01, 0.1, 0.2, 0.3
Số chu kì	Số chu kì đào tạo mạng	1000, 2000, 3000, 4000

Trong quá trình tối ưu tham số mô hình bằng thuật toán di truyền, số lượng cá thể tối đa trong quần thể được lựa chọn từ đầu là 100 cá thể. Số lượng thế hệ đào tạo được khống chế sao cho sau 15 thế hệ, hiệu suất không được cải thiện thì coi như kết quả đã hội tụ và tiến hành dừng vòng lặp. Thống kê các thông số khởi tạo của thuật toán di truyền thể hiện trên Bảng 3. Thuật toán này sử dụng kỹ thuật xác thực chéo 5 lần trên tập đào tạo để đánh giá hiệu suất thay vì tập kiểm nghiệm. Điều này nhằm giúp ẩn đi tập kiểm nghiệm trong quá trình tối ưu, coi nó như một tập dữ liệu mới, chưa từng được tiếp cận với mô hình nhằm tránh hiện tượng quá khớp (overfitting). Tập kiểm nghiệm chỉ được sử dụng để đánh giá hiệu suất của mô hình cuối cùng được chọn. Kết quả tối ưu bằng thuật toán di truyền thể hiện trên Hình 3 và tổng hợp các tham số trong Bảng 4.

Bảng 3. Tham số của thuật toán di truyền

Tham số	Giá trị
Số cá thể	100
Tỷ lệ giao phối	50%
Tỷ lệ đột biến	20%
Số thế hệ	Dừng sau 15 thế hệ không cải thiện hiệu suất
Tập dữ liệu	5 Fold CV/Tập đào tạo.
Tiêu chí đánh giá	R ²



Hình 4. Kết quả chạy tối ưu kiến trúc mạng thần kinh nhân tạo bằng thuật toán di truyền.

Bảng 4. Các tham số tối ưu của mô hình


Tham số	Giá trị
Số nơ ron ẩn	23
Thuật toán đào tạo	Quasi-Newton
Hàm kích hoạt	Relu
Tốc độ học tập	0.01
Số chu kì	2000

Nhận xét: Có thể thấy rằng, quá trình tối ưu hội tụ ở khoảng thế hệ 27, với tiêu chí R² đạt 0.903 trên tập xác thực chéo 5 lần. Giá trị này không đổi cho đến thế hệ 50, thỏa mãn điều kiện dừng của thuật toán. Thuật toán đào tạo phù hợp nhất cho dữ liệu này là thuật toán Quasi-Newton, số nơ ron ẩn không cần quá nhiều để mô hình đạt được độ chính xác tốt. Mô hình này sẽ được sử dụng để đánh giá hiệu suất ở phần tiếp theo.


3.2. Khả năng dự báo của mô hình

Mô hình mạng thần kinh nhân tạo, với các tham số kiến trúc mô hình tối ưu tìm được ở phần trước, được đào tạo trên tập huấn luyện, và sau đó được đánh giá hiệu quả trên tập kiểm nghiệm. Kết quả của quá trình đào tạo, sử dụng hàm mất mát là hàm sai số bình


phương trung bình (MSE), được thể hiện trên Hình 4. Có thể thấy sau khoảng 2000 chu kỳ đào tạo, kết quả đã khá hội tụ tại giá trị MSE = 30568 (kPa)



Hình 5. Đường cong lỗi trung bình của mô hình trong quá trình đào tạo
 Kết quả hồi quy dự đoán sức chịu tải cọc của mạng thần kinh nhân tạo trên tập huấn luyện và tập kiểm tra thể hiện trên Hình 3 và mô phỏng kết quả dự đoán trên hình Hình 3.



Hình 6. Kết quả hồi quy dự đoán của mô hình mạng TKNT



Hình 7. Mô phỏng kết quả dự đoán của mạng thần kinh nhân tạo
 Nhận xét: Kết quả phân tích cho thấy, mô hình mạng thần kinh nhân tạo dự đoán chính xác sức chịu tải cọc. Cụ thể, với tập huấn luyện, chỉ tiêu R² = 0,868 và RMSE = 640.672 kN. Với tập kiểm tra, chỉ tiêu R² = 0,911 và RMSE = 912.64 kN.

3.3. So sánh kết quả tính với mô hình hồi quy tuyến tính. Trong phần này, kết quả tính của mô hình mạng thần kinh nhân tạo được so sánh với kết quả tính theo hồi quy tuyến tính. Hồi quy tuyến tính là một trong những mô hình phổ biến nhất của xác suất thống kê và đã thể hiện được hiệu quả tốt trong rất nhiều nghiên cứu trước đó. Công thức tổng quát của hồi quy tuyến tính có thể được thể hiện qua công thức sau:


$$y_i = f(x_{1i}, x_{2i}, \dots, x_{6i}) = \sum_{j=1}^6 \beta_j \cdot x_{ji} + \beta_0 \quad (4)$$

Trong đó, β_j là hệ số của biến đầu vào j và β_0 là hệ số tự do.

Tiêu chí lỗi bình phương cực tiểu thường được sử dụng để tìm ra các hệ số tối ưu cho mô hình hồi quy tuyến tính, tiêu chí đó được thể hiện qua công thức sau:

$$S = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \rightarrow \min \quad (5)$$

Trong đó, S là tổng bình phương sai số; n là số lượng dữ liệu đào tạo; y_i là giá trị dự đoán và \hat{y}_i là giá trị thực.



Hình 8. Mô phỏng kết quả dự đoán theo mô hình hồi quy tuyến tính
 Trong nghiên cứu này, thuật toán di truyền là thuật toán được sử dụng để tối ưu các hệ số của mô hình hồi quy tuyến tính. Kết quả

của quá trình tối ưu được thể hiện trong Bảng 5. Kết quả hồi quy của mô hình được thể hiện trên Hình 8.

Bảng 5. Các hệ số tối ưu của mô hình hồi quy tuyến tính

Số hạng tự do	B	D	L/B	γ	ϕ
-205.81	-50.48	1909.98	-15.34	-255.65	878.78

Bảng 6. So sánh kết quả giữa hai phương pháp

Tập dữ liệu	Tiêu chí	Mạng thần kinh nhân tạo	Hồi quy tuyến tính	Chênh lệch
Đào tạo	R ²	0,996	0,772	29,02%
	RMSE (kPa)	31,018	270,713	88,54%
Kiểm tra	R ²	0,981	0,594	65,15%
	RMSE (kPa)	49,31	228,907	78,46%

Nhận xét: Kết quả so sánh giữa hai phương pháp được thể hiện trên Bảng 6. Có thể thấy rằng, mô hình hồi quy tuyến tính dự đoán sức chịu tải của móng nông khá tốt, cụ thể R² = 0,772; RMSE = 270,713 (kPa) trên tập huấn luyện và R² = 0,594; RMSE = 228,907 (kPa) trên tập kiểm tra. Tuy vậy, khả năng dự đoán của mô hình mạng thần kinh nhân tạo lại cho thấy độ chính xác vượt trội khi đạt trên 0.98 với tiêu chí R² ở cả 2 tập dữ liệu. Ngoài ra, nếu dựa trên tiêu chí RMSE, độ chính xác mô hình mạng thần kinh nhân tạo cũng cho thấy lỗi thấp khi đều đạt dưới 50 (kPa).

4. KẾT LUẬN VÀ KIẾN NGHỊ

Bài báo đã trình bày việc ứng dụng mô hình mạng thần kinh nhân tạo để xác định sức chịu tải cực hạn của móng nông. Kiến trúc mô hình được tối ưu bằng thuật toán di truyền, điều này cho phép tiết kiệm thời gian và tài nguyên để tìm được mô hình tốt so với giải pháp tìm kiếm thủ công. Kết quả tối ưu cho thấy, mạng thần kinh nhân tạo với 23 nút ẩn và sử dụng hàm kích hoạt relu sẽ có tiềm năng tốt cho việc dự đoán sức chịu tải cực hạn của móng nông. Ngoài ra, mô hình mạng thần kinh nhân tạo cho kết quả vượt trội so với kết quả tính theo hồi quy tuyến tính. Trên cơ sở kết quả tính toán, kiến nghị nên nghiên cứu đưa mô hình mạng thần kinh nhân tạo đã được tối ưu vào các tiêu chuẩn nền móng để đạt độ chính xác cao hơn trong thiết kế thực tế.

TÀI LIỆU THAM KHẢO

- TCVN 9362-2012 (2012), *Tiêu chuẩn thiết kế nền nhà và công trình*.
- Tatsuoka F., Okahara M., Tanaka T. và cộng sự. (1991). Progressive Failure and Particle Size Effect in Bearing Capacity of a Footing on Sand. *ASCE*, 788-802.
- Bagiriska M. và Srokoz P.E. (2019). The Optimal ANN Model for Predicting Bearing Capacity of Shallow Foundations trained on Scarce Data. *KSCE J Civ Eng*, **23**(1), 130-137.
- Holland J.H., Holland P. of P. and of E.E. and C.S.J.H., và Holland S.L. in H.R.M. (1992), *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*, MIT Press.
- Lee I.-M. và Lee J.-H. (1996). Prediction of pile bearing capacity using artificial neural networks. *Computers and Geotechnics*, **18**(3), 189-200.
- McCulloch W.S. và Pitts W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, **5**(4), 115-133.
- Pham T.A., Ly H.-B., Tran V.Q. và cộng sự. (2020). Prediction of Pile Axial Bearing Capacity Using Artificial Neural Network and Random Forest. 21.
- Shahnazari H. và Tutunchian M.A. (2012). Prediction of ultimate bearing capacity of shallow foundations on cohesionless soils: An evolutionary approach. *KSCE J Civ Eng*, **16**(6), 950-957.
- Terzaghi, K (2007). Bearing Capacity. *Theoretical Soil Mechanics*. John Wiley & Sons, Ltd, 118-143.
- Al-Hamed S.A., Wahby M.F., và Aboukarima A.M. (2014). Artificial neural network for soil cohesion and soil internal friction angle prediction from soil physical properties data.
- HANSEN J. Brinch (1961). A general formula for bearing capacity. *Danish Geotechnical Institute, Bulletin*, **11**, 38-46.
- Kohestani V.R., Vosoghi M., Hassanlourad M. và cộng sự. (2017). Bearing capacity of shallow foundations on cohesionless soils: A random forest based approach. *Civil Engineering Infrastructures Journal*, **50**(1), 35-49.
- Meyerhof G.G. (1963). Some Recent Research on the Bearing Capacity of Foundations. *Can Geotech J*, **1**(1), 16-26.
- Momeni E., Nazir R., Armaghani D.J. và cộng sự. (2015). Application of Artificial Neural Network for Predicting Shaft and Tip Resistances of Concrete Piles. *Earth Sciences Research Journal*, **19**(1), 85-93.
- VESIC A.S. (1975). Bearing Capacity of Shallow Foundations. *Foundation Engineering Handbook*.