

NGHIÊN CỨU SỬ DỤNG MÔ HÌNH HỌC MẠNG THẦN KINH NHÂN TẠO DỰ BÁO VÀ NGHIÊN CỨU CƯỜNG ĐỘ CHỊU NÉN CỦA ĐẤT GIA CỐ XI MĂNG

Nguyễn Hữu Năm

Viện Thủy điện và Năng lượng tái tạo

Nguyễn Quang Phú

Trường Đại học Thủy lợi

Nguyễn Tiếp Tân

Viện Khoa học Thủy lợi Việt Nam

Tóm tắt: Nghiên cứu này ứng dụng Mạng Thần Kinh Nhân Tạo (ANN) trong việc dự đoán cường độ chịu nén không hạn chế (UCS) của đất gia cố xi măng. UCS bị ảnh hưởng bởi nhiều yếu tố như thành phần đất, hàm lượng xi măng và các điều kiện môi trường. Các phương pháp thực nghiệm truyền thống để xác định UCS thường tốn nhiều thời gian và chi phí, dẫn đến sự quan tâm ngày càng tăng đối với các phương pháp học máy. Trong nghiên cứu này, một mô hình ANN được phát triển dựa trên tập dữ liệu gồm 50 mẫu với 9 biến đầu vào: hàm lượng hữu cơ, hạt cát, hạt bụi, hạt sét, hạt cuội, giới hạn chảy, giới hạn dẻo, chỉ số dẻo và hàm lượng xi măng. Tập dữ liệu được chia thành 70% dùng để huấn luyện và 30% để kiểm chứng. Cấu trúc ANN tối ưu bao gồm hai lớp ẩn với lần lượt 4 và 3 nơ ron, đã dự đoán chính xác các giá trị UCS. Mô hình đạt độ chính xác cao với hệ số R^2 là 0.9545 đối với tập huấn luyện và 0.9212 đối với tập kiểm chứng. Phân tích SHAP đã chỉ ra rằng hàm lượng xi măng, giới hạn chảy và chỉ số dẻo là các biến có ảnh hưởng lớn nhất đến dự đoán UCS. Mô hình ANN này cung cấp một phương pháp hiệu quả và tiết kiệm chi phí trong việc dự đoán UCS cho đất gia cố xi măng, giúp tối ưu hóa các dự án hạ tầng liên quan đến gia cố đất yếu.

Từ khóa: Mạng thần kinh nhân tạo (ANN), cường độ chịu nén, đất gia cố xi măng, học máy

Summary: This study explores the application of Artificial Neural Networks (ANN) in predicting the unconfined compressive strength (UCS) of cement-stabilized soil. UCS is influenced by various factors, including soil composition, cement content, and environmental conditions. Traditional experimental methods for determining UCS are time-consuming and costly, leading to a growing interest in machine learning approaches. In this research, an ANN model was developed using a dataset of 50 samples with 9 input variables: organic content, sand, silt, clay, gravel content, liquid limit, plastic limit, plasticity index, and cement content. The dataset was split into 70% for training and 30% for testing. The optimal ANN architecture, consisting of two hidden layers with 4 and 3 neurons respectively, accurately predicted UCS values. The model achieved high accuracy, with an R^2 of 0.9545 for the training set and 0.9212 for the testing set. SHAP analysis identified cement content, liquid limit, and plasticity index as the most influential variables in UCS prediction. The ANN model provides an efficient and cost-effective method for predicting UCS in cement-stabilized soils, making it a valuable tool for infrastructure projects involving weak soil stabilization.

Keywords: Artificial Neural Networks (ANN), Unconfined Compressive Strength (UCS), Cement-stabilized soil, Machine learning.

1. ĐẶT VẤN ĐỀ

Trong các công trình xây dựng hạ tầng và kỹ thuật, việc gia cố đất yếu bằng xi măng là một giải pháp phổ biến nhằm cải thiện tính chất cơ lý của đất, đặc biệt là cường độ chịu nén. Cường độ chịu

nén của đất gia cố xi măng phụ thuộc vào nhiều yếu tố như thành phần đất, tỷ lệ xi măng, độ ẩm, thời gian dưỡng hộ và môi trường xung quanh. Tuy nhiên, việc dự đoán chính xác cường độ chịu nén của đất gia cố xi măng dựa trên các thông số

Ngày nhận bài: 03/10/2024

Ngày thông qua phản biện: 06/11/2024

Ngày duyệt đăng: 16/11/2024

này không hề đơn giản, do sự phức tạp và tính biến thiên cao của các yếu tố ảnh hưởng.

Trước đây, các phương pháp thực nghiệm truyền thống được sử dụng để đánh giá cường độ chịu nén, nhưng những phương pháp này thường đòi hỏi thời gian và chi phí lớn.

Gần đây, sự phát triển của các mô hình học máy, đặc biệt là mạng thần kinh nhân tạo (Artificial Neural Networks - ANN), đã mở ra một hướng nghiên cứu mới trong việc dự đoán các đặc tính cơ lý của vật liệu. ANN có khả năng xử lý các dữ liệu phức tạp và phi tuyến tính, giúp xây dựng các mô hình dự báo chính xác và linh hoạt hơn. Trong thực tế nhiều mô hình học máy đã được áp dụng trong nghiên cứu dự đoán các tính chất cơ học của vật liệu xây dựng. Các mô hình học máy (ML) đã trở nên phổ biến rộng rãi trong nhiều lĩnh vực của cuộc sống trong vài thập kỷ qua, nhờ sự phát triển nhanh chóng của công nghệ trí tuệ nhân tạo [1], [2]. Nhiều vấn đề phức tạp trong kỹ thuật dân dụng, chẳng hạn như kỹ thuật kết cấu [3], [4], [5], kỹ thuật địa kỹ thuật [1], [6], [7] và khoa học vật liệu [8], [9], [10] đã được giải quyết một cách hiệu quả bằng các phương pháp học máy. Trong nghiên cứu về bê tông, nhiều phương pháp AI đã được sử dụng để ước tính hệ số khuếch tán clorua, chẳng hạn như mô hình di truyền đa gen [11] và mạng nơ-ron nhân tạo (ANN) [12], [13], [14], [15]. Hầu hết các nghiên cứu đều phát triển các mô hình ANN để dự đoán hệ số khuếch tán clorua của bê tông. Ngoại trừ nghiên cứu của Liu và cộng sự [13], các nghiên cứu khác đã dự đoán hệ số khuếch tán clorua cho các loại bê tông thông thường, bê tông hiệu suất cao và bê tông tự đầm, với số lượng

dữ liệu dao động từ 72 đến 270 mẫu. Nghiên cứu của Liu và cộng sự [13] đã sử dụng 653 mẫu để xây dựng các mô hình ANN nhằm dự đoán hệ số khuếch tán clorua của bê tông có chứa các phụ gia khoáng khác nhau.

Vì vậy, việc áp dụng mô hình mạng thần kinh nhân tạo để dự báo cường độ chịu nén của đất gia cố xi măng có ý nghĩa thực tiễn cao. Không chỉ giúp tối ưu hóa quá trình gia cố mà còn giảm thiểu chi phí và thời gian thử nghiệm. Nghiên cứu này hướng đến việc xây dựng và đánh giá mô hình ANN dựa trên các thông số về thành phần vật liệu, điều kiện gia cố và dưỡng hộ, từ đó dự báo chính xác cường độ chịu nén của đất gia cố xi măng. Mục tiêu nghiên cứu là ứng dụng mô hình học máy (ANN) để phát triển một công cụ hỗ trợ dự báo nhanh chóng và hiệu quả cho quá trình thiết kế và kiểm soát chất lượng trong công tác gia cố đất yếu bằng xi măng.

2. MÔ TẢ CƠ SỞ DỮ LIỆU

Trong nghiên cứu này, bộ dữ liệu dùng cho việc xây dựng mô hình học máy bao gồm 50 mẫu cường độ chịu nén sau 28 ngày của đất gia cố bằng xi măng cùng với 9 biến đầu vào bao gồm Hàm lượng hữu cơ, Hạt cát, Hạt bụi, Hạt sét, Hạt cuội, Giới hạn chảy, Giới hạn dẻo, Chỉ số dẻo, Hàm lượng xi măng sử dụng. 50 mẫu này được thu thập từ nghiên cứu trước đó của Gajurel et al. [16]. Giá trị thống kê của các biến này bao gồm giá trị trung bình, giá trị nhỏ nhất, phân vị 25%, giá trị trung vị, phân vị 75% và giá trị lớn nhất của bộ dữ liệu được mô tả chi tiết trong Bảng 1. Bảng 1 thống kê mô tả của các yếu tố đầu vào liên quan đến nghiên cứu cường độ chịu nén của đất gia cố xi măng (UCS):


Bảng 1: Giá trị thống kê của các biến bao gồm 3 biến đầu vào và 1 biến đầu ra

	Đơn vị	Trung bình	Độ lệch chuẩn	Min	Phân vị 25%	Trung vị	Phân vị 75%	Max
Hàm lượng hữu cơ	%	0.2	0.4	0.0	0.0	0.1	0.2	1.5
Hạt cát	%	28.3	27.1	0.0	6.0	24.0	32.0	94.0
Hạt bụi	%	26.8	24.5	2.0	10.0	19.0	29.5	81.0
Hạt sét	%	33.5	26.4	0.0	11.3	20.0	48.0	82.0
Hạt cuội	%	11.6	23.2	0.0	0.0	0.0	0.0	70.0

	Đơn vị	Trung bình	Độ lệch chuẩn	Min	Phân vị 25%	Trung vị	Phân vị 75%	Max
Giới hạn chảy	%	39.4	18.7	19.0	23.5	33.0	49.5	87.0
Giới hạn dẻo	%	19.5	9.1	0.0	16.0	20.0	26.0	35.0
Chỉ số dẻo	%	17.5	16.1	0.0	3.5	13.0	28.0	53.0
Hàm lượng xi măng	%	7.0	4.2	1.0	4.0	6.0	10.0	16.0
UCS	MPa	2.1	1.3	0.4	1.2	1.8	2.7	7.1

Hàm lượng hữu cơ có mức trung bình rất thấp (0.2%) và độ lệch chuẩn nhỏ, cho thấy hầu hết các mẫu có hàm lượng hữu cơ gần bằng 0. Hàm lượng cát, hạt bụi, và hạt sét có giá trị trung bình tương đối lớn, với sự phân tán khá cao, đặc biệt là cát và sét. Hàm lượng xi măng trung bình là 7%, với khoảng biến động từ 1% đến 16%.

Cường độ chịu nén (UCS) có trung bình 2.1 MPa, với độ lệch chuẩn là 1.3 MPa, biến động từ 0.4 MPa đến 7.1 MPa. Bảng này cung cấp một cái nhìn tổng quan về tính chất cơ học và thành phần của đất gia cố xi măng, giúp hiểu rõ hơn về các yếu tố ảnh hưởng đến cường độ chịu nén (UCS).



Hình 1: Tương quan phân cụm giữa các biến đầu vào và cường độ chịu nén của đất gia cố

Hình 1 mô tả tương quan phân cụm giữa các biến đầu vào và cường độ chịu nén của đất gia cố liên quan đến việc phân tích mối quan hệ giữa các yếu tố đầu vào (như hàm lượng xi măng, độ ẩm, kích thước hạt) và cường độ chịu nén của đất sau khi gia cố bằng xi măng. Mục đích là tìm ra các nhóm biến có liên quan chặt chẽ với nhau hoặc tác động mạnh đến cường độ chịu nén của đất. Trong phân cụm dữ liệu: Correlation distance có thể được sử dụng trong các thuật toán phân cụm như K-means hoặc hierarchical clustering để nhóm các đối tượng dựa trên mối quan hệ tương quan giữa chúng. Có thể thấy ngoại trừ hàm lượng xi măng có tương quan tương đối mạnh với cường độ chịu nén của đất gia cố bằng xi măng.

3. THUẬT TOÁN HỌC MÁY MẠNG THẦN KINH NHÂN TẠO (ANN)

Mô hình toán học của mạng ANN truyền thẳng được trình bày như sau:


$$y(x) = f\left(\sum_{i=1}^n w_i x_i\right) \quad (1)$$

Trong đó: $y(x)$: giá trị đầu ra theo biến x

f : hàm kích hoạt hay hàm truyền

w_i : trọng số liên kết của nơ ron x_i

x_i : các giá trị đầu vào



Hình 2: Mô hình cơ chế hoạt động của mạng ANN

Nguyên lý hoạt động của mạng nơ-ron truyền thẳng chủ yếu dựa trên quá trình huấn luyện, trong đó thuật toán lan truyền ngược thường được sử dụng để tính toán đạo hàm của từng tham số trong mạng. Trong quá trình này, mạng sẽ được huấn luyện cho đến khi nó có thể phân biệt tất cả các mẫu hoặc khi mức sai số đạt ngưỡng yêu cầu. Tổng sai số của mạng được tính bằng cách cộng các sai số qua từng lần huấn luyện. Nói cách khác, mạng liên tục học từ các mẫu và điều chỉnh trọng số cho đến khi tổng sai số giảm xuống dưới giá trị mục tiêu đã đặt.

Khi tính toán tổng sai số để xác định điều kiện dừng, các sai số phải được chuyển thành giá trị dương. Sau khi hoàn thành quá trình huấn luyện, mạng sẽ có khả năng nhận diện không chỉ các mẫu hoàn hảo mà còn cả những mẫu bị nhiễu hoặc lỗi. Để nâng cao khả năng chống nhiễu, người ta có thể cố ý thêm vào tập dữ liệu huấn luyện các mẫu bị nhiễu. Hiệu quả của quá trình huấn luyện được cải thiện nếu các mẫu được xáo trộn ngẫu nhiên.

Khi mạng đạt đến mức huấn luyện tối ưu, sai số trên tập hợp kiểm tra sẽ đạt mức tối thiểu. Tuy nhiên, nếu tiếp tục huấn luyện quá mức, sai số trên tập kiểm tra sẽ tăng lên, dẫn đến hiện tượng mạng nơ-ron mất khả năng xử lý tốt dữ liệu mới hoặc nhiễu.



4. KẾT QUẢ DỰ ĐOÁN CƯỜNG ĐỘ CHỊU NÉN CỦA ĐẤT GIA CỐ BẰNG XI MĂNG

Bộ dữ liệu gồm 50 mẫu sẽ được chia theo tỷ lệ 70%/30% cho 2 tập tương ứng là tập dữ liệu huấn luyện và tập dữ liệu kiểm chứng. Tập dữ liệu kiểm chứng sẽ giúp thuật toán ANN xây dựng mô hình học máy ANN bao gồm số lớp ẩn và số nơ ron trong một lớp ẩn dựa trên các giá trị mặc định của siêu tham số có sẵn trong thư viện Sklearn [17]. Tập dữ liệu kiểm chứng giúp xác đánh giá độ chính xác của mô hình học máy được xây dựng.

Sau các vòng lặp lựa chọn 1 và 2 lớp ẩn với mỗi lớp ẩn lựa chọn từ 1 đến 9 nơ ron bằng số biến

đầu vào, tổng số các trường hợp là 9 trường hợp 1 lớp ẩn và 81 trường hợp cho 2 lớp ẩn, 90 trường hợp đã được đưa vào mô phỏng, kết quả cho thấy số lớp ẩn là 2 với lớp ẩn 1 có 4 nơ ron và lớp ẩn 2 có 3 nơ ron. Cùng đó là hàm activation sử dụng là relu, phương pháp giải gần

đúng Newton 'lbfgs'. Kết quả dự đoán cường độ nén của hỗn hợp đất gia cố được mô tả trong Hình 3, cho hai trường hợp là tập dữ liệu huấn luyện Hình 3a và tập dữ liệu kiểm chứng Hình 3b.



Hình 3: So sánh cường độ chịu nén của hỗn hợp đất gia cố giữa mô hình ANN dự đoán và thí nghiệm (a) huấn luyện và (b) kiểm chứng

Hình 3 mô tả sự so sánh giá trị cường độ chịu nén của hỗn hợp đất gia cố bằng xi măng trong thực tế đo được với giá trị cường độ chịu nén của đất gia cố được dự đoán bởi mô hình học máy ANN (Hình 3a) tập dữ liệu huấn luyện và kiểm chứng (Hình 3b). Kết quả so sánh cho thấy mô hình học máy ANN dự báo cường độ chịu nén của đất gia cố với độ chính xác cao cho tập dữ liệu huấn luyện gồm 35 mẫu. Để định lượng độ chính xác của mô hình học máy ANN đối với tập dữ liệu kiểm chứng trong việc dự đoán cường độ chịu nén, 3 chỉ số hiệu suất đã được sử dụng là hệ số tương quan giữa dự đoán và thực tế $R^2=0.9545$, sai số căn quân phương $RMSE=2381$ MPa và sai số tuyệt đối $MAE=0.1288$ MPa.

Sử dụng mô hình học máy ANN này cho tập dữ liệu kiểm chứng gồm 15 mẫu, theo phân tích từ việc so sánh giá cường độ chịu nén của đất gia cố trong thực tế đo được với giá trị cường độ chịu nén của đất gia cố được dự đoán bởi mô hình học máy ANN (Hình 3b), kết quả cho thấy rằng mô hình học máy GB có độ chính xác rất cao, khi mà đa phần các điểm giá trị cường độ chịu nén thực tế nằm gần với đường cong cường độ chịu nén của đất gia cố dự báo bằng mô hình ANN. Hệ số xác định R^2 của giá trị dự đoán và


giá trị thực tế về cường độ chịu nén của đất gia cố có giá trị cao với $R^2=0.9212$, các chỉ số đánh giá độ chính xác khác của mô hình gồm sai số căn quân phương RMSE của toàn tập dữ liệu kiểm chứng cho giá trị dự đoán và giá trị thực tế cao hơn giá trị RMSE của tập huấn luyện và đạt 0.4777 MPa. Sai số trung bình tuyệt đối MAE của tập dữ liệu kiểm chứng cũng cao hơn không lớn so với tập huấn luyện với $MAE=0.3855$ MPa.

Điều này chứng tỏ mô hình mạng thần kinh nhân tạo ANN có thể đạt độ chính xác cao trong việc dự đoán cường độ chịu nén của đất gia cố 9 biến sử dụng là Hàm lượng hữu cơ, Hạt cát, Hạt bụi, Hạt sét, Hạt cuội, Giới hạn chảy, Giới hạn dẻo, Chỉ số dẻo, Hàm lượng xi măng sử dụng.


Sử dụng mô hình ANN gồm 2 lớp ẩn (4,3) nơ ron kết hợp với phân tích toàn cục SHAP cho kết quả phân tích ảnh hưởng cụ thể của 9 biến đến giá trị cường độ chịu nén dự báo của mô hình cũng như ảnh hưởng đến độ chính xác của mô hình dự báo ANN, kết quả phân tích được thể hiện trong Hình 4a. Ảnh hưởng của 9 biến đến khả năng dự báo hay độ chính xác của mô hình được sắp xếp theo thứ tự giảm dần Hàm lượng xi măng > Giới hạn chảy > Chỉ số dẻo > Hàm lượng hạt sét > Hàm lượng hạt bụi > Giới hạn dẻo > Hàm lượng hữu

cơ > Hàm lượng hạt cát > Hàm lượng hạt cuội. Điều này cho thấy để dự đoán cường độ chịu nén của đất gia cố xi măng bằng mô hình ANN với độ chính xác cao, các biến đầu vào gồm Hàm lượng

xi măng, Giới hạn chảy, Chỉ số dẻo, Hàm lượng hạt sét là cần phải được đưa vào mô hình để dự báo cường độ chịu nén của đất gia cố.



(a)



(b)

Hình 4: Phân tích toàn cục bằng SHAP ảnh hưởng của 9 biến đến giá trị cường độ chịu nén của đất gia cố bằng xi măng được dự báo bằng mô hình ANN

Ngoài ra, Hình 4b cho thấy đồng thời ảnh hưởng giá trị của từng biến đầu vào đến giá trị cường độ chịu nén. Cụ thể, hàm lượng xi măng càng lớn làm tăng cường độ chịu nén của đất gia cố. Giới hạn chảy thấp, chỉ số dẻo và giới hạn dẻo cao làm tăng hiệu quả của đất gia cố. Tăng hàm lượng xi măng làm tăng đáng kể cường độ chịu nén, thể hiện vai trò chủ đạo trong việc cải thiện khả năng chịu lực của đất gia cố. Tuy nhiên thành phần hạt bụi và hạt sét cao làm giảm hiệu quả của việc gia cố đất bằng xi măng. Thành phần hạt bụi và hạt cát ảnh hưởng rất nhỏ tới quá trình gia cố đất bằng xi măng. Những mẫu đất có giới hạn chảy thấp và chỉ số dẻo cao cũng tăng khả năng chịu nén, cho thấy các tính chất cơ học của đất cũng ảnh hưởng đến kết quả gia cố. Hàm lượng hạt sét và bụi cao làm giảm hiệu quả gia cố, điều này có thể giải thích do sự kết cấu kém hơn của các thành phần này trong hỗn hợp.

5. KẾT LUẬN

Kết luận từ nghiên cứu cho thấy rằng mô hình mạng thần kinh nhân tạo (ANN) là một công cụ mạnh mẽ và hiệu quả trong việc dự đoán cường

độ chịu nén của đất gia cố xi măng. Mô hình ANN đã dự đoán cường độ chịu nén của đất gia cố xi măng với độ chính xác cao, đặc biệt với hệ số tương quan R^2 đạt 0.9545 trên tập huấn luyện và 0.9212 trên tập kiểm chứng. Các sai số như RMSE và MAE cũng ở mức chấp nhận được, cho thấy mô hình có khả năng khớp tốt giữa giá trị thực tế và giá trị dự đoán.

Phân tích SHAP đã chỉ ra rằng các biến quan trọng nhất ảnh hưởng đến cường độ chịu nén là hàm lượng xi măng, giới hạn chảy, chỉ số dẻo và hàm lượng hạt sét. Đặc biệt, hàm lượng xi măng có ảnh hưởng mạnh nhất, càng nhiều xi măng thì cường độ chịu nén càng tăng. Ngược lại, các thành phần hạt bụi và hạt sét cao làm giảm khả năng chịu nén của đất.

Việc sử dụng mô hình ANN không chỉ giảm thiểu thời gian và chi phí so với phương pháp thực nghiệm truyền thống mà còn cho phép xử lý tốt các yếu tố phức tạp và phi tuyến tính. Điều này cho thấy mô hình ANN có tiềm năng ứng dụng rộng rãi trong thực tế, giúp tối ưu hóa quy trình thiết kế và kiểm soát chất lượng trong các dự án gia cố đất yếu bằng xi măng.

TÀI LIỆU THAM KHẢO

- [1] T. A. Pham, V. Q. Tran, H.-L. T. Vu, and H.-B. Ly, "Design deep neural network architecture using a genetic algorithm for estimation of pile bearing capacity," *PLOS ONE*, vol. 15, no. 12, p. e0243030, dec 2020, doi: 10.1371/journal.pone.0243030.
- [2] Q. H. Nguyen, H.-B. Ly, T.-A. Nguyen, V.-H. Phan, L. K. Nguyen, and V. Q. Tran, "Investigation

- of ANN architecture for predicting shear strength of fiber reinforcement bars concrete beams,” *PLOS ONE*, vol. 16, no. 4, p. e0247391, avr 2021, doi: 10.1371/journal.pone.0247391.
- [3] Q. H. Nguyen *et al.*, “A novel hybrid model based on a feedforward neural network and one step secant algorithm for prediction of load-bearing capacity of rectangular concrete-filled steel tube columns,” *Molecules*, vol. 25, no. 15, p. 3486, 2020.
- [4] H. Q. Nguyen, H.-B. Ly, V. Q. Tran, T.-A. Nguyen, T.-T. Le, and B. T. Pham, “Optimization of Artificial Intelligence System by Evolutionary Algorithm for Prediction of Axial Capacity of Rectangular Concrete Filled Steel Tubes under Compression,” *Materials*, vol. 13, no. 5, p. 1205, 2020.
- [5] T. A. Pham, H.-B. Ly, V. Q. Tran, L. V. Giap, H.-L. T. Vu, and H.-A. T. Duong, “Prediction of Pile Axial Bearing Capacity Using Artificial Neural Network and Random Forest,” *Applied Sciences*, vol. 10, no. 5, p. 1871, 2020.
- [6] V. Q. Tran and H. Q. Do, “Prediction of California Bearing Ratio (CBR) of Stabilized Expansive Soils with Agricultural and Industrial Waste Using Light Gradient Boosting Machine,” *Journal of Science and Transport Technology*, Sep. 2021, Accessed: Oct. 19, 2021. [Online]. Available: <https://jstt.vn/index.php/en/article/view/3>
- [7] T.-A. Nguyen, H.-B. Ly, and B. T. Pham, “Backpropagation Neural Network-Based Machine Learning Model for Prediction of Soil Friction Angle,” *Mathematical Problems in Engineering*, vol. 2020, p. e8845768, Dec. 2020, doi: 10.1155/2020/8845768.
- [8] H.-V. T. Mai, T.-A. Nguyen, H.-B. Ly, and V. Q. Tran, “Prediction Compressive Strength of Concrete Containing GGBFS using Random Forest Model,” *Advances in Civil Engineering*, vol. 2021, p. e6671448, May 2021, doi: 10.1155/2021/6671448.
- [9] H.-V. T. Mai, T.-A. Nguyen, H.-B. Ly, and V. Q. Tran, “Investigation of ANN Model Containing One Hidden Layer for Predicting Compressive Strength of Concrete with Blast-Furnace Slag and Fly Ash,” *Advances in Materials Science and Engineering*, vol. 2021, p. e5540853, Jun. 2021, doi: 10.1155/2021/5540853.
- [10] T.-A. Nguyen, H.-B. Ly, H.-V. T. Mai, and V. Q. Tran, “Prediction of Later-Age Concrete Compressive Strength Using Feedforward Neural Network,” *Advances in Materials Science and Engineering*, vol. 2020, p. e9682740, Sep. 2020, doi: 10.1155/2020/9682740.
- [11] 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, Dec. 2017, doi: 10.1016/j.measurement.2017.08.031.
- [12] A. R. Boğa, M. Öztürk, and İ. B. Topçu, “Using ANN and ANFIS to predict the mechanical and chloride permeability properties of concrete containing GGBFS and CNI,” *Composites Part B: Engineering*, vol. 45, no. 1, pp. 688–696, Feb. 2013, doi: 10.1016/j.compositesb.2012.05.054.
- [13] Q. Liu, M. F. Iqbal, J. Yang, X. Lu, P. Zhang, and M. Rauf, “Prediction of chloride diffusivity in concrete using artificial neural network: Modelling and performance evaluation,” *Construction and Building Materials*, vol. 268, p. 121082, Jan. 2021, doi: 10.1016/j.conbuildmat.2020.121082.
- [14] S. Inthata, W. Kowtanapanich, and R. Cheerarot, “Prediction of chloride permeability of concretes containing ground pozzolans by artificial neural networks,” *Mater Struct*, vol. 46, no. 10, pp. 1707–1721, Oct. 2013, doi: 10.1617/s11527-012-0009-x.
- [15] H.-W. Song and S.-J. Kwon, “Evaluation of chloride penetration in high performance concrete using neural network algorithm and micro pore structure,” *Cement and Concrete Research*, vol. 39, no. 9, pp. 814–824, Sep. 2009, doi: 10.1016/j.cemconres.2009.05.013.
- [16] A. Gajurel, B. Chittoori, P. S. Mukherjee, and M. Sadegh, “Machine learning methods to map stabilizer effectiveness based on common soil properties,” *Transportation Geotechnics*, vol. 27, p. 100506, Mar. 2021, doi: 10.1016/j.trgeo.2020.100506.
- [17] F. Pedregosa *et al.*, “Scikit-learn: Machine Learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.