

Artificial intelligence approach to predict the penetration and softening point of graphene oxide modified asphalt

Hoang Thi Huong Giang*, Nguyen Hoang Long, Le Thanh Hai, Le Nho Thien, Vu The Thuan

¹University of Transport Technology, No 54 Trieu Khuc, Thanh Xuan, Hanoi 100000, Vietnam

Article info

Type of article:

Original research paper

*Corresponding author:

E-mail address:

gianghth @utt.edu.vn

Received:

November 29, 2021

Accepted:

December 17, 2021

Published:

December 28, 2021

Abstract: Penetration and softening point are the two most important criteria for classifying asphalt grades according to penetration. The determination of these two parameters of modified asphalt graphene oxide (GO) by experimental method encountered certain difficulties due to the high cost of GO and long experimental time. The purpose of this study is to use the adaptive neuro-fuzzy inference system (ANFIS) combined with the genetic algorithm (GA) to predict the penetration and softening point of GO modified asphalt. Two datasets including the penetration dataset (122 samples), softening point dataset (130 samples) collected from 12 different studies with 9 input parameters, are used to construct and test the data digital simulation tool. In addition, the study uses a 10-fold cross-validation technique along with statistical criteria such as correlation coefficient (R) and root of mean square error (RMSE) to evaluate the performance of the models. The research results show that, for the penetration dataset, the ANFIS-GA model has RMSE = 6.045 (0.1 mm), R = 0.949, the ANFIS model has RMSE = 8.492 (0.1 mm), R = 0.893. For the softening point dataset, the ANFIS-GA model has RMSE = 1.848 (°C), R = 0.991, the ANFIS model has RMSE = 13.863 (°C), R = 0.818. This shows that both ANFIS-GA and ANFIS models have good predictive performance and high accuracy. With smaller RMSE and higher R in both datasets, the ANFIS-GA model is evaluated to be better than ANFIS. This model can completely be applied to help materials engineers save time and experimental costs.

Keywords: Adaptive neuro-fuzzy inference system (ANFIS); genetic algorithm (GA); artificial intelligence (AI); machine learning (ML); penetration; softening point; graphene oxide (GO)

Phương pháp tiếp cận trí tuệ nhân tạo để dự báo độ kim lún và điểm hóa mềm của nhựa đường biến tính graphen oxit

Hoàng Thị Hương Giang, Nguyễn Hoàng Long, Lê Thanh Hải, Lê Nho Thiện, Vũ Thế Thuần

¹Trường Đại học Công nghệ Giao thông Vận tải, Số 54 Triều Khúc, Hà Nội 100000

Thông tin bài viết

Dạng bài viết:

Bài báo nghiên cứu

Tác giả liên hệ:

Địa chỉ E-mail:

gianghth@utt.edu.vn

Ngày nộp bài:

29/11/2021

Ngày chấp nhận:

17/12/2021

Ngày đăng bài:

28/12/2021

Tóm tắt: Độ kim lún và điểm hóa mềm là hai chỉ tiêu quan trọng nhất để phân loại mác nhựa đường theo độ kim lún truyền thống. Việc xác định 2 chỉ tiêu này của nhựa đường biến tính graphen oxit (GO) bằng phương pháp thực nghiệm gặp những khó khăn nhất định do giá thành GO cao, thời gian thí nghiệm kéo dài. Mục đích của nghiên cứu này là sử dụng hệ thống suy luận thần kinh mờ thích ứng (ANFIS) kết hợp thuật toán giải thuật di truyền (GA) để dự đoán độ kim lún và điểm hóa mềm của nhựa đường biến tính GO. Hai bộ dữ liệu bao gồm bộ dữ liệu độ kim lún (122 mẫu), bộ dữ liệu điểm hóa mềm (130 mẫu) được thu thập từ 12 nghiên cứu khác nhau với 9 tham số đầu vào, được dùng để xây dựng và kiểm chứng công cụ mô phỏng số. Ngoài ra, nghiên cứu sử dụng kỹ thuật xác thực chéo 10 lần cùng với các tiêu chí thống kê là hệ số tương quan (R) và căn của sai số toàn phương trung bình (RMSE) để đánh giá hiệu suất của các mô hình. Kết quả nghiên cứu cho thấy, đối với bộ dữ liệu độ kim lún, mô hình ANFIS-GA có RMSE = 6.045 (0.1 mm), R = 0.949, mô hình ANFIS có RMSE = 8.492 (0.1 mm), R = 0.893. Đối với bộ dữ liệu hóa mềm, mô hình ANFIS-GA có RMSE = 1.848 (°C), R = 0.991, mô hình ANFIS có RMSE = 13.863 (°C), R = 0.818. Điều này cho thấy, cả hai mô hình ANFIS-GA và ANFIS đều đạt hiệu suất dự đoán tốt và độ chính xác cao. Với RMSE nhỏ hơn và R cao hơn ở cả 2 bộ dữ liệu, mô hình ANFIS-GA được đánh giá là tốt hơn ANFIS. Mô hình này hoàn toàn có thể được áp dụng để giúp các kỹ sư vật liệu tiết kiệm thời gian và chi phí thí nghiệm.

Từ khóa: Hệ thống suy luận thần kinh mờ thích ứng (ANFIS); giải thuật di truyền (GA); trí tuệ nhân tạo (AI); máy học (ML); độ kim lún; điểm hóa mềm, graphen oxit (GO)

1. Đặt vấn đề

Biến tính nhựa đường gốc là một phương pháp phổ biến để cải thiện các tính chất lưu biến và cơ lý của nhựa đường nhằm đáp ứng các yêu cầu về tải trọng, lưu lượng, hạn chế hư hỏng và tăng tuổi thọ của mặt đường nhựa [1]. Để đạt được hiệu quả mong muốn, nhiều loại phụ gia được đưa vào nhựa đường như vụn cao su [2],

chất thải nhựa [3], polime [4]. Nhìn chung, các phụ gia này đáp ứng được các yêu cầu về hiệu suất như ổn định ở nhiệt độ cao để tránh hằn lún, đủ khả năng chống nứt do mỏi, nứt do nhiệt. Tuy nhiên, nhựa đường biến tính chất thải nhựa, vụn cao su, polime thường có nhiệt độ trộn và đầm nén cao hơn nhiều so với nhựa đường gốc. Một số vật liệu trong nhóm phụ gia polime có sự phân

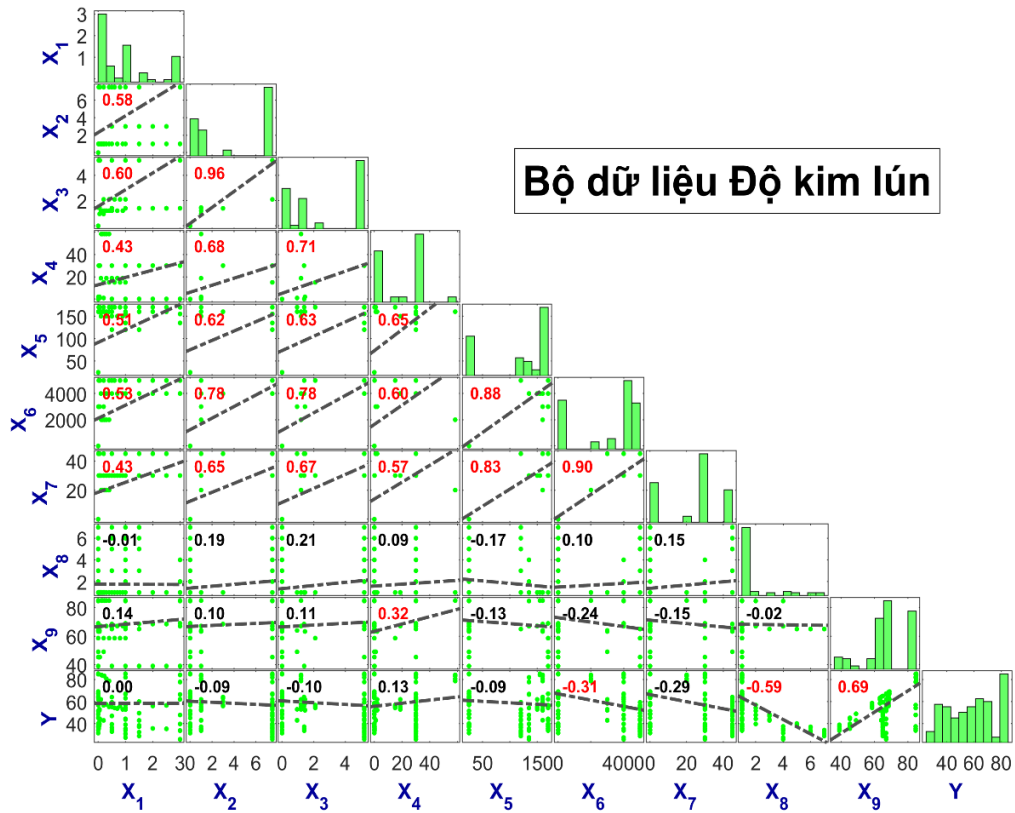
tách pha dẫn đến phân tán thô khi nguội [4]. Ngày nay, các vật liệu nano cũng được sử dụng nhiều trong cải biến nhựa đường do có diện tích bề mặt riêng lớn, làm tăng hiệu suất sửa đổi. Các vật liệu nano dùng để cải biến nhựa đường có thể kể đến nano-silica [5], nano kim loại [6], [7], nano sợi [8]. Những vật liệu nano này có tác động tích cực đến khả năng tăng cường độ cứng, độ nhớt, và do đó tăng khả năng chống hằn lún ở nhiệt độ cao cho mặt đường nhựa. Tuy nhiên, những vật liệu này dường như không cải thiện tính chất nhiệt độ thấp của nhựa đường biến tính [9].

Graphen oxit (GO) là một vật liệu nano thuộc họ graphen, có nguồn gốc từ graphit, được biết đến từ 150 năm trước với nhiều ứng dụng [10]. Tuy nhiên, việc sử dụng GO để nâng cao các đặc tính của nhựa đường chỉ mới được phát triển khoảng vài năm trở lại đây. Với diện tích bề mặt cao, chứa nhiều nhóm chức oxy phân cực bề mặt, nhiều nghiên cứu đã chứng minh được hiệu suất tuyệt vời của GO trong việc cải thiện các đặc tính của nhựa đường. Các nghiên cứu của Adnan và cộng sự [11], Zhu và Zhang [12], Zheng và cộng sự [13] chỉ ra rằng, GO cải thiện tốt các đặc tính cơ lý của nhựa đường như độ kim lún, điểm hóa mềm, độ dẻo, và độ nhớt. Một số đặc tính khác của nhựa đường khi bổ sung GO cũng được cải thiện đáng kể như hiệu suất làm việc ở nhiệt độ cao [14], [15], đặc tính làm việc ở nhiệt độ thấp [16], tăng cường khả năng chống lão hóa của nhựa đường [17]. Trong số các chỉ tiêu đánh giá của nhựa đường, độ kim lún và điểm hóa mềm là hai chỉ tiêu quan trọng nhất để phân loại mác nhựa đường theo độ kim lún [18], nên việc xác định 2 chỉ tiêu này của nhựa đường biến tính GO là rất cần thiết. Tuy nhiên, GO là vật liệu có giá thành cao (khoảng từ vài trăm USD/kg tùy thuộc loại GO), các phương pháp nghiên cứu thực nghiệm thường tốn nhiều thời gian và chi phí. Do vậy, cần có một phương pháp dự báo hai chỉ tiêu trên của nhựa đường biến tính GO.


Gần đây, với sự phát triển nhanh chóng của kỹ thuật trí tuệ nhân tạo (AI), các phương pháp máy học đã được sử dụng phổ biến trong nhiều lĩnh vực cuộc sống [19–21]. Trong kỹ thuật mặt đường, các phương pháp này cũng được sử dụng trong nhiều bài toán khác nhau. Nguyễn và cộng sự [22] sử dụng hệ thống suy luận thần kinh mờ thích ứng để dự đoán chỉ số độ gồ ghề quốc tế IRI. Hamed Majidifard [23] đề xuất mô hình mới để dự đoán chiều sâu vết hằn bánh xe của hỗn hợp bê tông nhựa bằng cách sử dụng lập trình biểu hiện gen (GEP). Golzar và cộng sự [24] dùng mạng nơ-ron nhân tạo (ANN) để điều tra thống kê về các tính chất cơ lý của nhựa đường biến tính bazơ và polyme. Lý và đồng nghiệp [25] phát triển mô hình mạng nơ-ron sâu (DNN) để dự đoán cường độ nén của bê tông cao su. Các nghiên cứu [26–29] sử dụng các phương pháp học máy khác nhau để phát hiện ổ gà trên mặt đường nhựa. Từ các nghiên cứu trên cho thấy phương pháp AI phù hợp với cả bài toán hồi quy và phân loại nên có thể sử dụng để dự đoán chỉ tiêu độ kim lún và điểm hóa mềm của nhựa đường biến tính GO.

Trong nghiên cứu này, nhóm tác giả đề xuất sử dụng hệ thống suy luận thần kinh mờ thích ứng (ANFIS) và thuật toán giải thuật di truyền (GA) để phát triển hai mô hình là ANFIS và ANFIS-GA nhằm dự báo độ kim lún và điểm hóa mềm của nhựa đường biến tính GO. Với mục đích này, bộ dữ liệu được thu thập từ các nghiên cứu thực nghiệm và chia thành 2 tập con là bộ dữ liệu độ kim lún (122 mẫu), bộ dữ liệu điểm hóa mềm (130 mẫu) được sử dụng để xây dựng và đánh giá năng lực dự báo của các mô hình đề xuất, với các tiêu chí thống kê như hệ số tương quan (R), căn của sai số toàn phương trung bình (RMSE). Hiệu suất dự đoán và độ chính xác của hai mô hình được so sánh để chọn ra mô hình tốt nhất cho bài toán dự báo.

2. Cơ sở dữ liệu



Hình 1. Mỗi tương quan giá trị của các biến đầu vào, đầu ra trong bộ dữ liệu độ kim lún



Hình 2. Mỗi tương quan giá trị của các biến đầu vào, đầu ra trong bộ dữ liệu điểm hóa mềm

Để chuẩn bị cho quá trình đào tạo các mô hình, bộ dữ liệu độ kim lún và bộ dữ liệu điểm hóa mềm được tổng hợp đầy đủ từ 12 nghiên cứu thực nghiệm đã được công bố trên các tạp chí uy tín thế giới [15], [30], [11], [31], [32], [13], [33],[16], [34], [35], [36], [37]. Trong đó, bộ dữ liệu kim lún gồm 122 kết quả thí nghiệm, bộ dữ liệu hóa mềm gồm 130 kết quả thí nghiệm. Việc xác định các tham số đầu vào để dự đoán hai chỉ tiêu của nhựa đường biến tính GO đóng vai trò rất quan trọng. Các tham số này phải phản ánh chính xác và phạm vi rộng nhất của vật liệu đầu vào, điều kiện thí nghiệm. Hay nói cách khác, độ chính xác và độ tin cậy của dự đoán trong các bài toán AI phụ thuộc nhiều vào tính đại diện thống kê của dữ liệu đầu vào. Trên cơ sở đó, 9 tham số đầu vào liên quan đến quá trình chế tạo mẫu nhựa đường biến tính GO ảnh hưởng đến độ kim lún và điểm hóa mềm của nhựa đường biến tính GO được xác định, bao gồm tỷ lệ GO (X_1), số lớp GO (X_2), chiều dày lớp GO (X_3), kích thước bên trung bình lớp GO (X_4), nhiệt độ trộn (X_5), vận tốc trộn RPM (X_6), thời gian trộn (X_7), loại hóa già (X_8), độ kim lún (bộ dữ liệu độ kim lún) hoặc điểm hóa mềm (bộ dữ liệu điểm hóa mềm) của nhựa đường ban đầu (X_9). Mỗi bộ dữ liệu được chia ngẫu nhiên thành 2 phần, 70% dữ liệu được sử dụng để huấn luyện các mô hình, 30% dữ liệu còn lại dùng để kiểm chứng các mô hình.

Bên cạnh đó, mối tương quan giữa các tham số đầu vào, và giữa tham số đầu vào với tham số đầu ra được phân tích và thiết lập thông qua ma trận đối xứng 10×10 như Hình 1 và 2. Đường chéo ma trận biểu thị biểu đồ phân bố dữ liệu của các biến đầu vào, đầu ra; phần phía dưới đường chéo biểu thị giá trị của hệ số tương quan giữa các biến. Các giá trị dương biểu thị mối tương quan tích cực, giá trị âm biểu thị mối tương quan tiêu cực. Đồng thời, màu sắc của các giá trị biểu thị mức độ tương quan, giá trị màu đỏ là tương quan vừa, cao và rất cao, điều này thể hiện sự phụ thuộc giữa các biến. Các giá trị màu đen là tương quan thấp, thậm chí rất thấp, điều này thể hiện sự độc lập giữa các biến.

3. Phương pháp máy học

3.1. Hệ thống suy luận thần kinh mờ thích ứng (ANFIS)

Được đề xuất lần đầu tiên vào năm 1990 bởi Jang, ANFIS là một hệ thống dự đoán nhân tạo thông minh, sử dụng kết hợp kỹ thuật máy học của mạng ANN và hệ thống logic mờ [38]. Bằng cách sử dụng quy trình học kết hợp, ANFIS được đề xuất có thể xây dựng một tập hợp các quy tắc "if-then" mờ với các hàm thuộc (membership functions) thích hợp để tạo các cặp đầu vào-đầu ra được chỉ định. Quy tắc "if-then" mờ hoặc câu lệnh điều kiện mờ là biểu thức có dạng If A Then B, trong đó A và B là nhãn của các tập mờ được đặc trưng bởi các hàm thuộc thích hợp. Với hình thức ngắn gọn, các quy tắc if-then mờ thường được sử dụng để nắm bắt các phương thức lập luận không chính xác, đóng một vai trò thiết yếu trong khả năng đưa ra quyết định của con người trong trường hợp không chắc chắn và không chính xác. Cấu trúc ANFIS bao gồm 5 lớp chính [39]:

- Lớp 1: Được gọi là lớp mờ. Lớp này gồm các hàm thuộc được xác định từ các biến đầu vào. Đầu ra là mức giá trị của hàm thuộc được tính toán dựa trên một hàm thuộc Gaussian.

- Lớp 2: Lớp quy tắc. Lớp này gồm các nút quy tắc, mỗi đầu ra từ các nút quy tắc đại diện cho một sản phẩm của các tín hiệu đầu vào.

- Lớp 3: Lớp chuẩn hóa. Lớp này đã chuẩn hóa các hàm thuộc. Mỗi nút là một nút cố định, số lượng các nút trong lớp này bằng số lượng các nút trong lớp 2.

- Lớp 4: Lớp giải mờ. Lớp này thực hiện phần kết quả của các quy tắc mờ. Mỗi nút trong lớp này là nút thích nghi, số lượng các nút trong lớp này bằng số lượng nút trong lớp 3.

- Lớp 5: Lớp đầu ra hay gọi là lớp tổng kết, là tổng của các đầu ra tất cả các nút thích nghi trong lớp 4.

Tuy nhiên, có một hạn chế trong mô hình ANFIS như ANFIS không mạnh trong việc tìm kiếm trọng số tốt nhất và tốc độ hội tụ chậm, điều này ảnh hưởng lớn đến hiệu quả dự đoán [40]. Nhiều nghiên cứu đã sử dụng các phương pháp tối ưu hóa khác nhau để tìm ra trọng số của các


tham số tiền trước và tham số hệ quả theo cách tốt hơn như thuật toán giải thuật di truyền (GA) [41], tối ưu hóa bầy đàn (PSO) [42] hoặc thuật toán đàn kiến [43]. Hai tham số này nằm ở lớp 1 và lớp 4 như đã nêu ở phần trên. Trong bài báo này, nhóm tác giả đề xuất thuật toán giải thuật di truyền để tối ưu hóa các tham số trong ANFIS.

3.2. Giải thuật di truyền (GA)

GA dựa trên thuyết tiến hóa của Charles Darwin [44], sử dụng các nguyên tắc di truyền, đột biến, chọn lọc tự nhiên và trao đổi chéo. Nó bao gồm một số thuật ngữ bộ gen như nhiễm sắc thể, quần thể, và gen. Nhiễm sắc thể được tạo thành từ gen, mỗi gen mang một số đặc điểm và nằm trong nhiễm sắc thể, mỗi nhiễm sắc thể sẽ đại diện cho một giải pháp của vấn đề [45]. GA là phương pháp tìm kiếm tối ưu ngẫu nhiên bằng

cách mô phỏng theo sự tiến hóa của con người hay sinh vật. Trong GA, việc tìm kiếm giả thuyết thích hợp được bắt đầu với một quần thể, hay một tập hợp có chọn lọc ban đầu của các giả thuyết. Các cá thể của quần thể hiện tại khởi nguồn cho quần thể thế hệ kế tiếp bằng các hoạt động lai ghép và đột biến ngẫu nhiên. Trong bước tiếp theo, các giả thuyết trong quần thể hiện tại được ước lượng liên hệ với đại lượng thích nghi. Các giả thuyết phù hợp nhất được chọn theo xác suất là các hạt giống sản sinh thế hệ kế tiếp, gọi là cá thể. Cá thể nào phát triển hơn, thích nghi với môi trường sẽ tồn tại, ngược lại sẽ bị đào thải. Do vậy, GA có thể dò tìm thế hệ mới có độ thích nghi tốt hơn.

3.3. Xác thực chéo (Cross Validation)



Hình 3. Minh họa kỹ thuật xác thực chéo 10 lần

Xác thực chéo là một kỹ thuật được sử dụng để đo lường xem một mô hình học tập có thể tổng quát hóa trên dữ liệu không nhìn thấy được hay không. Dữ liệu không nhìn thấy được là tất cả các dữ liệu mà mô hình chưa từng học trước đây. Từ đó cung cấp khả năng ước tính khách quan về hiệu suất mô hình dựa trên những dữ liệu không được sử dụng trong khi huấn luyện. Thông thường, một tập dữ liệu được chia theo ngẫu nhiên hoặc phân tầng thành ba tập con: tập dữ liệu huấn luyện, tập dữ liệu xác thực và tập dữ liệu kiểm chứng, với các chức năng

tương ứng là huấn luyện, xác nhận và kiểm tra mô hình. Trong trường hợp tập dữ liệu được chia thành hai phần là tập dữ liệu huấn luyện và tập dữ liệu kiểm chứng, xác thực chéo sẽ được thực hiện theo hai bước chính: chia nhỏ tập dữ liệu huấn luyện thành n phần (n nếp gấp) có kích thước xấp xỉ nhau; huấn luyện xen kẽ và xác nhận giữa chúng. Như vậy, có tất cả n lần huấn luyện, mỗi lần chọn 1 phần làm dữ liệu xác thực, n-1 phần còn lại làm dữ liệu huấn luyện, tập dữ liệu kiểm chứng được sử dụng để đánh giá mô hình khi gặp dữ liệu chưa từng được học. Kết

quả đánh giá cuối cùng của mô hình là trung bình cộng kết quả đánh giá n lần huấn luyện [46]. Kỹ thuật phân chia bộ dữ liệu thành các phần có thể khác nhau và được lựa chọn dựa trên kích thước dữ liệu và mục tiêu cuối cùng. Trong nghiên cứu này, nhóm tác giả lựa chọn xác thực chéo 10 lần được minh họa trong Hình 3.

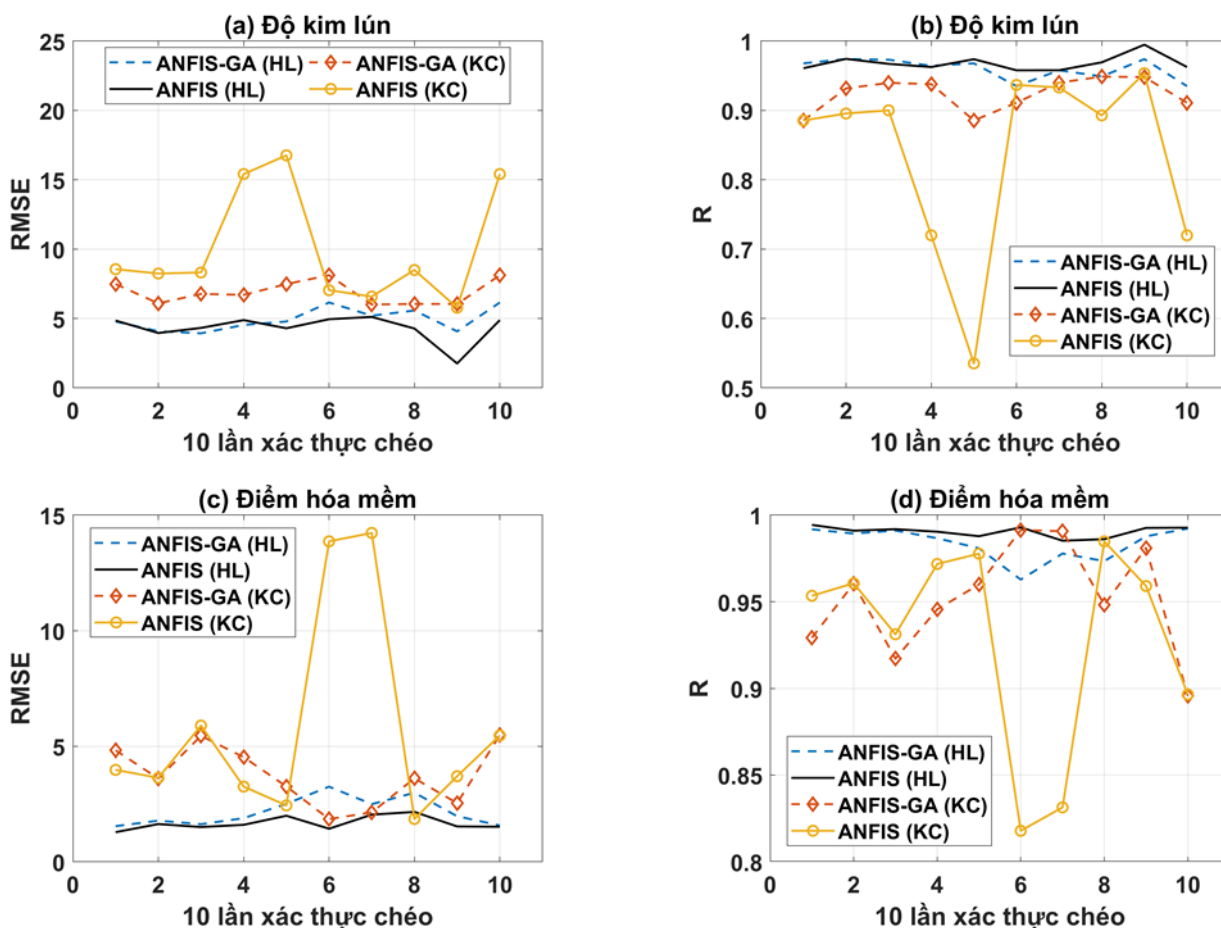
3.4. Đánh giá năng lực dự báo: R và RMSE

Để đánh giá hiệu suất và độ chính xác của các mô hình máy học trong việc dự đoán độ kim lún và điểm hóa mềm của nhựa đường biến tính GO, các chỉ số hiệu suất được sử dụng trong nghiên cứu này bao gồm hệ số tương quan (R) và căn của sai số toàn phương trung bình

(RMSE). Đây là 2 chỉ số được sử dụng nhiều nhất để đo sai số trong các bài toán AI/ML. Trong đó, chỉ số R dùng để ước tính mối tương quan giữa kết quả thực tế và kết quả dự đoán, có giá trị nằm trong khoảng [-1;1], RMSE đo mức độ sai số trung bình giữa kết quả đầu ra thực tế và kết quả dự đoán. Về mặt định lượng, giá trị tuyệt đối của R càng gần 1 và RMSE càng gần 0 thì hiệu suất và độ chính xác mô hình càng cao. Công thức xác định hai chỉ số hiệu suất trên có thể tham khảo trong tài liệu trích dẫn [47].

4. Kết quả và thảo luận

4.1. Xây dựng mô hình ANFIS và ANFIS-GA



Hình 4. Kết quả hiệu suất dự báo của hai mô hình ANFIS-GA và ANFIS trên: (a) bộ dữ liệu độ kim lún theo tiêu chí RMSE, (b) bộ dữ liệu độ kim lún theo tiêu chí R, (c) bộ dữ liệu điểm hóa mềm theo tiêu chí RMSE, và (d) bộ dữ liệu điểm hóa mềm theo tiêu chí R

Trong phần này, quá trình xây dựng hai công cụ mô phỏng số ANFIS và ANFIS-GA được thực hiện trên cả hai bộ dữ liệu độ kim lún và điểm hóa mềm. Trước tiên, quá trình huấn luyện hai mô hình được tiến hành, tập dữ liệu huấn

luyện-xác thực (chiếm 70% bộ dữ liệu) được chia thành 10 phần để tiến hành xác thực chéo. Với 10 lần mô phỏng, hiệu suất trung bình của tập dữ liệu huấn luyện-xác thực được tính toán. Tập dữ liệu kiểm chứng (chiếm 30% dữ liệu còn lại)

được sử dụng để kiểm chứng mô hình đối với những dữ liệu chưa được học. Kết quả đánh giá hiệu suất dự báo các mô hình đối với cả hai tập dữ liệu được thể hiện ở Hình 4.

Từ kết quả Hình 4 cho thấy, đối với bộ dữ liệu độ kim lún, mô hình ANFIS-GA có khả năng đào tạo tốt và ổn định. Điều này thể hiện ở các giá trị RMSE thấp, dao động với biên độ rất nhỏ xung quanh 5 (đối với tập huấn luyện-xác thực), xung quanh 7 (đối với tập kiểm chứng). Các giá trị R đều lớn hơn 0.9 cho cả hai tập dữ liệu. Năng lực đào tạo của mô hình ANFIS so với ANFIS-GA là thấp hơn, cụ thể các giá trị RMSE của hai mô hình xấp xỉ bằng nhau đối với tập huấn luyện-xác thực, nhưng ở tập kiểm chứng RMSE của mô hình ANFIS lại cao hơn và có khoảng biến thiên rộng hơn với ba giá trị lớn hơn 15. Các giá trị R ở tập huấn luyện rất cao, trung bình trên 0.95. Với tập kiểm chứng, giá trị R lại thấp hơn, phần lớn đều trên 0.9, ngoại trừ có ba giá trị thấp dưới 0.75.

Tương tự, đối với bộ dữ liệu điểm hóa mềm (Hình 4c,d), năng lực đào tạo của hai mô hình đều cao, tuy nhiên mô hình ANFIS-GA được đánh giá cao hơn ANFIS. Với mô hình ANFIS-GA, các giá trị RMSE đều thấp dưới 5 ở cả tập huấn luyện-xác thực và kiểm chứng, các giá trị R đạt được rất cao trên 0.95 với tập huấn luyện-xác thực, và trên 0.92 đối với tập kiểm chứng. So với mô hình ANFIS-GA, mô hình ANFIS có các giá trị RMSE thấp hơn và R cao hơn ở tập huấn luyện-xác thực. Tuy nhiên, ở tập kiểm chứng khoảng biến thiên của RMSE và R lại rất lớn. Phần lớn các giá trị RMSE đều dưới 5, có hai giá trị đạt xấp xỉ 15; các giá trị R đa phần trên 0.95, có ba giá trị nằm trong khoảng 0.8-0.9.

Như vậy, sau khi thực hiện 10 lần xác thực chéo với 10 mô phỏng, hai mô hình ANFIS và ANFIS-GA đã được xây dựng với độ chính xác cao và kiểm chứng độ tin cậy bởi 3 phần dữ liệu độc lập ở cả hai bộ dữ liệu kim lún và điểm hóa mềm. Ở phần tiếp theo, kết quả dự báo tiêu biểu của hai mô hình này được trình bày.

4.2. Kết quả dự báo tiêu biểu của hai mô hình ANFIS-GA và ANFIS

Trong phần này, kết quả dự báo điển hình

của hai mô hình ANFIS-GA và ANFIS được trình bày. Các kết quả này trích xuất từ hai mô hình đã được xây dựng, xác thực và kiểm chứng ở phần trên. Mô hình hồi quy cho các tập dữ liệu khác nhau của hai bộ dữ liệu, dự báo bởi ANFIS-GA và ANFIS được thể hiện trên Hình 5.

Kết quả thể hiện trên Hình 5 cho thấy, hai mô hình được đề xuất trong nghiên cứu này đều có độ chính xác cao ở cả hai bộ dữ liệu. Với bộ dữ liệu độ kim lún, mô hình ANFIS-GA đạt được RMSE = 5.571, R = 0.949 ở tập dữ liệu huấn luyện-xác thực, và RMSE = 6.045, R = 0.949 ở tập dữ liệu kiểm chứng. Mô hình ANFIS đạt được RMSE = 4.283, R = 0.969 ở tập dữ liệu huấn luyện-xác thực, ở tập dữ liệu kiểm chứng các giá trị này lần lượt là 8.492 và 0.893. Tuy nhiên, để so sánh năng lực dự báo của các mô hình, kết quả dự báo phần kiểm chứng thường được chú trọng hơn phần huấn luyện-xác thực. Với hệ số tương quan R cao hơn và sai số nhỏ hơn so với phần huấn luyện-xác thực, mô hình ANFIS-GA đã thể hiện năng lực dự báo tốt hơn và khả năng tổng quát hóa cao hơn mô hình ANFIS trong dự báo độ kim lún của nhựa đường biến tính GO.

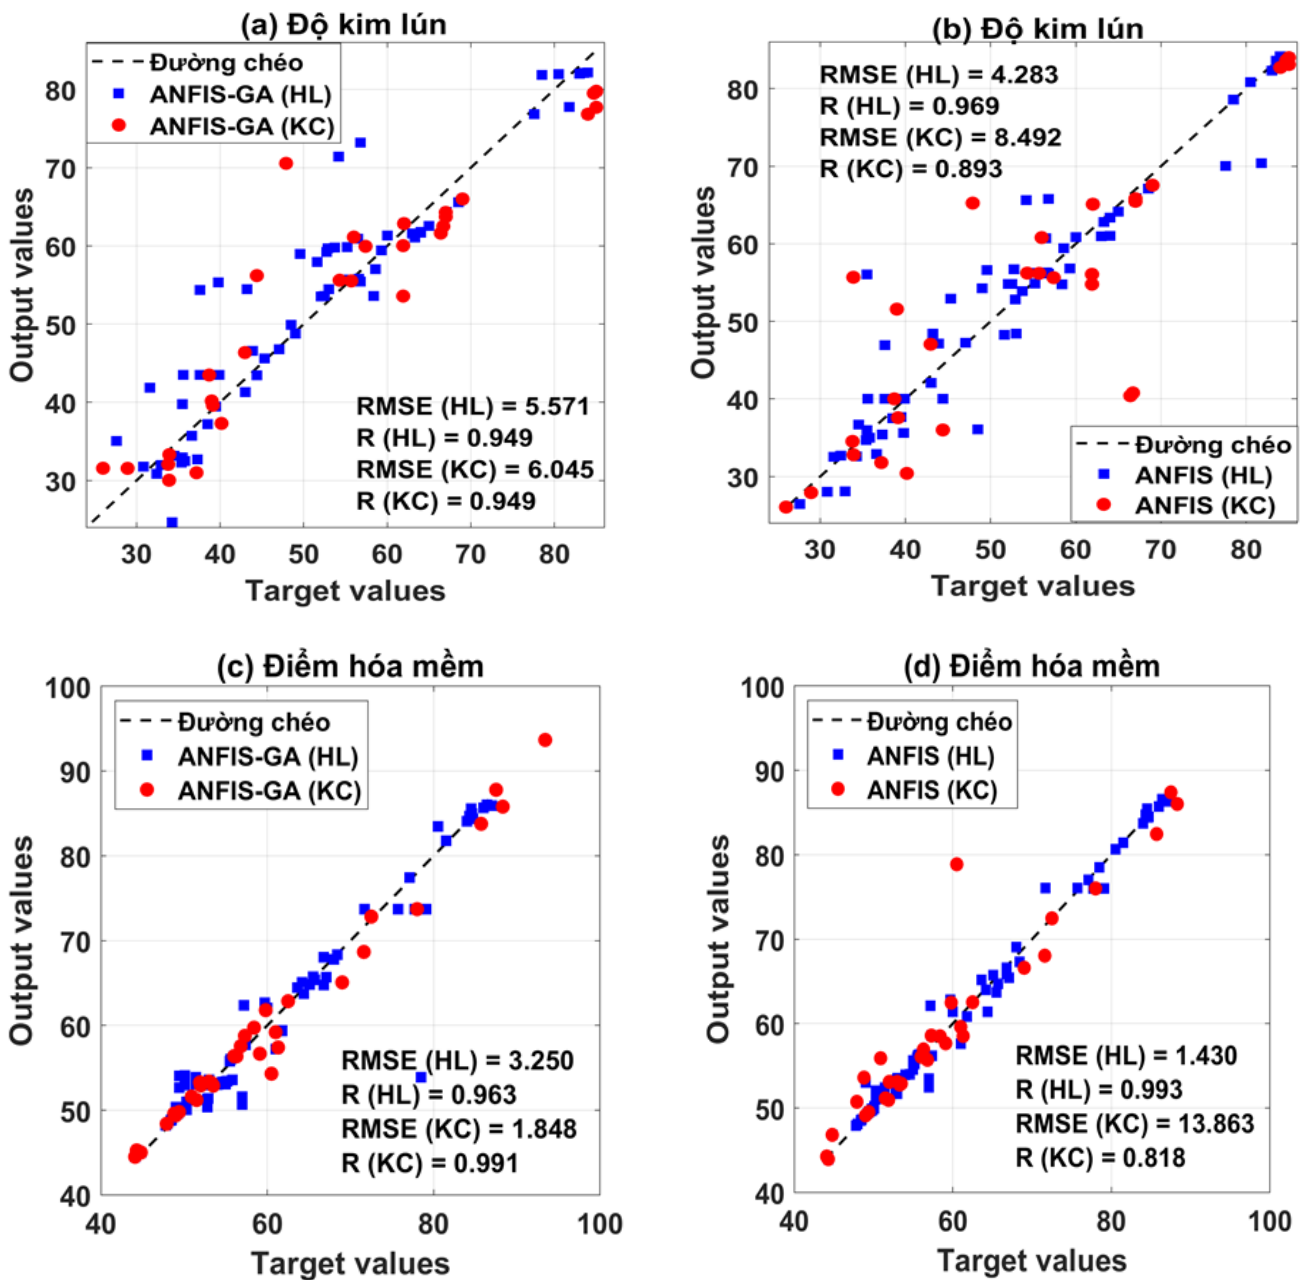
Tương tự với bộ dữ liệu điểm hóa mềm, kết quả đánh giá hiệu suất dự báo của hai mô hình cho thấy mô hình ANFIS-GA có độ chính xác cao hơn mô hình ANFIS. Cụ thể, với mô hình ANFIS-GA, giá trị RMSE và R ở phần huấn luyện-xác thực lần lượt là 3.250, 0.963, ở phần kiểm chứng lần lượt là 1.848, 0.991. Trong khi đó, với mô hình ANFIS mặc dù kết quả dự báo ở phần huấn luyện-xác thực có tốt hơn mô hình ANFIS-GA (RMSE = 1.430, R = 0.993), nhưng ở phần kiểm chứng lại thấp hơn nhiều mô hình ANFIS-GA (RMSE = 13.863, R = 0.818).

Như vậy, với kết quả dự báo của hai mô hình đã chọn để dự báo độ kim lún và điểm hóa mềm của nhựa đường biến tính GO, mô hình ANFIS-GA cho kết quả dự báo với độ chính xác và độ tin cậy tốt hơn mô hình ANFIS. Do đó, mô hình ANFIS-GA được lựa chọn để đánh giá kết quả sai số mô phỏng.

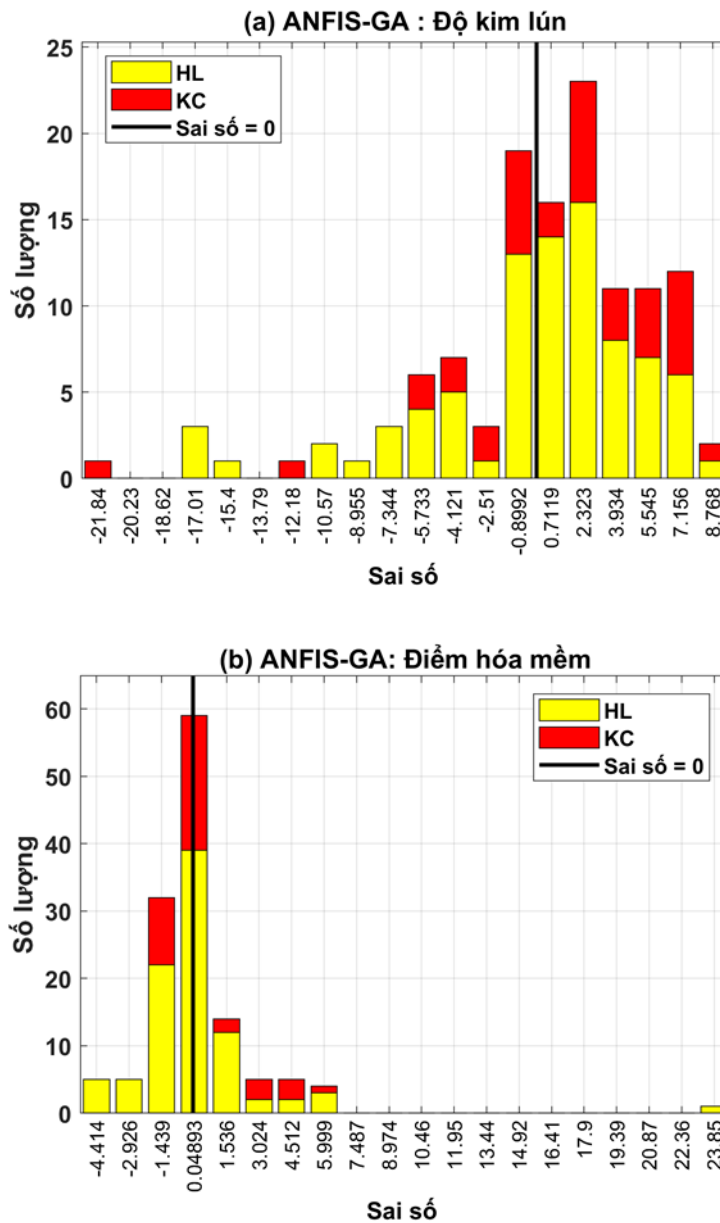
Kết quả đồ thị phân bố sai số mô phỏng của mô hình ANFIS-GA thông qua các tập dữ liệu huấn luyện-xác thực và kiểm chứng ở cả hai

bộ dữ liệu được trình bày ở Hình 6. Nhìn chung, các sai số ở cả hai bộ dữ liệu được tìm thấy đều tập trung phân bố xung quanh vị trí sai số bằng 0 với số lượng mẫu lớn. Xem xét bộ dữ liệu độ kim lún, hầu hết các sai số nằm trong khoảng $[-7; 7]$ (0.1mm) ở cả tập dữ liệu huấn luyện-xác thực và kiểm chứng, có 8 mẫu (tập huấn luyện-xác thực) và 4 mẫu (tập kiểm chứng) có sai số nằm ngoài khoảng trên, trong đó có 1 mẫu ở tập kiểm chứng có sai số lớn hơn 21 (0.1mm). Với bộ dữ liệu điểm hóa mềm, các sai số tập trung chủ yếu

trong khoảng $[-1.5; 1.5]^{\circ}\text{C}$, các mẫu còn lại có sai số đều nhỏ hơn 6°C ở cả hai tập dữ liệu, có duy nhất 1 mẫu ở tập huấn luyện-xác thực có sai số lớn hơn 23°C . Với sai số nhỏ như trên, năng lực dự báo của mô hình ANFIS-GA với bài toán xác định độ kim lún và điểm hóa mềm của nhựa đường biến tính GO được đánh giá là rất tốt. Mô hình này hoàn toàn có thể được áp dụng để giúp các kỹ sư vật liệu tiết kiệm thời gian và chi phí thí nghiệm.



Hình 5. Kết quả hồi quy của hai mô hình trên tập dữ liệu huấn luyện-xác thực và kiểm chứng: (a) mô hình ANFIS-GA của bộ dữ liệu độ kim lún, (b) mô hình ANFIS của bộ dữ liệu độ kim lún, (c) mô hình ANFIS-GA của bộ dữ liệu điểm hóa mềm, và (d) mô hình ANFIS của bộ dữ liệu điểm hóa mềm



Hình 6. Kết quả sai số mô phỏng của mô hình ANFIS-GA cho dữ liệu huấn luyện-xác thực và kiểm chứng của 2 bộ dữ liệu: (a) bộ dữ liệu độ kim lún, (b) bộ dữ liệu điểm hóa mềm

5. Kết luận

Trong nghiên cứu này, hai mô hình ANFIS và ANFIS-GA được xây dựng và xác nhận để dự đoán độ kim lún và điểm hóa mềm của nhựa đường biến tính GO. Với mục đích này, bộ dữ liệu kim lún gồm 122 kết quả thí nghiệm, bộ dữ liệu hóa mềm gồm 130 kết quả thí nghiệm được thu thập từ 12 nghiên cứu thực nghiệm đã được công bố trên các tạp chí uy tín thế giới. Có 9 tham số đầu vào được sử dụng cho cả hai bộ dữ liệu. Hai tiêu chí RMSE và R được sử dụng để đánh giá hiệu suất của hai mô hình được đề xuất. Kết quả nghiên cứu cho thấy, cả hai mô

hình được đề xuất đều cho hiệu suất dự báo tốt và độ chính xác cao. Cụ thể xét cho tập dữ liệu kiểm chứng, với bộ dữ liệu độ kim lún, mô hình ANFIS-GA có RMSE = 6.045 (0.1mm), R = 0.949, mô hình ANFIS có RMSE = 8.492 (0.1mm), R = 0.893. Với bộ dữ liệu hóa mềm, mô hình ANFIS-GA có RMSE = 1.848 (°C), R = 0.991, mô hình ANFIS có RMSE = 13.863 (°C), R = 0.818. Như vậy, mô hình ANFIS-GA được đánh giá là tốt hơn mô hình ANFIS trong bài toán dự báo độ kim lún và điểm hóa mềm của nhựa đường biến tính GO.

Tài liệu tham khảo

- [1] A. S. Hosseini, P. Hajikarimi, M. Gandomi, F. M. Nejad, and A. H. Gandomi, "Genetic programming to formulate viscoelastic behavior of modified asphalt binder," *Construction and Building Materials*, vol. 286, p. 122954, 2021.
- [2] M. Fakhri and A. Azami, "Evaluation of warm mix asphalt mixtures containing reclaimed asphalt pavement and crumb rubber," *Journal of Cleaner Production*, vol. 165, pp. 1125–1132, 2017.
- [3] L. Costa, J. Peralta, J. R. Oliveira, and H. M. Silva, "A new life for cross-linked plastic waste as aggregates and binder modifier for asphalt mixtures," *Applied Sciences*, vol. 7, no. 6, p. 603, 2017.
- [4] U. Isacson and X. Lu, "Testing and appraisal of polymer modified road bitumens—state of the art," *Materials and Structures*, vol. 28, no. 3, pp. 139–159, 1995.
- [5] A. Al-Omari, M. Taamneh, M. A. Khasawneh, and A. Al-Hosainat, "Effect of crumb tire rubber, microcrystalline synthetic wax, and nano silica on asphalt rheology," *Road Materials and Pavement Design*, vol. 21, no. 3, pp. 757–779, 2020.
- [6] S. Pirmohammad, Y. Majd-Shokorlou, and B. Amani, "Experimental investigation of fracture properties of asphalt mixtures modified with Nano Fe₂O₃ and carbon nanotubes," *Road Materials and Pavement Design*, vol. 21, no. 8, pp. 2321–2343, 2020.
- [7] H. Zhang, Y. Gao, G. Guo, B. Zhao, and J. Yu, "Effects of ZnO particle size on properties of asphalt and asphalt mixture," *Construction and Building Materials*, vol. 159, pp. 578–586, 2018.
- [8] M. J. Khattak, A. Khattab, and H. R. Rizvi, "Characterization of carbon nano-fiber modified hot mix asphalt mixtures," *Construction and Building Materials*, vol. 40, pp. 738–745, 2013.
- [9] S. Wu and O. Tahri, "State-of-art carbon and graphene family nanomaterials for asphalt modification," *Road Materials and Pavement Design*, vol. 22, no. 4, pp. 735–756, 2021.
- [10] W. Gao, *Graphene oxide: reduction recipes, spectroscopy, and applications*. Springer, 2015.
- [11] A. M. Adnan, X. Luo, C. Lü, J. Wang, and Z. Huang, "Improving mechanics behavior of hot mix asphalt using graphene-oxide," *Construction and Building Materials*, vol. 254, p. 119261, 2020.
- [12] J. Zhu, K. Zhang, K. Liu, and X. Shi, "Performance of hot and warm mix asphalt mixtures enhanced by nano-sized graphene oxide," *Construction and Building Materials*, vol. 217, pp. 273–282, 2019.
- [13] Q. Zeng, Y. Liu, Q. Liu, P. Liu, Y. He, and Y. Zeng, "Preparation and modification mechanism analysis of graphene oxide modified asphalts," *Construction and Building Materials*, vol. 238, p. 117706, 2020.
- [14] K. Liu, J. Zhu, K. Zhang, J. Wu, J. Yin, and X. Shi, "Effects of mixing sequence on mechanical properties of graphene oxide and warm mix additive composite modified asphalt binder," *Construction and Building Materials*, vol. 217, pp. 301–309, 2019.
- [15] J. Zhu, K. Zhang, K. Liu, and X. Shi, "Adhesion characteristics of graphene oxide modified asphalt unveiled by surface free energy and AFM-scanned micro-morphology," *Construction and Building Materials*, vol. 244, p. 118404, 2020.
- [16] W. Zeng, S. Wu, L. Pang, Y. Sun, and Z. Chen, "The utilization of graphene oxide in traditional construction materials: Asphalt," *Materials*, vol. 10, no. 1, p. 48, 2017.
- [17] D. Singh, A. Kuity, S. Girimath, A. Suchismita, and B. Showkat, "Investigation of Chemical, Microstructural, and Rheological Perspective of Asphalt Binder Modified with Graphene Oxide," *Journal of Materials in Civil Engineering*, vol. 32, no. 11, p. 04020323, 2020.

- [18] H. EN12591, "Bitumen and Bituminous Binders—Specifications for Paving Grade Bitumens," CEN: Brussels, Belgium, 2009.
- [19] 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, 2020.
- [20] H.-B. Ly et al., "Prediction and sensitivity analysis of bubble dissolution time in 3D selective laser sintering using ensemble decision trees," *Materials*, vol. 12, no. 9, p. 1544, 2019.
- [21] H. Chen, P. G. Asteris, D. Jahed Armaghani, B. Gordan, and B. T. Pham, "Assessing dynamic conditions of the retaining wall: developing two hybrid intelligent models," *Applied Sciences*, vol. 9, no. 6, p. 1042, 2019.
- [22] H.-L. Nguyen et al., "Adaptive network based fuzzy inference system with meta-heuristic optimizations for international roughness index prediction," *Applied Sciences*, vol. 9, no. 21, p. 4715, 2019.
- [23] H. Majidifard, B. Jahangiri, P. Rath, L. U. Contreras, W. G. Buttlar, and A. H. Alavi, "Developing a prediction model for rutting depth of asphalt mixtures using gene expression programming," *Construction and Building Materials*, vol. 267, p. 120543, 2021.
- [24] K. Golzar, A. Jalali-Arani, and M. Nematollahi, "Statistical investigation on physical–mechanical properties of base and polymer modified bitumen using Artificial Neural Network," *Construction and Building Materials*, vol. 37, pp. 822–831, 2012.
- [25] H.-B. Ly, T.-A. Nguyen, and V. Q. Tran, "Development of deep neural network model to predict the compressive strength of rubber concrete," *Construction and Building Materials*, vol. 301, p. 124081, 2021.
- [26] M. H. Yousaf, K. Azhar, F. Murtaza, and F. Hussain, "Visual analysis of asphalt pavement for detection and localization of potholes," *Advanced Engineering Informatics*, vol. 38, pp. 527–537, 2018.
- [27] W. Ye, W. Jiang, Z. Tong, D. Yuan, and J. Xiao, "Convolutional neural network for pothole detection in asphalt pavement," *Road materials and pavement design*, vol. 22, no. 1, pp. 42–58, 2021.
- [28] N.-D. Hoang, "An artificial intelligence method for asphalt pavement pothole detection using least squares support vector machine and neural network with steerable filter-based feature extraction," *Advances in Civil Engineering*, vol. 2018, 2018.
- [29] Y. Pan, X. Zhang, G. Cervone, and L. Yang, "Detection of asphalt pavement potholes and cracks based on the unmanned aerial vehicle multispectral imagery," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 11, no. 10, pp. 3701–3712, 2018.
- [30] J.-S. Jang, "ANFIS: adaptive-network-based fuzzy inference system," *IEEE transactions on systems, man, and cybernetics*, vol. 23, no. 3, pp. 665–685, 1993.
- [31] G. Manogaran, R. Varatharajan, and M. K. Priyan, "Hybrid recommendation system for heart disease diagnosis based on multiple kernel learning with adaptive neuro-fuzzy inference system," *Multimedia tools and applications*, vol. 77, no. 4, pp. 4379–4399, 2018.
- [32] D. Karaboga and E. Kaya, "Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey," *Artificial Intelligence Review*, vol. 52, no. 4, pp. 2263–2293, 2019.
- [33] D. Whitley, "A genetic algorithm tutorial," *Statistics and computing*, vol. 4, no. 2, pp. 65–85, 1994.
- [34] J. Kennedy and R. C. Eberhart, "A discrete binary version of the particle swarm algorithm," in *1997 IEEE International conference on systems, man, and cybernetics. Computational cybernetics and simulation, 1997*, vol. 5, pp. 4104–4108.
- [35] E. Atashpaz-Gargari and C. Lucas, "Imperialist competitive algorithm: an algorithm

- for optimization inspired by imperialistic competition,” in 2007 IEEE congress on evolutionary computation, 2007, pp. 4661–4667.
- [36] C.-F. Juang, “A hybrid of genetic algorithm and particle swarm optimization for recurrent network design,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 34, no. 2, pp. 997–1006, 2004.
- [37] K. Gai, L. Qiu, H. Zhao, and M. Qiu, “Cost-aware multimedia data allocation for heterogeneous memory using genetic algorithm in cloud computing,” *IEEE transactions on cloud computing*, vol. 8, no. 4, pp. 1212–1222, 2016.
- [38] R. Kohavi, “A study of cross-validation and bootstrap for accuracy estimation and model selection,” in *Ijcai*, 1995, vol. 14, no. 2, pp. 1137–1145.
- [39] H.-B. Ly et al., “Hybrid artificial intelligence approaches for predicting critical buckling load of structural members under compression considering the influence of initial geometric imperfections,” *Applied Sciences*, vol. 9, no. 11, p. 2258, 2019.