

# ỨNG DỤNG MẠNG NƠ-RON HỌC SÂU TRONG DỰ BÁO ĐỘ MẤT MÁT KHỐI LƯỢNG CỦA BÊ TÔNG CHỨA CỐT LIỆU CAO SU DƯỚI ẢNH HƯỞNG CỦA NHIỆT ĐỘ

## PREDICTING MASS LOSS OF WASTE TIRE RUBBER CONCRETE UNDER EFFECT OF TEMPERATURE USING DEEP LEARNING NEURAL NETWORK

Lê Trần Minh Đạt<sup>1\*</sup>, Đoàn Viết Long<sup>1</sup>

<sup>1</sup>Trường Đại học Bách khoa - Đại học Đà Nẵng

\*Tác giả liên hệ: ltm-dat@dut.udn.vn

(Nhận bài: 22/4/2021; Chấp nhận đăng: 18/5/2021)

**Tóm tắt** - Bài báo này giới thiệu cách tiếp cận mới trong việc sử dụng mô hình mạng nơ-ron học sâu (DLNN) để dự đoán độ mất mát khối lượng của bê tông chứa cốt liệu cao su (RC) dưới tác dụng của nhiệt độ. Một mô hình cấu trúc của DLNN với 22 nơ-ron trong 3 lớp ẩn được đề xuất. Bộ dữ liệu với 162 mẫu, bao gồm bốn yếu tố ảnh hưởng: Tỷ lệ nước/ xi măng, thời gian nung, nhiệt độ, tỉ lệ vụn cao su thay thế được sử dụng để huấn luyện và xác nhận mô hình đã được thu thập từ các tài liệu. Đầu ra là tỉ lệ mất mát khối lượng của RC. Mô hình DLNN được so sánh với hai kỹ thuật học máy khác là Random Forest và Multilayer Perceptron. Kết quả cho thấy mô hình DLNN vượt trội hơn so với các mô hình khác và do đó nó có thể được sử dụng như một phương pháp phù hợp để dự đoán độ mất mát khối lượng của RC dưới ảnh hưởng của nhiệt độ.

**Từ khóa** - Bê tông cao su; mạng nơ-ron học sâu; rừng ngẫu nhiên; kỹ thuật học máy; mất mát khối lượng

### 1. Đặt vấn đề

Ở Việt Nam, mỗi năm thải ra hơn 400.000 tấn cao su phế liệu. Trong đó, 50% số lốp rác thải bị vứt trên mặt đất, 40% lốp rác thải được tiêu huỷ bằng cách đốt và chỉ có 10% được tái sử dụng. Để giải quyết các vấn đề môi trường nghiêm trọng gây ra bởi sự gia tăng nhanh chóng số lượng lốp xe thải và lưu trữ lốp xe không hiệu quả thì việc sử dụng vụn cao su từ lốp xe tái chế làm cốt liệu thay thế chế tạo bê tông là một trong những cách tiếp cận mang lại hiệu quả cao kèm theo đó là có thể duy trì được việc sử dụng bền vững tài nguyên cao su.

Việc thay thế cốt liệu thô hoặc cốt liệu mịn bằng vụn cao su theo tỉ lệ khác nhau trong thành phần cấp phối làm thay đổi đáng kể các đặc tính cơ lý của bê tông chứa cốt liệu cao su. Cụ thể, giảm cường độ nén, cường độ uốn và mô đun đàn hồi so với bê tông thông thường được báo cáo trong [1]. Tuy nhiên, các nghiên cứu khác cho thấy việc thay thế này mang lại nhiều đặc tính có lợi như: Tăng độ dẻo và ngăn ngừa hư hỏng giòn [6], trọng lượng đơn vị thấp, giảm độ dẫn nhiệt [9] và tăng khả năng hấp thụ nước khi hàm lượng cao su tăng lên [11].

Xác định độ mất mát khối lượng (ML) của RC dưới tác dụng của nhiệt độ có thể kiểm tra theo tiêu chuẩn (ASTM 1064, BIS 516). Tuy nhiên, phương pháp này tiêu tốn nhiều thời gian và chi phí. Nghiên cứu các tài liệu cho thấy, đến nay vẫn chưa có một mô hình toán học nào có

**Abstract** - This paper presents an new approach using deep learning neural network (DLNN) model to predict mass loss of concrete containing waste tire rubber under effect of temperature. A structural DLNN model with 22 neurons in 3 hidden layers is proposed. A Dataset with 162 samples, including four influencing factors: Water/ cement ratio, exposure durations, temperature, replacement rubber ratio for training and validating the model has been collected from the literature. The output target is the mass loss of the RC. The DLNN model is compared with two other machine learning techniques: Random Forest and Multilayer Perceptron. The results show that the DLNN model is superior to other models and therefore it can be used as a suitable method to predict the mass loss of RC under effect of temperature.

**Key words** - Rubber concrete; Deep Learning Neural Network (DLNN); random forest; machine learning; mass loss

thể dự đoán nhanh các đặc tính của RC dưới tác dụng của nhiệt độ vì mối quan hệ giữa ML của RC và các thành phần của nó mang tính chất phi tuyến. Trong những năm gần đây, mạng nơ-ron nhân tạo được sử dụng rộng rãi như một kỹ thuật của trí tuệ nhân tạo để giải quyết các bài toán phức tạp và phi tuyến tính đã được đề xuất cho việc học (learning) và xấp xỉ hàm [12]. Gupta và cộng sự [13] đã đề xuất một mô hình mạng trí tuệ nhân tạo (ANN) một lớp ẩn để dự đoán các đặc tính của RC dưới tác dụng của nhiệt độ. Kết quả cho thấy hiệu quả của mô hình ANN trong việc dự báo các đặc tính của RC, tuy nhiên tính ổn định của mô hình vẫn chưa được tác giả đề cập. Mô hình hóa ảnh hưởng của cao su phế thải đến cường độ nén của bê tông dựa trên cơ sở dữ liệu kết quả thí nghiệm với việc thay thế một phần hoặc toàn bộ bằng ANN đã được báo cáo bởi Marijana Hadzima-Nyarko [15]. Kết quả cho thấy mô hình ANN có thể lưu trữ độ chính xác tốt với các kiến trúc khác nhau của mạng nơ-ron. Abdollahzade và cộng sự [15] xây dựng một mô hình ANN để ước tính cường độ của bê tông cao su so với hồi quy đa tuyến tính (Multilayer Regression). Kết quả cho thấy rằng mô hình ANN là một công cụ hữu hiệu có thể áp dụng để dự đoán các đặc tính cơ lý của RC.

Những năm gần đây, kỹ thuật học sâu gây được sự chú ý đối với cộng đồng nghiên cứu khoa học. Ưu điểm đáng chú ý nhất của mô hình học sâu là khả năng xây dựng các

tính chất bậc cao từ tập dữ liệu thô theo cách tăng dần. Các mô hình này có tính linh hoạt cao trong việc học và khái quát hóa để nắm bắt các mối quan hệ phức tạp ẩn trong tập dữ liệu đã thu thập. Chính vì vậy, mô hình học sâu đã vượt trội hơn các mô hình học máy truyền thống như mô hình hồi quy tuyến tính, rừng ngẫu nhiên, phân cụm K-means, vec-tơ hỗ trợ học máy, mạng nơ-ron lan truyền thuận,... trong nhiều lĩnh vực nghiên cứu.

Bài báo này đề xuất một mô hình mạng nơ-ron học sâu (DLNN) hiệu quả gồm lớp đầu vào (4 nơ-ron, 1 bias), lớp đầu ra (1 nơ-ron) và 22 nơron trong 3 lớp ẩn để dự đoán độ mất mát khối lượng của RC dưới tác dụng của nhiệt độ. Bên cạnh đó, mô hình DLNN được đề xuất so sánh với hai kỹ thuật học máy khác là Random Forest (RF) và Multilayer Perceptron (MLP).

## 2. Bộ dữ liệu và phương pháp nghiên cứu

### 2.1. Vật liệu

Xi măng được sử dụng trong các mẫu thí nghiệm là xi măng pooc-lăng thông thường theo [BIS 12269] [17], cát sông - cốt liệu mịn tự nhiên theo [BIS 383] [17]. Đá bazan nghiền - cốt liệu thô. Lớp xe phế thải được cắt nhỏ thành hạt cao su kích thước 2–5 mm theo chiều rộng và chiều dài tối đa 20 mm.

Các mẫu thí nghiệm được chế tạo với ba tỷ lệ nước/ xi măng khác nhau lần lượt là 0,35, 0,45 và 0,55; Tỷ lệ thay thế cốt liệu mịn theo khối lượng bằng sợi cao su: 0%, 5%, 10%, 15%, 20% và 25%; Nhiệt độ nung mẫu thí nghiệm: 150°C, 300°C, 450°C; Thời gian nung tương ứng 30 phút, 60 phút và 120 phút.

### 2.2. Mô tả bộ dữ liệu


Một bộ dữ liệu bao gồm 162 mẫu đã được thu thập từ các tài liệu nghiên cứu thực hiện trước đó [17] để huấn luyện và xác nhận mô hình. Bộ dữ liệu bao gồm bốn biến đầu vào (input variables): Tỷ lệ nước/ xi măng ( $X_1$ ), tỷ lệ phần trăm vụn cao su thay thế ( $X_2$ ), nhiệt độ ( $X_3$ ) và thời gian nung ( $X_4$ ). Một đặc tính quan trọng tác dụng của RC là độ mất mát khối lượng dưới tác dụng của nhiệt độ được đặt làm thông số đầu ra (output target). Để xác nhận hiệu quả của mô hình dự đoán DLNN, phần dữ liệu kiểm tra chiếm tỷ lệ 30% (49 mẫu) trong tổng số 162 mẫu. Tập dữ liệu huấn luyện được sử dụng để xác định các trọng số (hoặc tham số) của mô hình DLNN chứa 70% bộ dữ liệu (113 mẫu).

Để giảm biên độ biến động trong mô hình DLNN, cũng như nâng cao tốc độ học tập, hiệu suất, độ chính xác và tính ổn định của quá trình huấn luyện, biến đầu vào và đầu ra của tập dữ liệu đều được quy đổi lại tỷ lệ trong phạm vi đoạn [0, 1]. Phương trình quy đổi tỷ lệ của các biến được biểu diễn bên dưới:

$$y^{norm} = \frac{y - y^{min}}{y^{max} - y^{min}} \quad (1)$$

Trong đó,  $y$  là giá trị thực tế;  $y^{norm}$  là giá trị quy đổi;  $y^{min}$ ,  $y^{max}$  lần lượt là giá trị nhỏ nhất và lớn nhất của các biến đầu vào và đầu ra.

Các dữ liệu thống kê của các biến đầu vào và đầu ra được tóm tắt trong Bảng 1. Biểu đồ phân bố xác suất của các biến đầu vào và đầu ra được biểu thị trong Hình 1.



Hình 1. Biểu đồ phân bố xác suất của các biến đầu vào và đầu ra



**Bảng 1.** Bảng thống kê mô tả các biến

Biến	Mô tả	Min	Mean	Median	Max	Std	Skewness
X <sub>1</sub>	Tỉ lệ nước/xi măng	0.35	0.45	0.45	0.55	0.082	0.00
X <sub>2</sub>	Tỉ lệ thay thế vụn cao su	0.00	12.50	12.50	25.00	8.56	0.00
X <sub>3</sub>	Nhiệt độ	150.00	300.00	300.00	450.00	122.85	0.00
X <sub>4</sub>	Thời gian nung	30.00	50.00	60.00	60.00	14.18	-0.71
Y	Tỉ lệ mất mát khối lượng	1.11	3.52	3.685	6.24	1.40	0.007

### 2.3. Mạng nơ-ron học sâu

Cấu trúc cơ bản của mạng nơ-ron học sâu bao gồm ba lớp (lớp đầu vào, lớp ẩn và lớp đầu ra), các yếu tố trọng số, hàm kích hoạt (hàm chuyển đổi) và hàm học tập. Các lớp đầu vào và đầu ra là lớp đơn, chứa dữ liệu đầu vào và đầu ra mô hình tương ứng. Lớp ẩn chứa một hoặc nhiều lớp được sử dụng để xử lý dữ liệu. Các tế bào thần kinh ở các lớp này có các kết nối tiến hoặc lùi từ các tế bào thần kinh ở lớp trước đó.

Trong nghiên cứu này, thuật ngữ học sâu đề chỉ đến việc sử dụng nhiều lớp ẩn trong cấu trúc của mạng nơ-ron. Hàm ReLU (Rectified Linear Unit) được sử dụng làm hàm kích hoạt cho mô hình DLNN vì nó đơn giản hơn về mặt tính toán so với hàm truyền thống (sigmoid, tanh). Hơn nữa, vì mạng nơ-ron học sâu được đào tạo thông qua phương pháp học tập dựa trên thuật toán gradient kết hợp sự lan truyền ngược. Do đó, hàm *ReLU* có thể giúp tránh hiện tượng biến mất gradient, hiện tượng có thể cản trở đáng kể quá trình học tập [18].

Công thức toán học của hàm *ReLU* được biểu diễn như dưới đây:

$$f_s = \max(0, x) \quad (2)$$

Ưu thế vượt trội của DLNN thể hiện ở quá trình học tự động từ các mẫu huấn luyện để thiết lập các mối quan hệ giữa biến đầu vào và đầu ra [16]. Ngoài ra, DLNN không ràng buộc điều kiện hạn chế nào đối với các tham số đầu vào để xây dựng các hàm phân phối.

Một yếu tố quan trọng của mạng DLNN là việc xác định các các yếu tố trọng số phù hợp để tối ưu hóa hàm mất mát. Phương pháp kết hợp giữa truyền bình phương căn bậc hai và suy giảm gradient ngẫu nhiên với phương pháp xung lượng (Adam - Adaptive Moment Optimization) được sử dụng để xác định các giá trị tối ưu của các trọng số [19].

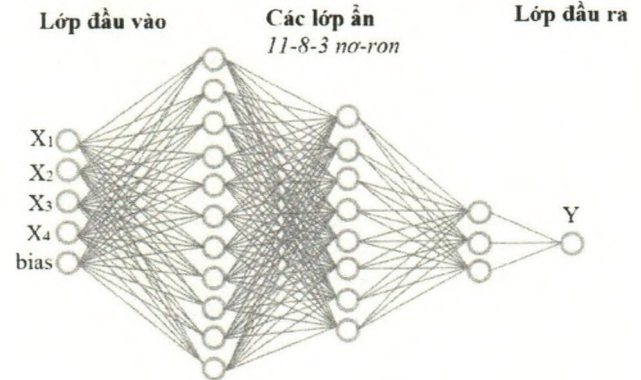
Hàm mất mát hàm là hàm sai số bình phương trung bình (Mean Square Error – MSE) thường được sử dụng trong các bài toán hồi quy khi dự đoán các giá trị liên tục. Công thức biểu diễn của MSE có dạng:

$$L(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (3)$$

Trong đó,  $y$ ,  $\hat{y}$  là các giá trị thực và giá trị dự đoán của biến đầu ra của mẫu  $i$ .

Nghiên cứu đã tiến hành thử nghiệm tính toán tối ưu số lớp ẩn trong cấu trúc của mạng DLNN và số nơ-ron trong mỗi lớp ẩn. Lựa chọn số lượng nơ-ron trong các lớp ẩn quá nhiều hoặc quá ít có thể dẫn đến việc mất ổn định của mô hình huấn luyện [12]. Quá trình thử nghiệm tối ưu được

thực hiện để kiểm tra tất cả các tổ hợp sử dụng từ 2 đến 30 nơ-ron cho mô hình trong mỗi lớp ẩn. Số lượng nơ-ron tối ưu cho cấu trúc DLNN được xác định bằng cách thực hiện xác nhận chéo 5 lần cho tập huấn luyện. Kết quả Mô hình DLNN ổn định chứa lần lượt mười một, tám và ba nơ-ron lần lượt ở ba lớp ẩn, bốn nơ-ron và một bias ở lớp đầu vào và một nơ-ron ở lớp đầu ra. Bias được xem như là một tham số bổ sung, sử dụng để điều chỉnh tham số đầu ra thông qua các trọng số liên kết các biến đầu vào với các nơ-ron. Cấu trúc hoàn chỉnh của mô hình DLNN được thể hiện trong Hình 2.



**Hình 2.** Cấu trúc của mô hình DLNN được đề xuất gồm ba lớp ẩn với 11, 8, 3 nơ-ron tương ứng trong mỗi lớp ẩn

### 2.4. Mạng Multilayer Perceptron

Multilayer Perceptron (MLP) là một dạng của mạng nơ-ron nhân tạo truyền thẳng dùng để mô hình hóa và giải quyết nhiều bài toán phức tạp trong kỹ thuật [20]. Trong bài báo này cấu trúc tối ưu của mô hình MLP để dự đoán độ mất mát khối lượng của RC gồm lớp đầu vào, lớp đầu ra và một lớp ẩn với 80 nơ-ron. Mỗi lớp bao gồm các nút được kết nối đầy đủ với tất cả các nút trong lớp tiếp theo. Hàm ReLU được sử dụng như một chức năng kích hoạt giữa các lớp. Thuật toán Bộ nhớ giới hạn Broyden-Fletcher-Goldfarb-Shanno (LBFGS) với giá trị momentum = 0,2 được chọn để tối ưu các trọng số.

### 2.5. Chỉ số đánh giá hiệu suất mô hình

Nghiên cứu sử dụng ba chỉ số thống kê là hệ số tương quan ( $R^2$ ), căn bậc hai của sai số bình phương trung bình (RMSE) và sai số tuyệt đối trung bình (MAE) để đánh giá hiệu suất của các mô hình và độ chính xác của kết quả dự đoán. Giá trị của  $R^2$  cho biết mối quan hệ thống kê giữa các giá trị thực tế và giá trị dự đoán của tham số đầu ra. Cụ thể, độ mất mát khối lượng của bê tông chứa vụn cao su dưới tác dụng của nhiệt độ. Các chỉ số RMSE và MAE biểu thị cho việc đánh giá lỗi của các mô hình dự báo. Giá trị  $R^2$  cao hơn cho thấy, hiệu suất tốt hơn của các mô hình. Về tổng thể, các chỉ số này được xác định trong các phương trình sau:

$$MAE = \frac{\sum_{i=1}^m |y_i - \hat{y}_i|}{m} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{m}} \quad (5)$$

$$R^2 = \frac{\sum_{i=1}^m (\hat{y}_i - \bar{y})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^m (\hat{y}_i - \bar{y})^2 \sum_{i=1}^m (y_i - \bar{y})^2}} \quad (6)$$

Trong đó,  $\hat{y}_i$  và  $\bar{y}tb$  được xác định tương ứng là các giá trị và giá trị trung bình dự đoán của độ mất mát khối lượng của RC;  $y_i$  và  $\bar{y}b$  lần lượt là giá trị và giá trị trung bình độ mất mát khối lượng thực tế của RC;  $m$  là số lượng mẫu dữ liệu.

**3. Kết quả và thảo luận**

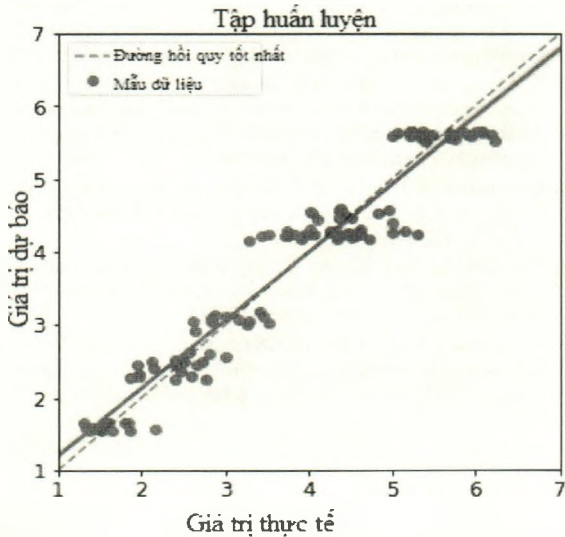
Thông qua các chỉ số thống kê  $R^2$ , MAE, RMSE, hiệu suất của các mô hình DLNN, RF và MLP đối với tập huấn luyện và kiểm tra được trình bày trong Bảng 2. Kết quả cho thấy, mô hình DLNN với 3 lớp ẩn cho giá trị  $R^2$  (0,906) cao hơn, tương ứng là các giá trị thấp hơn của RMSE và MAE (lần lượt là 0,444 và 0,387) trên tập dữ liệu kiểm tra. Mặc dù, các hệ số xác định  $R^2$  được quan sát là tương đồng đối với mô hình DLNN và MLP trong tập huấn luyện.

**Bảng 2.** Giá trị các chỉ số thống kê của mô hình DLNN, RF, MLP

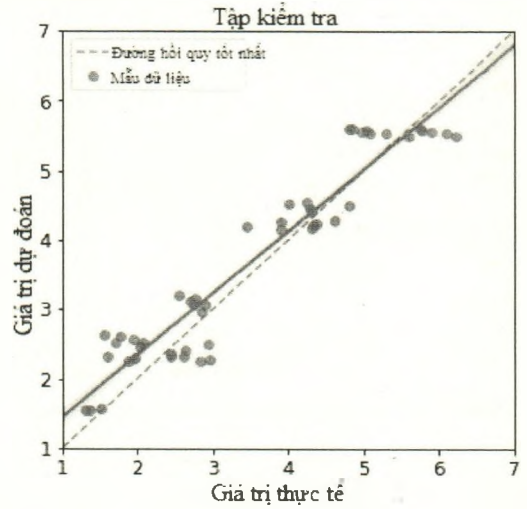
	Tập huấn luyện			Tập kiểm tra		
	$R^2$	RMSE	MAE	$R^2$	RMSE	MAE
<b>DLNN</b>	0.940	0.351	0.290	0.906	0.444	0.387
<b>RF</b>	0.971	0.237	0.190	0.850	0.562	0.475
<b>MLP</b>	0.949	0.319	0.259	0.860	0.507	0.438

Số liệu quan sát hiệu suất dự báo của mô hình DLNN và MLP cho thấy, sự vượt trội của mô hình DLNN ( $R^2 = 0,906$ ,  $RMSE = 0,444$ ,  $MAE = 0,387$ ) so với MLP ( $R^2 = 0,860$ ,  $RMSE = 0,507$ ,  $MAE = 0,438$ ) trong tập kiểm tra (Bảng 2). Điều này có thể dẫn đến kết luận rằng, cấu trúc DLNN với ba lớp ẩn có thể đạt được khả năng dự đoán tốt và ổn định hơn so với mô hình MLP chứa một lớp ẩn.

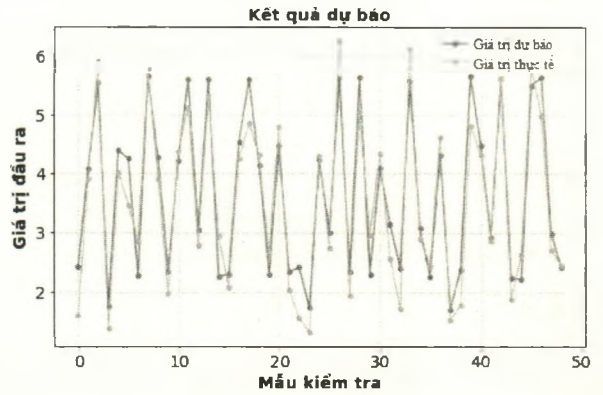
Độ lệch các giá trị dự báo của thông số đầu ra xung quanh đường hồi quy của tập huấn luyện và kiểm tra được thể hiện trong Hình 3 và 4. Giá trị thực tế và dự báo của biến đầu ra trong 49 mẫu của tập kiểm tra được minh họa trong Hình 5.



**Hình 3.** Độ lệch xung quanh đường hồi quy của mô hình DLNN trong tập huấn luyện

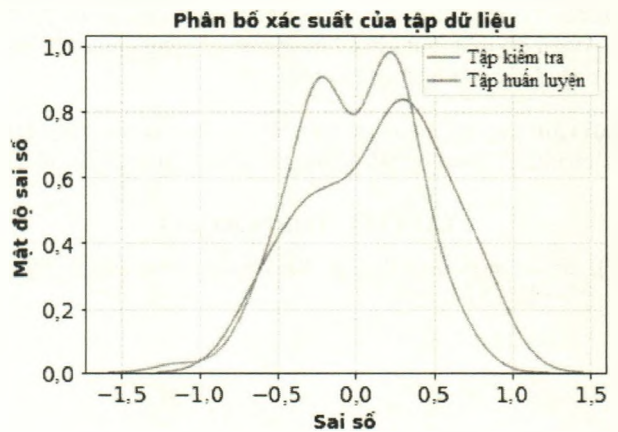


**Hình 4.** Độ lệch xung quanh đường hồi quy của mô hình DLNN trong tập kiểm tra



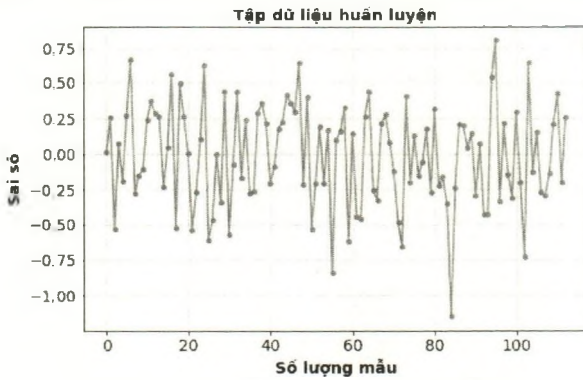
**Hình 5.** Giá trị thực tế và dự báo của biến đầu ra trong tập kiểm tra

Hình 6 mô tả mật độ phân bố xác suất sai số tuyệt đối của biến đầu ra của tập huấn luyện và tập kiểm tra. Có thể thấy rằng, mật độ phân bố xác suất của sai số tuyệt đối trong khoảng giá trị -0,5 đến 0,5 thu được trên tập huấn luyện đạt được xấp xỉ 85%, trên tập kiểm tra 70%. Giá trị sai số tuyệt đối giữa giá trị dự báo và giá trị thực tế của tập huấn luyện và tập kiểm tra được minh họa trong Hình 7 và 8.

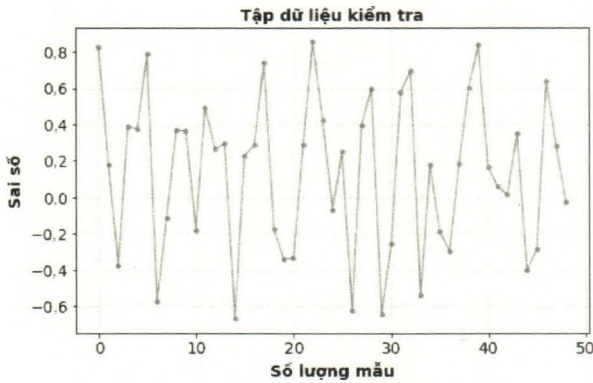


**Hình 6.** Mật độ phân bố xác suất sai số của tập huấn luyện và tập kiểm tra





Hình 7. Giá trị sai số tuyệt đối của tập huấn luyện



Hình 8. Giá trị sai số tuyệt đối của tập kiểm tra

#### 4. Kết luận

Trong nghiên cứu này một mô hình mạng nơ-ron học sâu với ba lớp ẩn đã được đề xuất và so sánh với hai kỹ thuật máy học khác là RF và MLP để dự đoán độ mất mát khối lượng của RC. Một tập dữ liệu bao gồm 162 mẫu được thu thập từ tài liệu và phục vụ cho việc huấn luyện và kiểm tra mô hình. Việc xác nhận các mô hình đạt được bằng cách sử dụng các chỉ số thống kê như  $R^2$ , RMSE, MAE. Mô hình DLNN cho giá trị  $R^2$  cao nhất là 0,906 và các giá trị RMSE và MAE tương ứng thấp nhất lần lượt là 0,444 và 0,387 trong tập kiểm tra. Kết quả cho thấy mô hình DLNN được đề xuất cho hiệu suất dự báo vượt trội, mạnh mẽ và ổn định hơn so với các mô hình khác. Do đó, DLNN có thể được coi là một cách tiếp cận phù hợp để dự đoán độ mất mát khối lượng của bê tông chứa cốt liệu cao su dưới ảnh hưởng của nhiệt độ.

**Lời cảm ơn:** Bài báo này được hỗ trợ bởi Trường Đại học Bách khoa - Đại học Đà Nẵng, mã số Đề tài: T2020-02-23.

#### TÀI LIỆU THAM KHẢO

[1] Bộ tài nguyên và môi trường. “Báo cáo môi trường quốc gia”. 2010. 109-116.

- [2] Bušić R, Milićević I, Kalman, Šipoš T, Strukar K, “Recycled Rubber as an Aggregate Replacement in Self-Compacting Concrete”. *Literature Overview Materials*. 11, 2018. 1729-1743.
- [3] D Snelson, J M Kinuthia, P Davies, S. Chang. “Sustainable construction: Composite use of tyres and ash in concrete”. *Waste Manage*. 29. 2009. 360–367.
- [4] B S Thomas, R Ch Gupta, V J Panicker, “Recycling of waste tire rubber as aggregate in concrete: durability-related performance”. *Journal of Cleaner Production*, 112, 2016, 504–513.
- [5] O Youssef, R Hassanli, J E Mills, “Mechanical performance of FRP-confined and unconfined crumb rubber concrete containing high rubber content”. *Journal of Building Engineering*. 11, 2017, 115–126.
- [6] X Shu, B Huang. “Recycling of waste tire rubber in asphalt and Portland cement concrete: an overview”, *Construction and Building Materials*. 67, 2014, 217–224.
- [7] B S Thomas, R C Gupta, P Kalla, L Csetenyi, “Strength, abrasion and permeation characteristics of cement concrete containing discarded rubber fine aggregates”, *Construction and Building Materials*, 59, 2014, 204–212.
- [8] L Zheng, X S Huo, Y Yuan, “Strength, modulus of elasticity, and brittleness index of rubberized concrete”. *Journal of Materials in Civil Engineering*. 20, 2008, 692–699.
- [9] M Zaleská, Z Pavlík, D Čížek, O Jankovský, M Pavlíková. “Eco-friendly concrete with scrap-tyre-rubber-based aggregate – Properties and thermal stability”. *Construction and Building Materials*. 225, 2019, 709-722.
- [10] A A Aliabdo, A E M A Elmoaty, M M Abdelbaser. “Utilization of waste rubber in non-structural applications”, *Construction and Building Materials*, 91, 2015, pp 195–207.
- [11] G Girskas, D Nagrockiene, “Crushed rubber waste impact of concrete basic properties”. *Construction and Building Materials*. 140, 2017, 36–42.
- [12] K. Gnana Sheela, S. N. Deepa, “Review on Methods to Fix Number of Hidden Neurons in Neural Networks”. *Mathematical Problems in Engineering*, vol. 2013, 2013, 45-56.
- [13] T Gupta, K A Patel, S Siddique, R K Sharma, S Chaudhary, “Prediction of mechanical properties of rubberised concrete exposed to elevated temperature using ANN”. *Measurement*, 147, 2019, 106870.
- [14] M Hadzima-Nyarko, E K Nyarko, N Ademović, I Milićević, T K Šipoš, “Modelling the Influence of Waste Rubber on Compressive Strength of Concrete by Artificial Neural Networks”, *Materials*, 561, 2019, 154-165.
- [15] A Abdollahzadeh, R Masoudnia, S Aghababaei, “Predict Strength of Rubberized Concrete Using Artificial Neural Network”. *Wseas Transactions on Computers*, 2, 2011, 31–40.
- [16] M Gesoglu, E Guneyisi, T Ozturan, E Ozbay, “Modeling the mechanical properties of rubberized concretes by neural network and genetic programming”, *Materials and Structures*, 43, 2010, 42-57.
- [17] T. Gupta, S. Siddique, R.K. Sharma, S. Chaudhary, “Effect of elevated temperature and cooling regimes on mechanical and durability properties of concrete containing waste rubber fiber”. *Construction and Building Materials*, 137, 2017, 35–45.
- [18] Goodfellow, I Bengio, Y Courville, “Deep Learning (Adaptive Computation and Machine Learning series)”, *The MIT Press*, 2016, ISBN-10: 0262035618.
- [19] D P Kingma, Ba J, “Adam: a method for stochastic optimization”, *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*, San Diego, 2015.
- [20] M Leshno, V Y Lin, A Pinkus, S Schocken, “Multilayer feedforward networks with a nonpolynomial activation function can approximate any function”, *Neural Network*, 6, 1993, 861–867.