

Sử dụng mô hình hồi quy mạng lưới nơ ron sâu để dự đoán cường độ chịu nén của bê tông tự lèn

Using deep neural network regression model to predict compressive strength of self-compacting concrete

Trần Thu Hiền^{a*}, Phan Ngọc Trung^b, Hoàng Nhật Đức^c
Tran Thu Hien^{a*}, Phan Ngoc Trung^b, Hoang Nhat Duc^c

^aKhoa Xây dựng, Trường Công nghệ, Trường Đại học Duy Tân, Đà Nẵng, Việt Nam

^aFaculty of Civil Engineering, The School of Engineering and Technology, Duy Tan University, Da Nang, 550000, Vietnam

^bUBND phường Thuận Phước, Quận Hải Châu, Đà Nẵng, Việt Nam

^bPeople's Committee of Thuan Phuoc Ward, Hai Chau District, Da Nang, 550000, Vietnam

^cViện Nghiên cứu và Phát triển Công nghệ cao, Trường Đại học Duy Tân, Đà Nẵng, Việt Nam

^cInstitute of Research and Development, Duy Tan University, Da Nang, 550000, Vietnam

(Ngày nhận bài: 18/03/2024, ngày phản biện xong: 22/03/2024, ngày chấp nhận đăng: 06/05/2024)

Tóm tắt

Mô hình hồi quy mạng lưới nơ ron sâu (DNNR) đã được sử dụng để dự đoán cường độ chịu nén của bê tông tự lèn. Mô hình được đào tạo và kiểm tra trên tổng số 327 điểm dữ liệu. Các biến số đầu vào bao gồm 6 hàm lượng thành phần và tuổi của bê tông theo ngày. Mô hình DNNR đã cho thấy khả năng xác định được các ảnh xạ phức tạp giữa biến đầu vào và đầu ra. Kết quả dự đoán cường độ chịu nén của bê tông tự lèn có độ chính xác cao so với kết quả thực nghiệm.

Từ khóa: mô hình hồi quy mạng lưới nơ ron sâu; cường độ chịu nén; bê tông tự lèn.

Abstract

The deep neural network regression (DNNR) model was used to predict the compressive strength of self-compacting concrete. The model was trained and tested on a total of 327 data points. Input variables include six component quantities and the age in days of concrete. The DNNR model has been shown to be capable of identifying complex mappings between input and output variables. The predicted compressive strengths of self-compacting concrete are highly accurate in comparing with to experimental results.

Keywords: deep neural network regression; compressive strength; self consolidating concrete.

1. Mở đầu

Bê tông là loại vật liệu được sử dụng phổ biến nhất trên thế giới hiện nay. Xét về mức độ tiêu

thụ bình quân trên đầu người, trên toàn thế giới, bê tông chỉ đứng sau nước ngọt [3,8]. Bê tông có nhiều ưu điểm vượt trội so với các loại vật liệu

*Tác giả liên hệ: Trần Thu Hiền

Email: tranthuhien197@gmail.com

khác: dễ chế tạo, tạo hình, phổ biến mọi nơi trên thế giới, giá thành thấp, có thể kết hợp hiệu quả với cốt thép dùng cho nhiều mục đích kết cấu khác nhau,...

Các tính năng của bê tông, ở cả trạng thái tươi lẫn đóng rắn đều có thể thay đổi rất đa dạng, đáp ứng cho từng yêu cầu cụ thể của công trình. Ngoài bê tông nặng thông thường, có thể kể đến nhiều loại bê tông đặc biệt khác như bê tông nhẹ, bê tông rất nặng, bê tông cường độ cao, bê tông tự làm sạch, bê tông chịu nhiệt... Trong đó, bê tông tự lèn được phát triển từ nhu cầu thực tiễn tại Nhật Bản những năm 1980. Sự thiếu hụt về nhân công lao động tay nghề cao, ảnh hưởng của tiếng ồn do đầm lèn khi thi công bê tông thông thường đã thúc đẩy phát triển một loại bê tông hoàn toàn mới. Loại bê tông này có khả năng tự chảy để lấp đầy ván khuôn, có khả năng vượt qua các chướng ngại vật là cốt thép mà vẫn giữ được sự đồng nhất, không bị phân tầng cả ở trạng thái tĩnh lẫn động. Đó là bê tông tự lèn. Ngoài ra, các tính chất khác của bê tông tự lèn vẫn được đảm bảo, thậm chí còn được nâng cao như chất lượng bề mặt hoàn thiện, cường độ... [9,12].

Cường độ nén (CS) của SCC là một thông số cơ học quan trọng, cơ bản cho mục đích thiết kế kết cấu. Từ cường độ chịu nén của SCC, các tính chất khác như mô đun đàn hồi, cường độ chịu kéo có thể được tính toán. Tuy nhiên, cường độ chịu nén của SCC thường được xác định bằng thực nghiệm. Phương pháp này đòi hỏi nhiều thời gian và chi phí [9]. Do đó, việc phân tích các dữ liệu thực nghiệm sẵn có và xây dựng các mô hình dự đoán cường độ nén của bê tông nói chung và SCC nói riêng sẽ rất hữu ích. Các mô hình dựa trên dữ liệu này có thể góp phần định hướng, hỗ trợ công tác thiết kế thành phần hỗn hợp SCC.

Nhiều phương pháp học máy (ML) tiên tiến khác nhau đã được đề xuất và áp dụng để mô hình hóa CS của SCC [1, 6]. Mạng lưới thần kinh được sử dụng trong [13] để dự đoán CS 28 ngày của hỗn hợp SCC thông thường và cường độ cao

có chứa tro bay. Uysal và Tanyildizi [13] đưa ra mô hình mạng thần kinh nhân tạo (ANN) để ước tính CS của hỗn hợp có chứa phụ gia khoáng và sợi polypropylene (PP) tiếp xúc với nhiệt độ cao. Vakhshouri và Nejadi [14] đã dựa vào mô hình suy luận mờ thần kinh thích ứng (ANFIS) để thực hiện việc xây dựng mô hình tính toán. Mặc dù ANFIS là một công cụ có khả năng phân tích hồi quy phi tuyến tính, giai đoạn tính toán thiết kế của nó đòi hỏi một nỗ lực đáng kể trong cấu hình các mô hình, bao gồm việc thiết lập các hàm liên quan để hình thành mô hình tính toán. Ngoài ra, nghiên cứu này chỉ sử dụng một bộ dữ liệu hạn chế, chỉ bao gồm 55 mẫu dữ liệu. Để thiết lập các mô hình ML mạnh mẽ và đáng tin cậy, nên sử dụng các bộ dữ liệu lớn hơn. Asteris và Mokos [2] cũng sử dụng ANN để ước tính CS 28 ngày của SCC; tại công trình này, các tác giả đã dựa vào một bộ dữ liệu khá lớn, bao gồm 205 bản ghi và 11 biến dự báo.

ML dựa trên ANN và lập trình di truyền (GP) đã được sử dụng trong [5] để dự đoán các đặc tính cường độ của SCC pha trộn geopolyme. Kết quả cho thấy cả ANN và GP đều có khả năng đưa ra dự đoán tốt dựa vào dữ liệu thử nghiệm. Farooq và cộng sự [6] đã nghiên cứu hiệu suất của ANN, hỗ trợ hồi quy véc tơ (SVR) và lập trình biểu hiện gen (GEP) trong việc lập mô hình một tập dữ liệu bao gồm 300 mẫu. Xi măng, tỷ lệ nước - chất kết dính, cốt liệu thô, cốt liệu mịn, tro bay và phụ gia siêu dẻo được coi là những yếu tố ảnh hưởng đến CS. Các tác giả đã chứng minh rằng GEP có thể thu được kết quả dự đoán chính xác, nhưng họ cũng chỉ ra rằng phương pháp này có thể không mang lại kết quả khả quan nếu nó bị mắc kẹt vào trong một giải pháp tối ưu cục bộ, đồng thời, tốn kém chi phí và mất nhiều thời gian.

Các mô hình Levenberg-Marquardt ANN (LM-ANN) đã được sử dụng trong [10]. Các mô hình này dựa trên thuật toán Levenberg-Marquardt (LM), bắt nguồn từ phương pháp của Newton và rất phù hợp để giảm thiểu các hàm là

tổng bình phương của các hàm phi tuyến. Nghiên cứu này đã báo cáo một mối tương quan tốt giữa quan sát và dự đoán CS của SCC. Tuy nhiên, thuật toán LM yêu cầu tính toán và lưu trữ ma trận Jacobian [10], điều này có thể làm thêm phức tạp và tốn thêm nhiều thời gian về mặt tính toán đối với bộ dữ liệu quy mô lớn và ANN sâu.

2. Dữ liệu thực nghiệm

Cường độ chịu nén của bê tông tự lèn được xác định bằng thực nghiệm trên các hỗn hợp có tỷ lệ thành phần khác nhau (Bảng 1). Tuổi bê tông khảo sát thay đổi từ 1 đến 365 ngày. Tất cả các hỗn hợp đều chứa xi măng, nước, cốt liệu lớn, cốt liệu nhỏ, tro bay loại F và phụ gia siêu dẻo. Hàm lượng tro bay và xi măng thay đổi đáng kể từ hỗn hợp chứa ít nhất đến hỗn hợp chứa nhiều nhất, cụ thể tăng lần lượt là 18.7 và 8.3 lần. Các thành phần khác, như cốt liệu lớn, cốt liệu nhỏ cũng thay đổi đáng kể giữa các hỗn hợp, khoảng 2 lần. Tương ứng với những sự thay

đổi này là sự biến thiên rất lớn về cường độ nén của bê tông tự lèn thu được, từ khoảng 4.5 đến 90.6 MPa, tức cách nhau 20 lần. Những điều này cho thấy sự đa dạng của tập dữ liệu thực nghiệm đã thu thập được. Tổng cộng tập dữ liệu này chứa 327 điểm thực nghiệm. Sự đa dạng và số lượng mẫu của dữ liệu có ý nghĩa rất lớn với việc đào tạo mô hình dự đoán.

Trong mô hình này, kết quả dự đoán của mô hình là cường độ chịu nén của bê tông tự lèn. Các biến đầu vào của mô hình chính là hàm lượng của các thành phần hỗn hợp (xi măng, nước, cốt liệu lớn, cốt liệu nhỏ, tro bay loại F và phụ gia siêu dẻo). Trong mô hình này, loại xi măng hay loại phụ gia siêu dẻo... sử dụng không được xét đến. Ngoài ra, cường độ chịu nén của bê tông phụ thuộc rất lớn vào tuổi của bê tông. Chính vì vậy, đây cũng được xem là biến đầu vào của mô hình. Như vậy, tổng cộng mô hình có 7 biến đầu vào.

Bảng 1. Các biến số đầu vào của mô hình [5]

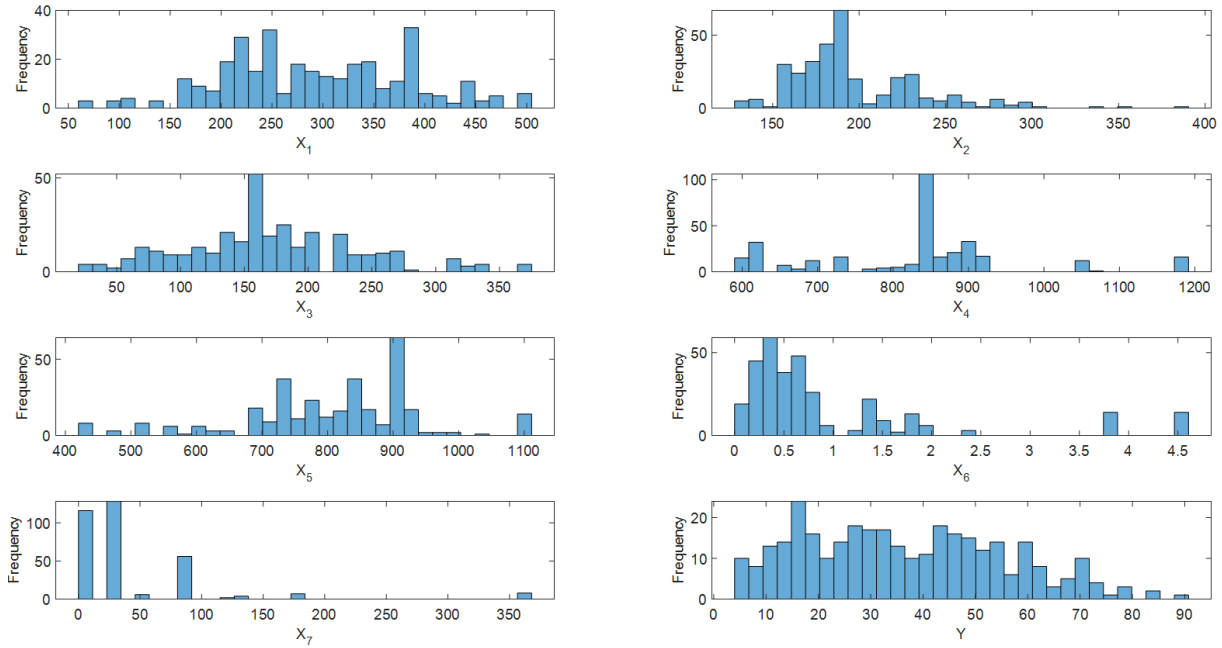
Biến số	Ký hiệu	Đơn vị	Min	Trung bình	Tiêu chuẩn	Max
Xi măng	X1	kg/m ³	61,00	293,08	89,78	503,00
Nước	X2	kg/m ³	132,00	197,00	37,62	590,39
Tro bay loại F	X3	kg/m ³	20,00	170,23	69,68	373,00
Cốt liệu thô	X4	kg/m ³	590,00	828,34	137,30	1190,00
Cốt liệu mịn	X5	kg/m ³	434,00	807,47	135,80	1109,00
Phụ gia siêu dẻo	X6	%	0,00	0,98	1,11	4,60
Tuổi của bê tông	X7	ngày	1,00	44,31	63,76	365,00
Cường độ nén	Y	MPa	4,44	36,45	19,07	90,60

Tần suất xuất hiện của từng biến số đầu vào (X1 đến X7) và của biến đầu ra (Y) được tính theo tỷ lệ % và thể hiện trên Hình 1. Thấy rằng các biến số xuất hiện rời rạc, và hoàn toàn không đồng đều.

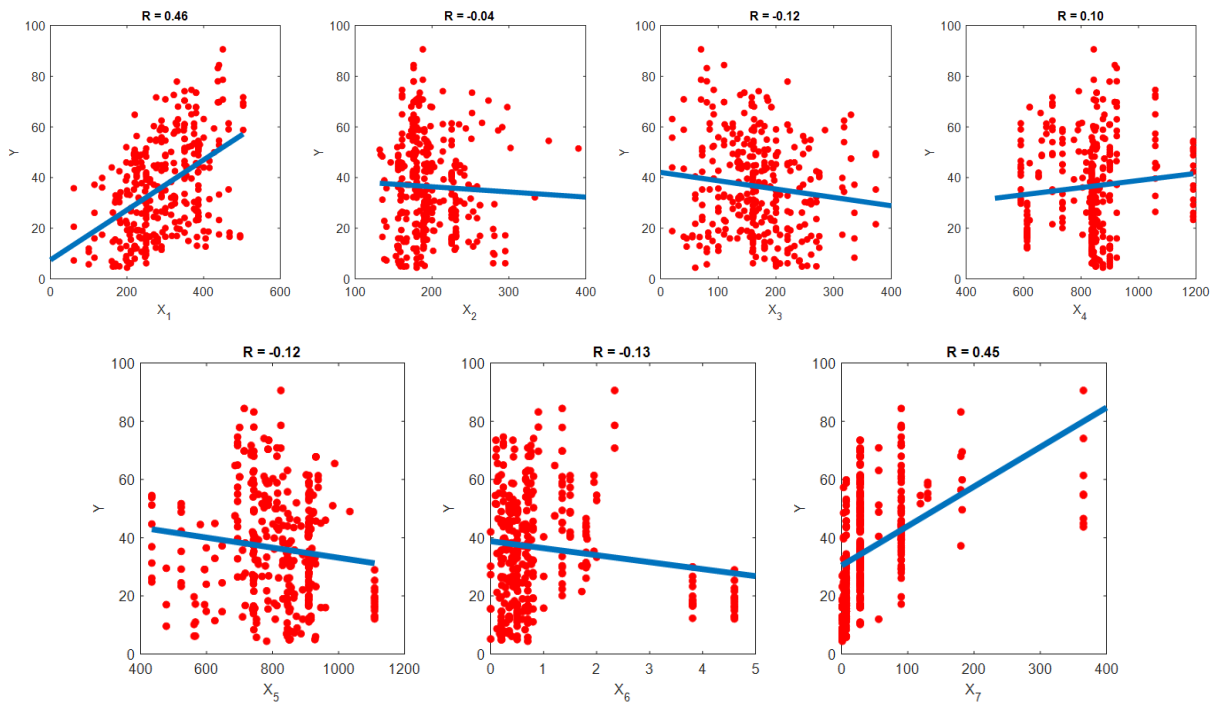
Sự ảnh hưởng giữa từng biến dự đoán với biến đầu ra của mô hình, tức cường độ chịu nén của SCC - được thể hiện bằng bảy biểu đồ trên Hình 2. Có thể thấy mối quan hệ tương quan giữa tất cả bảy biến dự đoán với cường độ chịu nén hoàn toàn không theo quy luật tuyến tính. Nghĩa

là, cường độ chịu nén phụ thuộc vào các biến đầu vào theo các hàm phi tuyến.

Như vậy, để dự đoán một cách chính xác cường độ chịu nén của SCC cần sử dụng đến các phương pháp phân tích phi tuyến tiên tiến. Cụ thể, trong nghiên cứu này, mô hình hồi quy mạng lưới nơ ron sâu (DNNR) sẽ được thử nghiệm và kiểm tra. Để thử nghiệm, huấn luyện mô hình, 90% tập dữ liệu được sử dụng. Còn lại 10% tập dữ liệu được dùng để kiểm tra mô hình thu được. Việc chia tập dữ liệu thành hai tập con được thực hiện một cách hoàn toàn ngẫu nhiên.



Hình 1. Tần suất xuất hiện của 7 biến số đầu vào và biến đầu ra của tập dữ liệu



Hình 2. Quan hệ tương quan giữa 7 biến số đầu vào và biến đầu ra của tập dữ liệu

3. Mô hình hồi quy mạng lưới nơ ron sâu

Một mô hình DNNR có cấu trúc điển hình như sau: một lớp đầu vào, một tập hợp các lớp ẩn và một lớp đầu ra. Lớp đầu vào có nhiệm vụ nhận các tín hiệu đầu vào. Các lớp ẩn chứa các đơn vị xử lý thông tin riêng lẻ, gọi là nơ-ron, được tổ chức thành các lớp khác nhau. Mỗi lớp

ẩn này đóng vai trò là toán tử kỹ thuật tính năng tự trị. Các biểu diễn cấp cao ngày càng tăng của tập dữ liệu gốc dần dần được chất lọc qua các lớp ẩn.

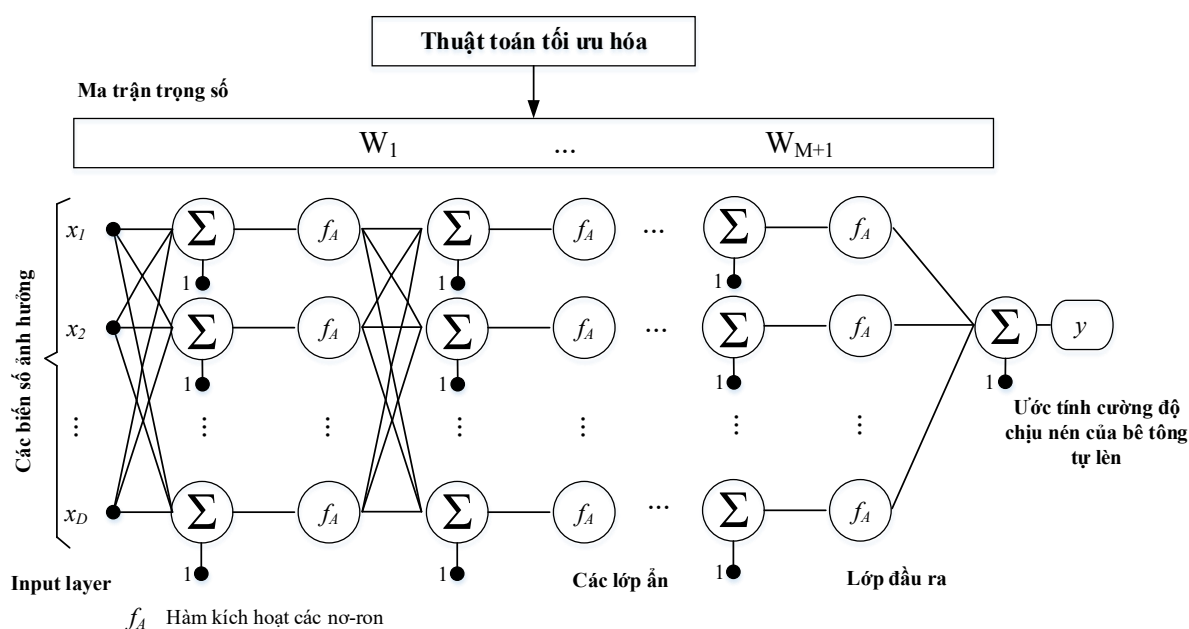
Nhờ cấu trúc xếp chồng lên nhau của các lớp ẩn mà mô hình DNNR có khả năng biểu diễn ánh xạ của các hàm đa biến và phức tạp. Mỗi quan

hệ ánh xạ phức tạp được xử lý qua các hàm kích hoạt phi tuyến tính (f_A) bằng các nơ-ron của các lớp ẩn. Một số hàm kích hoạt phi tuyến f_A phổ biến là sigmoid logistic (Sigmoid), sigmoid tiếp tuyến hyperbolic (Tanh) và kích hoạt đơn vị tuyến tính (ReLU).

Với lớp đầu ra, hàm tuyến tính được sử dụng để ước tính giá trị của cường độ chịu nén. Việc tính toán của một mô hình DNNR gắn liền với sự điều chỉnh các ma trận trọng số, đại diện cho toàn bộ cấu trúc mô hình. Nghiên cứu này sử

dụng ước tính thời điểm thích ứng tiên tiến nhất (Adam) để hoạt động DNNR.

Cấu trúc của mô hình Hồi quy mạng lưới nơ-ron sâu (DNNR) sử dụng trong nghiên cứu này được thể hiện ở Hình 3. Lớp đầu vào gồm D nút, chính là số lượng biến dự đoán. Lớp này nhận các thông tin liên quan đến thành phần hỗn hợp và tuổi của bê tông. Tiếp theo, thông tin nhận được trong lớp đầu tiên được xử lý nhờ một tập hợp gồm M lớp ẩn. Các giá trị cường độ chịu nén dự đoán sẽ thu được ở lớp đầu ra của mạng.



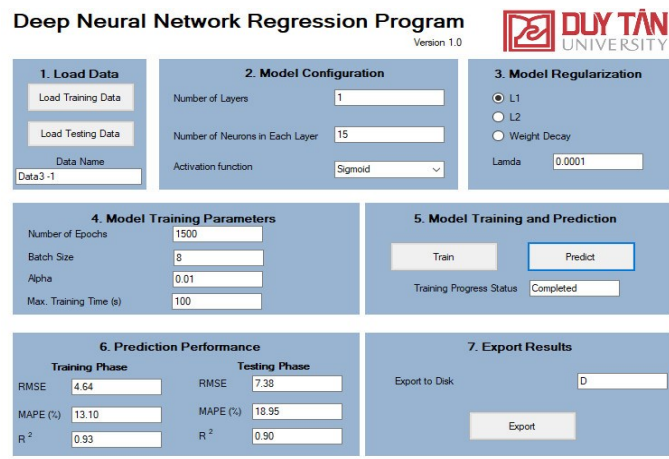
Hình 3. Cấu trúc của mô hình DNNR

4. Kết quả và thảo luận

Chương trình DNNR được xây dựng trong Visual C#. NET framework 4.8 và môi trường phát triển tích hợp Microsoft Visual Studio (IDE). Giao diện người dùng của chương trình hiển thị trên Hình 4.

Mục 1 cho phép người dùng tải dữ liệu đầu vào, gồm tập dữ liệu huấn luyện và tập dữ liệu kiểm tra. Mục 2 cho phép tùy chỉnh cấu trúc của mô hình DNNR gồm số lớp ẩn, số nơ-ron trong mỗi lớp ẩn và dạng của hàm kích hoạt phi tuyến. Ba chức năng kích hoạt được chương trình hỗ trợ

là sigmoid, tanh và ReLU. Mục 3 cho phép lựa chọn các phương thức chuẩn hóa giảm dần, gồm L1, L2 hoặc trọng số. Phương thức chuẩn hóa giúp giảm bớt tình trạng thừa. Mục 4 cho phép tinh chỉnh số vòng lặp, kích thước lô, tốc độ học tập (α) và thời gian đào tạo tối đa (được đo bằng giây). Với các tham số đã được thiết lập, chương trình DNNR tiến hành giai đoạn đào tạo và kiểm tra mô hình. Khi giai đoạn đào tạo và kiểm tra kết thúc, kết quả liên quan đến hiệu suất dự đoán (RMSE, MAPE, R^2) được thể hiện ở Mục 6. Trong mục 7, người dùng có thể xuất kết quả ma trận các trọng số của mô hình DNNR.



Hình 4. Giao diện người dùng (GUI) của chương trình DNNR [5]

Các thông số dùng để thiết lập mô hình dự đoán cường độ chịu nén của bê tông tự lèn bằng DNNR được thống kê trong Bảng 2.

Bảng 2. Thông số của mô hình DNNR

Số lớp ẩn	1
Số nơ ron mỗi lớp ẩn	15
Dạng hàm kích hoạt	Sigmoid
Mô hình chuẩn hóa	L1
Hệ số lamda	0.0001
Số vòng lặp	1500
Kích thước lô	8
Alpha	0.01
Thời gian đào tạo tối đa	100 s

Hiệu quả dự đoán của mô hình được thể hiện rõ hơn trong Bảng 3 và Hình 5. Nhìn chung, mô hình DNNR có khả năng dự đoán tốt cường độ chịu nén của SCC trong tập dữ liệu đã thu thập.

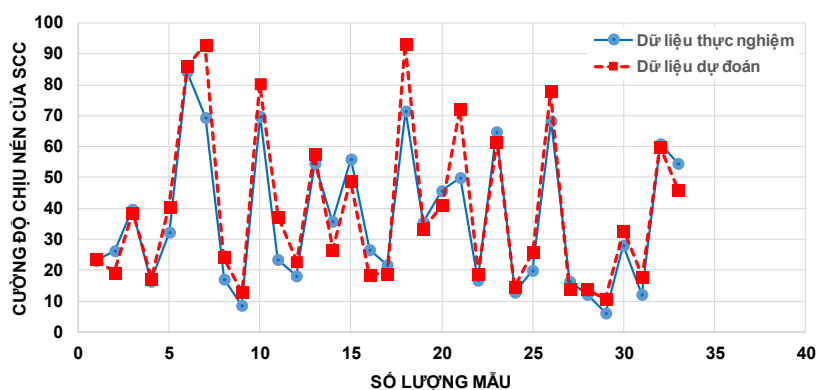
Hệ số xác định (R^2) nằm trong khoảng từ 0,90 đến 0,93. Độ chính xác của mô hình trên tập huấn luyện tốt hơn một chút so với trên tập kiểm tra - điều này hoàn toàn logic.

Bảng 3. Hiệu suất của mô hình DNNR

	RMSE	MAPE	R^2
Tập huấn luyện	4.64	13.10%	0.93
Tập kiểm tra	7.38	18.95%	0.90

Hình 5 biểu diễn kết quả dự đoán của mô hình DNNR so với kết quả thực nghiệm. Các điểm dữ liệu dự đoán (màu đỏ) rất gần với dữ liệu thực nghiệm (màu xanh). Tuy nhiên, có thể quan sát thấy một xu hướng có vẻ hình hơn: kết quả dự

đoán lớn hơn so với thực nghiệm. Xu hướng này trong thực tế sẽ nghiêng theo chiều hướng nguy hiểm do sự dự báo hơi vượt khả năng chịu nén thực tế của bê tông.



Hình 5. Kết quả thực nghiệm và dự đoán cường độ chịu nén của SCC

5. Kết luận

Mô hình hồi quy mạng lưới nơ ron sâu đã cho phép dự đoán khá chính xác cường độ nén của bê tông tự lèn. Hệ số xác định đạt trên 0.9. Điều này cho thấy khả năng mạnh mẽ của DNNR trong việc biểu diễn các ánh xạ phi tuyến, đa biến, phức tạp.

Triển vọng tiếp theo của nghiên cứu này là tiếp tục thu thập các dữ liệu thực nghiệm liên quan đến cường độ chịu nén của bê tông tự lèn. Từ đó, kiểm chứng và tăng mức độ chính xác của mô hình đã sử dụng. Ngoài ra, có thể xây dựng các hàm tối ưu nhằm đề xuất các biến đầu vào hiệu quả nhất cho mô hình. Và mục tiêu cuối cùng của nghiên cứu mô phỏng là áp dụng được mô hình hồi quy mạng lưới nơ ron sâu (DNNR) vào thực nghiệm, dự đoán cường độ chịu nén của bê tông tự lèn, làm một cơ sở để hỗ trợ công tác thiết kế cấp phối bê tông.

Reference

- [1] Asteris, P.G., Roinos, K. (2016). Prediction of Self-Compacting Concrete Strength Using Artificial Neural Networks. *European Journal of Environmental and Civil engineering* (20(sup1)), 102-122.
- [2] Asteris, P.G., Mokos, V.G. (2020). Concrete compressive strength using artificial neural networks. *Neural Computing and Applications* 32, 11807-11826.
- [3] Bhagath Singh, G.V.P., Durga Prasad, V. (2024). Environmental impact of concrete containing high volume fly ash and ground granulated blast furnace slag. *Journal of Cleaner Production Volume* (448), 141729.
- [4] Đức, H.N., Diệu, B.T. (2018). Predicting earthquake-induced soil liquefaction based on a hybridization of kernel Fisher discriminant analysis and a least squares support vector machine: a multi-dataset study. *Bulletin of Engineering Geology and the Environment* (77(1)), 191-204.
- [5] Đức, H.N. (2022). Machine Learning-Based Estimation of the Compressive Strength of Self-Compacting Concrete: A Multi-Dataset Study. *Mathematics* (10(20)), 3771.
- [6] Farooq, F.; Czarnecki, S.; Niewiadomski, P.; Aslam, F.; Alabduljabbar, H.; Ostrowski, KA; 'Sliwa-Wieczorek, K.; Nowobilski, T.; Malazdrewicz, S. (2021). A Comparative Study for the Prediction of the Compressive Strength of Self-Compacting Concrete Modified with Fly Ash. *Materials* (14(17)),4934.
- [7] Flatt, R.J., Aïtcin, P.C. (2016). *Science and Technology of Concrete Admixtures*. Cambridge: Woodhead.
- [8] Flower, D., Sanjayan, J. (2007). Green house gas emissions due to concrete manufacture. *Int J LCA* (12), 282-288.
- [9] Khayat, K.H., De Shutter, G. (2014). *Mechanical Properties of Self-Compacting Concrete*. London: Springer.
- [10] Ni, H.G., Wang, J.Z. (2000). Prediction of compressive strength of concrete by neural networks. *Cement and Concrete Research* 30(8), 1245-1250.
- [11] Pazouki, G., Golafshani E., Behnood, A. (2021). Predicting the compressive strength of self-compacting concrete containing Class F fly ash using metaheuristic radial basis function neural network. *Structural Concrete* 23(2).
- [12] Sharbaf, M., Najimi, M., Ghafoori, N. [2022]. A comparative study of natural pozzolan and fly ash: Investigation on abrasion resistance and transport properties of self-consolidating concrete. *Construction and Building Materials* (346), 128330.
- [13] Uysal, M., Tanyildizi, H. (2012). Estimation of compressive strength of self compacting concrete

containing polypropylene fiber and mineral additives exposed to high temperature using artificial neural network. *Construction and Building Materials* (27(1)), 404-414.

[14] Vakhshouri, B., Nejadi, S. (2018). Prediction of compressive strength of self-compacting concrete by ANFIS models. *Neurocomputing* (280(6)), 13-22.