

## **ỨNG DỤNG THUẬT TOÁN CNN-1D ĐỂ DỰ ĐOÁN CƯỜNG ĐỘ CHỊU NÉN CỦA BÊ TÔNG SỬ DỤNG CHO CÁC CÔNG TRÌNH BIỂN**

**Nguyễn Thị Thu Hương<sup>1</sup>, Nguyễn Thị Phương Thảo<sup>2</sup>**

**Tóm tắt:** Cường độ chịu nén của bê tông là một chỉ tiêu quan trọng, đóng vai trò then chốt trong việc xác định khả năng chịu tải và độ bền của công trình. Đối với bê tông thường, cường độ nén có thể dự đoán thông qua các công thức thực nghiệm đã được xây dựng có sẵn. Với bê tông ứng dụng cho công trình biển, việc dự đoán được cường độ chịu nén khó khăn hơn do tổ hợp các thành phần vật liệu phức tạp và không có các công thức thực nghiệm có sẵn cho loại bê tông này. Bài báo đề cập đến việc sử dụng các mô hình học máy với thuật toán CNN-1D để dự đoán cường độ chịu nén của bê tông có sử dụng các loại phụ gia ứng dụng cho công trình biển. Bộ dữ liệu chạy mô hình gồm 1093 mẫu chia thành 2 phần theo tỷ lệ train:test là 70:30, ngoài ra sử dụng 42 mẫu để kiểm định độ chính xác của mô hình. Kết quả chạy thử cho thấy độ chính xác của mô hình xây dựng được tương đối tốt. Kết quả mô hình có thể giúp cho các nhà nghiên cứu trong lĩnh vực chuyên ngành sử dụng như một công cụ hỗ trợ quá trình tính toán xác định thành phần bê tông, giảm thời gian và nâng cao chất lượng thực nghiệm.

**Từ khóa:** Học máy, thuật toán, dự đoán, cường độ nén của bê tông, công trình biển.

### **1. ĐẶT VẤN ĐỀ**

Bê tông là loại vật liệu xây dựng được sử dụng rộng rãi nhất trên thế giới do có nhiều ưu điểm so với các vật liệu khác. Để đảm bảo rằng các kết cấu công trình hoạt động an toàn và ổn định trong suốt thời gian sử dụng theo tuổi thọ thiết kế, việc nghiên cứu các tính chất cơ học của bê tông là rất quan trọng, trong đó cường độ nén là chỉ số quan trọng nhất vì nó liên quan trực tiếp đến sự an toàn của công trình. Việc đánh giá cường độ của bê tông nhanh chóng và chính xác có ảnh hưởng lớn đối với chất lượng và tiến độ thi công của công trình. Tuy nhiên, bê tông được tạo thành từ các thành phần khác nhau, ví dụ: cốt liệu thô/mịn, xi măng, phụ gia, v.v., đặc biệt bê tông ứng dụng cho các công trình biển thường sử dụng kết hợp một số loại phụ gia để tăng độ bền khi chịu các tác động phá hoại mãnh liệt. Một hệ thống phức tạp như vậy khiến việc dự đoán chính xác cường độ nén của loại bê tông này trở thành một thách thức lớn do chưa có các công thức thực nghiệm được xây dựng sẵn. Phương pháp truyền thống nhất để

đo cường độ nén của bê tông là bằng thử nghiệm vật lý, bằng cách chế tạo khối thử nghiệm bê tông hình khối hoặc hình trụ theo thông số thiết kế, có thể đo bằng máy thử nén sau một thời gian bảo dưỡng tiêu chuẩn. Tuy nhiên, cách làm này tốn kém cả về thời gian và tiền bạc nên hiệu quả làm việc sẽ rất thấp. Khác với các cách thực nghiệm truyền thống, một số phương pháp hồi quy thực nghiệm được đề xuất để dự đoán cường độ chịu nén của bê tông với tỷ lệ hỗn hợp thiết kế cho trước của các thành phần khác nhau trong bê tông (B. Bharatkumar, et al 2001; S. Bhanja, et al 2002; M. F. M. Zain, et al 2009; De-Cheng Fenga, et al 2020). Tuy nhiên, quan hệ giữa cường độ bê tông với các thành phần của nó không thể hiện mối quan hệ tuyến tính đơn giản mà là mối quan hệ phi tuyến tính phức tạp, điều này khiến cho việc xác định các biểu thức hồi quy chính xác cho quan hệ này là vô cùng khó khăn (Zhu Xue-bing, 2011).

Trong những năm gần đây, với sự phát triển của trí tuệ nhân tạo (Artificial Intelligence - AI), việc sử dụng kỹ thuật học máy (Machine Learning - ML) để dự đoán cường độ nén của bê tông đang là xu hướng. ML là một nhánh của AI

---

<sup>1</sup> Khoa Công trình – Trường Đại học Thủy lợi

<sup>2</sup> Khoa Công nghệ thông tin – Trường Đại học Thủy lợi

và có thể được sử dụng cho một số bài toán, ví dụ: phân loại, hồi quy, phân cụm, v.v. Dự đoán cường độ nén của bê tông là một dạng bài toán hồi quy trong học máy. So với các phương pháp truyền thống, các thuật toán học máy có thể tự học từ dữ liệu đầu vào và đưa ra kết quả đầu ra có độ chính xác cao (H. Salehi, 2008; Daihong Li, et al 2023).

Cho đến nay, nhiều thuật toán học máy đã được sử dụng để dự đoán cường độ nén bê tông, trong đó một số thuật toán cho kết quả tốt như Mạng thần kinh nhân tạo (Artificial Neural Network - ANN) và Rừng ngẫu nhiên (Random forest – RF). Ngoài ra, một số phương pháp học kết hợp (Serkan Kiranyaz, 2019) được áp dụng vào bài toán này và cho độ chính xác cao hơn, hiệu quả hơn. Ý tưởng cơ bản của mô hình học kết hợp là sử dụng dữ liệu để huấn luyện một số mô hình học yếu, sau đó kết hợp những mô hình yếu này để xây dựng một mô hình mạnh mẽ hơn. Những mô hình yếu dựa trên các thuật toán học khác nhau, ví dụ: ANN hoặc FR, SVM, ... nhưng khi kết hợp chúng lại có thể cải thiện độ chính xác dự đoán và độ tin cậy của mô hình.

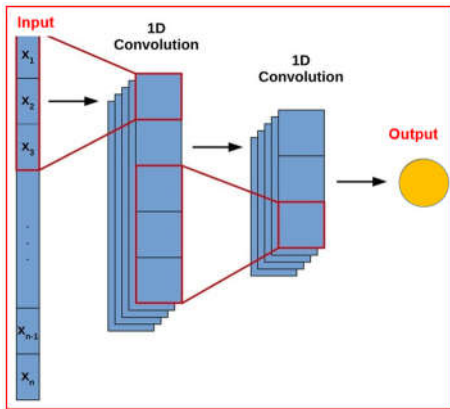
Trong những năm gần đây, sự phát triển của các mô hình học sâu đã mở ra một hướng nghiên cứu mới ứng dụng giải quyết các bài toán chuyên ngành. Các mô hình học sâu với cốt lõi là mạng nơ-ron và các lớp riêng biệt để trích xuất đặc trưng từ dữ liệu đã giúp giải quyết được nhiều bài toán với dữ liệu khó cũng như mô tả được mối quan hệ phi tuyến giữa đầu vào và đầu ra. Không những thế, với ưu điểm có thể thiết lập một mô hình sâu, nhiều lớp với các cách hiệu chỉnh tham số khác nhau phù hợp với từng loại dữ liệu, các mô hình học sâu cho phép thiết kế và xây dựng những mô hình từ đơn giản đến phức tạp để giải quyết các bài toán cụ thể. Một nhánh của học sâu được ứng dụng nhiều đặc biệt trong thị giác máy tính là mô hình mạng nơ-ron tích chập (CNN) với các lớp tích chập cho phép trích rút đặc trưng của dữ liệu nhiều chiều như hình ảnh hoặc video. Với ưu điểm học được rất tốt các đặc trưng của dữ liệu, mô hình này đã thay thế hoàn toàn các mô hình cũ trong bài toán thị giác

máy tính nói chung và bài toán nhận dạng hình ảnh nói riêng.

Một biến thể của mô hình CNN với các lớp tích chập một chiều (Conv1D) cũng đang thu hút sự chú ý của các nhà khoa học. Lớp Conv1D là lớp tích chập với các bộ lọc một chiều được sử dụng để trích xuất đặc trưng trong một số dữ liệu có dạng vec-tơ một chiều, dữ liệu chuỗi thời gian, dữ liệu âm thanh,.. Trong bài báo này, thuật toán Convolution Neural Network (CNN) 1D được sử dụng và kết hợp với 1093 bộ dữ liệu thực nghiệm bê tông để phát triển mô hình dự đoán cường độ nén bê tông và 42 mẫu được sử dụng để kiểm tra độ chính xác của mô hình.

## **2. GIỚI THIỆU THUẬT TOÁN MẠNG THẦN KINH TÍCH HỢP (CNN)**

Gần đây, sự phát triển của các mô hình học sâu đã mở ra một kỷ nguyên mới trong việc giải quyết các nhiệm vụ dự đoán và phân loại. Một trong những mạng nơ-ron được sử dụng nhiều nhất trong thời gian gần đây và thu được nhiều kết quả tốt là mạng nơ-ron tích chập – CNN. CNN được viết tắt của Convolutional Neural Network hay còn được gọi là mạng nơ-ron tích chập (Serkan Kiranyaz, et al 2019), là một trong những mô hình học sâu cực kỳ tiên tiến, bởi chúng cho phép xây dựng những hệ thống có độ chính xác cao và thông minh. CNN là mạng nơ-ron ưu việt giúp học tốt trên dữ liệu lưới hai chiều. Với sự ra đời của nhiều kiến trúc CNN khác nhau, nhiều nhiệm vụ phát hiện, nhận dạng và phân loại hình ảnh đã được giải quyết dễ dàng mà không cần trích xuất các đặc trưng trước khi đưa chúng vào mô hình. Ưu điểm của CNN là nó kết hợp việc trích xuất đặc trưng với việc học tập dựa trên các đặc trưng này trong một mô hình duy nhất. Mạng nơ-ron tích chập dạng này thường được gọi là "CNN-2D". Một biến thể của CNN-2D là CNN-1D đã được đề xuất để giúp tìm hiểu các đặc trưng trên dữ liệu chuỗi hoặc vectơ một chiều, phù hợp với bài toán trong nghiên cứu. Ưu điểm của CNN-1D là số lượng tham số và độ phức tạp tính toán ít hơn nhiều so với CNN-2D. Mô hình CNN-1D cho bài toán dự đoán cường độ bê tông được mô tả trên Hình 1 như sau:



Hình 1. Mô hình CNN-1D cho bài toán dự đoán cường độ bê tông

Hàm kích hoạt sử dụng cho mô hình CNN-1D trong nghiên cứu là hàm ReLU (Rectified Linear Unit). Đây là hàm kích hoạt rất được ưa chuộng sử dụng trong các mô hình học máy. Công thức hàm ReLU như sau:  $f(x) = \max(0, x)$ , trong đó: Nếu  $(x)$  là số dương, thì  $f(x) = x$ ; Nếu  $(x)$  là số âm, thì  $f(x) = 0$ .

Ưu điểm của hàm ReLU là tính đơn giản và do đó giúp tăng tốc quá trình huấn luyện mô hình. Tiếp theo hàm ReLU không gặp vấn đề mất gradient như hàm Sigmoid và ReLU giúp mạng nơ-ron có khả năng học được các hàm phi tuyến.

### 3. CƠ SỞ DỮ LIỆU THỰC NGHIỆM

#### 3.1. Mô tả dữ liệu

Để xây dựng mô hình dự đoán cần một lượng lớn dữ liệu thực nghiệm về cường độ chịu nén của bê tông. Để đạt được mục tiêu này, chúng tôi đã thu thập 1030 kết quả thí nghiệm cường độ chịu nén của bê tông được công bố tại các nguồn dữ liệu mở trên internet (I.-C. Yeh, 2008; De-Cheng Fenga, et al 2020) có tính tương tự với dữ liệu trong nghiên cứu

của tác giả, kết hợp với 105 dữ liệu từ các thí nghiệm thực tế của tác giả (Nguyễn Thị Thu Hương, 2016). Trong 105 mẫu từ tập dữ liệu trong nghiên cứu của tác giả sẽ được tách thành hai phần, 63 mẫu kết hợp với bộ dữ liệu tham khảo từ internet để huấn luyện và kiểm thử mô hình, 42 mẫu để xác thực lại độ chính xác của mô hình một lần nữa trước khi đưa ra đánh giá cuối cùng về chất lượng mô hình.

Việc sử dụng kết hợp hai bộ dữ liệu từ nguồn dữ liệu mở và dữ liệu thực nghiệm của tác giả sẽ giúp đảm bảo tính chính xác khi áp dụng các mô hình học máy (thường cần một bộ dữ liệu đủ lớn) và tương thích với kết quả thu được trong nghiên cứu của tác giả, từ đó có thể được áp dụng trong các nghiên cứu tiếp theo ở Việt Nam. Bê tông được thử nghiệm có thành phần gồm xi măng Pooclang, silica fume, tro bay, nước, phụ gia siêu dẻo, cốt liệu thô (đá), cốt liệu mịn (cát), và được bảo dưỡng trong điều kiện chuẩn một thời gian trước khi thí nghiệm nén mẫu. Sau đó, cường độ nén của bê tông đạt được thông qua quy trình thử nghiệm nén điển hình của mẫu hình trụ có chiều cao 150 mm. Tổng cộng có 9 tham số trong bộ dữ liệu thử nghiệm. Tên, đơn vị, giá trị tối thiểu/tối đa, giá trị trung bình và độ lệch chuẩn (SD) của các tham số thử nghiệm được liệt kê trong Bảng 1. Trước khi bắt đầu quá trình học, trước tiên phải xác định các biến đầu vào và đầu ra. Thành phần vật liệu và thời gian bảo dưỡng đều ảnh hưởng đến cường độ nén cuối cùng của bê tông, do đó tổng cộng có 8 biến đầu vào ( $X = \{X1; X2; \dots; X8\}$ ) và 1 biến đầu ra ( $Y$ ) được xem xét trong nghiên cứu này và được trình bày trong Bảng 1.

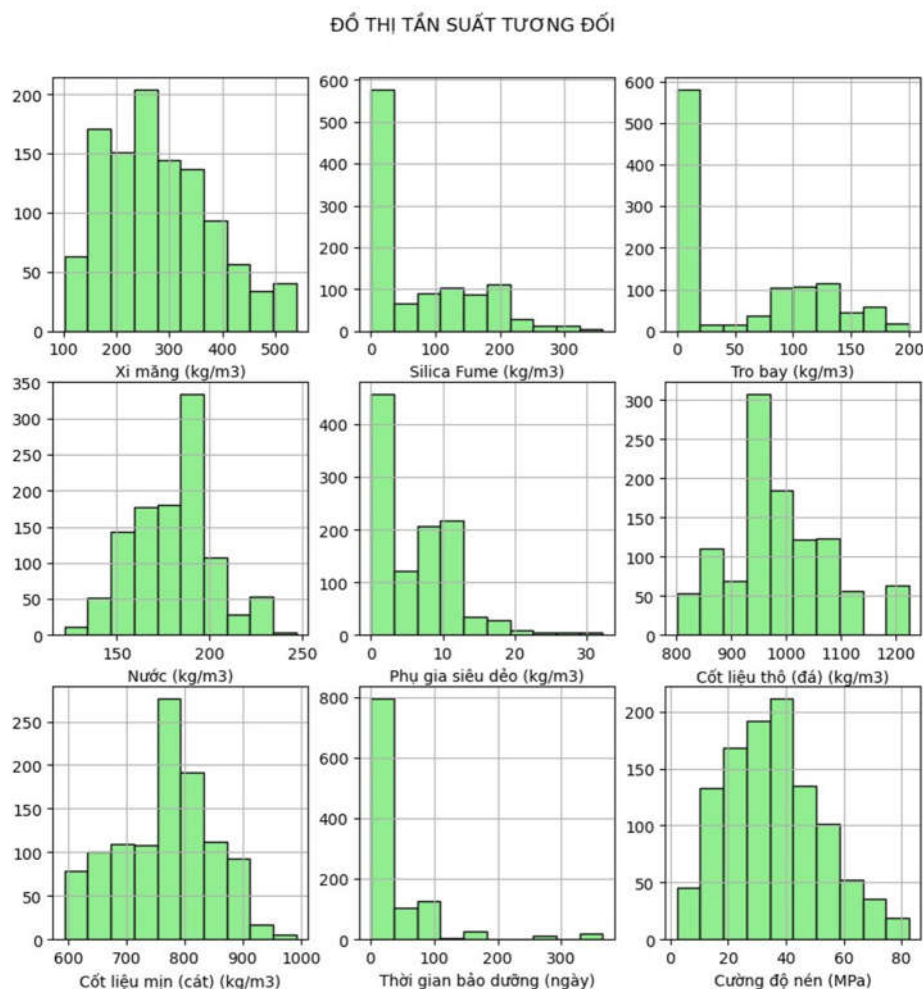
Bảng1: Các thông số trong thí nghiệm cường độ nén của bê tông

Tham số	Đơn vị	Min	Max	Mean	SD	Kiểu
X1: Xi măng	kg/m <sup>3</sup>	102,00	540,00	281,17	104,51	Đầu vào
X2: Nước	kg/m <sup>3</sup>	121,75	247,00	181,57	21,36	Đầu vào
X3: Cốt liệu thô (đá)	kg/m <sup>3</sup>	801,00	1145,00	972,92	77,75	Đầu vào
X4: Cốt liệu mịn (cát)	kg/m <sup>3</sup>	594,00	992,60	773,58	80,18	Đầu vào
X5: Phụ gia siêu dẻo	kg/m <sup>3</sup>	0,00	32:20	6 giờ 20	5,97	Đầu vào
X6: Silica fume	kg/m <sup>3</sup>	0,00	359,40	73,90	86,28	Đầu vào
X7: Tro bay	kg/m <sup>3</sup>	0,00	200,10	54,19	64:00	Đầu vào
X8: Thời gian bảo dưỡng	ngày	1,00	365,00	45,66	63,17	Đầu vào
Y: Cường độ nén	MPa	2,33	82,60	35,82	16,71	Đầu ra

### 3.2. Trực quan hóa dữ liệu

Phân bố thống kê của các tham số liên quan

được vẽ trong Hình 2, có thể giúp chúng ta có quan sát trực tiếp các thông số.




Hình 2. Phân phối thống kê các biến đầu vào/đầu ra

## 4. MÔ HÌNH DỰ ĐOÁN CƯỜNG ĐỘ NÉN CHO BÊ TÔNG DỰA TRÊN THUẬT TOÁN MẠNG NƠ-RON TÍCH CHẬP (CNN)

### 4.1. Xây dựng mô hình

Trước khi đưa vào mô hình, dữ liệu được chuẩn hóa với hàm StandardScaler trong thư viện sklearn.preprocessing để tạo ra một phân phối có trung bình bằng 0 và độ lệch chuẩn bằng 1. Sau khi dữ liệu được chuẩn hóa, tiến hành chia dữ liệu để đưa vào xây dựng mô hình. Sử dụng bộ dữ liệu concrete\_data.csv gồm 1093 mẫu chia thành 2 phần, phần Train để huấn luyện mô hình (70% tương ứng với 765 mẫu) và phần Test để kiểm tra kết quả mô hình (30% tương ứng với 328 mẫu). Dùng 42 mẫu còn lại trong bộ dữ liệu thí nghiệm của tác giả để xác thực lại kết quả mô hình một

lần nữa trước khi đưa ra đánh giá cuối cùng về chất lượng mô hình. Sơ đồ mô tả quy trình giải quyết bài toán dự đoán cường độ nén của bê tông như Hình 3.



Hình 3. Quy trình giải quyết bài toán dự đoán cường độ nén của bê tông

Mô tả tổng quan về mô hình và số lượng tham số trong mô hình như sau:

Model: "model\_conv1D"

Layer (type)	Output Shape	Param #
Conv1D_1 (Conv1D)	(None, 4, 64)	384
Conv1D_2 (Conv1D)	(None, 2, 32)	6176
Conv1D_3 (Conv1D)	(None, 2, 16)	528
MaxPooling1D (MaxPooling1D)	(None, 1, 16)	0
flatten (Flatten)	(None, 16)	0
Dense_1 (Dense)	(None, 32)	544
Dense_2 (Dense)	(None, 1)	33

=====  
 Total params: 7665 (29.94 KB)  
 Trainable params: 7665 (29.94 KB)  
 Non-trainable params: 0 (0.00 Byte)

Mô hình này sử dụng ba lớp tích chập 1 chiều với số lượng và kích thước Kernel được thực nghiệm với nhiều trường hợp khác nhau như trong Bảng 2.

**Bảng 2. Bảng tổng hợp số lượng và kích thước bộ lọc trong các trường hợp**

Số bộ lọc (kích thước bộ lọc)		
Lớp 1	Lớp 2	Lớp 3
64(3)	32(3)	16(2)
64(4)	32(2)	16(1)
64(4)	32(3)	16(2)
64(3)	32(3)	16(3)
32(3)	64(3)	128(3)
128(3)	64(3)	32(3)
128(4)	64(3)	32(2)
64(5)	32(3)	16(1)

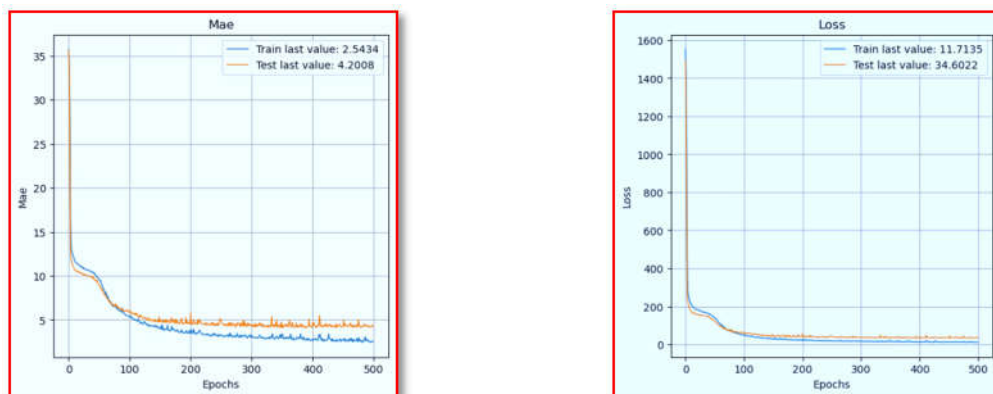
## 4.2. Kết quả và phân tích

### 4.2.1. Thực nghiệm 1: Thay đổi số bộ lọc và kích thước bộ lọc của mô hình CNN-1D để tìm ra tham số tốt nhất cho bài toán

Trong thực nghiệm này, tác giả đã thay đổi số lượng bộ lọc và kích thước bộ lọc tại mỗi lớp CNN như trong Bảng 2, đánh giá mô hình với từng trường hợp và được kết quả là mô hình đạt độ chính xác cao và sai số nhỏ khi thiết lập số bộ lọc và kích thước bộ lọc tương ứng cho 3 tầng như sau: 64(4), 32(3), 16(2).

### 4.2.2. Thực nghiệm 2: Đánh giá mô hình, kiểm tra, xác thực kết quả với các tham số đã chọn ở thực nghiệm trên

Sau khi huấn luyện mô hình với 500 lần lặp, đồ thị sai số MAE và đồ thị mất mát thu được như trong hình dưới đây:



Hình 4. Đồ thị sai số MAE và đồ thị mất mát Loss

Đồ thị sai số thể hiện sự khác biệt giữa giá trị thực và giá trị dự đoán của mô hình trên tập huấn luyện và tập kiểm tra. Đồ thị mất mát thể hiện giá trị của hàm mất mát (loss function) trên tập huấn

luyện và tập kiểm tra. Qua đồ thị này, có thể nhận xét quá trình huấn luyện mô hình như sau:


- Đồ thị sai số và đồ thị mất mát có xu hướng giảm dần theo số lần lặp (epoch) của quá trình huấn luyện. Điều này cho thấy mô hình đang học và có cải thiện kết quả;

- Hai đường thể hiện sai số và mất mát của tập huấn luyện và tập kiểm tra trên hai đồ thị tương ứng gần nhau và không có khoảng cách quá lớn. Điều này cho thấy mô hình không bị quá khớp (overfitting) hay


dưới khớp (underfitting) với dữ liệu;

- Đồ thị sai số và đồ thị mất mát tương đối ổn định và không có biến động quá lớn. Điều này cho thấy mô hình không bị ảnh hưởng quá nhiều bởi nhiễu trong dữ liệu hay tốc độ học (learning rate) quá cao;

Độ chính xác thu được với bộ kiểm tra là 88,9%, xác thực mô hình với 42 mẫu còn lại cho độ chính xác là 87,2%, với đồ thị scatter lần lượt trong hình dưới đây:



(a)



(b)

Hình 5. Tương quan giữa giá trị dự đoán và giá trị thực tế với (a) tập kiểm tra và (b) tập xác thực

Hình 5 cho thấy, phân bố các điểm thể hiện giá trị dự đoán và giá trị thực tế tương đối gần đường 1:1, chứng tỏ sự tương quan tốt giữa giá trị dự đoán và giá trị thực tế của mô hình dự đoán cường độ bê tông trên cả tập dữ liệu kiểm tra và tập dữ liệu xác thực. Mô hình dự đoán cường độ nén R28 của bê tông hoạt động tốt với hệ số xác định R-square bằng 0,90 trên tập dữ liệu kiểm tra và 0,83 trên tập dữ liệu xác thực. Ngoài ra, sai số toàn phương trung bình (MSE) và sai số tuyệt đối trung bình (MAE) cũng rất thấp, cho thấy mô hình có độ chính xác cao trong việc dự đoán cường độ chịu nén của bê tông loại có sử dụng phụ gia ứng dụng cho các công trình biển.

## 5. KẾT LUẬN

- Trong nội dung nghiên cứu này, một mô hình tiên tiến, mô hình mạng nơ-ron tích chập CNN-1D được áp dụng để dự đoán cường độ nén của bê tông ứng dụng cho công trình biển. Đây là loại bê tông có thành phần vật liệu phức tạp, chưa có các công thức thực nghiệm lập sẵn để dự đoán cường độ, nên việc ứng dụng mô hình học máy, học sâu để dự đoán cường độ nén của bê tông đã giải quyết được hạn chế này và mang lại những hiệu quả thiết thực;

- Nghiên cứu sử dụng 1093 mẫu để huấn luyện và kiểm thử mô hình, trong đó 1030 mẫu từ nguồn dữ liệu mở trên internet và 63 mẫu từ nghiên cứu thực nghiệm của tác giả. Dùng 42 mẫu còn lại trong phần dữ liệu thử nghiệm của tác giả để xác thực mô hình trước khi đưa ra đánh giá chất lượng mô hình. Tổng cộng có 9 tham số trong bộ dữ liệu, trong đó có 8 biến đầu vào và 1 biến đầu ra được xem xét trong nghiên cứu này;

- Kết quả nghiên cứu đạt được là xây dựng được mô hình CNN-1D cài đặt trên nền tảng Jupyter notebook. Kết quả thực nghiệm mô hình đã được đánh giá bằng các chỉ số như: Độ chính xác, R-Squared, MAE, MSE. Các chỉ số đánh giá cho thấy mô hình đạt chất lượng tốt với độ chính xác trên 87% với tất cả các tập huấn luyện (765 mẫu), kiểm thử (328 mẫu) và tập xác thực (42 mẫu);

- Với mô hình xây dựng được, có thể dự đoán được cường độ nén bê tông với các tỷ lệ hỗn hợp khác nhau tại các thời điểm khác nhau một cách hiệu quả. Do đó, có thể sử dụng mô hình để kiểm tra xem tỷ lệ hỗn hợp thiết kế có đáp ứng được yêu cầu về cường độ mục tiêu hay không hoặc có thể sử dụng để xem sự phát triển cường độ nén ở



các độ tuổi khác nhau. Hơn nữa, mô hình cũng có thể được coi là cơ sở, mở rộng thành các mô hình đa đầu ra để dự đoán một số đặc tính bê tông cùng

một lúc, ví dụ: cường độ, độ sụt, v.v. Do đó, mô hình này có thể áp dụng để tối ưu hóa tỷ lệ trộn cho các giá trị cường độ yêu cầu nhất định.

## TÀI LIỆU THAM KHẢO

- Nguyễn Thị Thu Hương, (2016), "*Nghiên cứu giải pháp nâng cao độ bền cho bê tông, bê tông cốt thép của kết cấu bảo vệ mái dè và bờ biển Việt Nam*", Luận án Tiến sĩ kỹ thuật, Trường Đại học Thủy lợi.
- B. Bharatkumar, R. Narayanan, B. Raghuprasad, D. Ramachandramurthy, (2001), "*Mix proportioning of high performance concrete*", *Cement and Concrete Composites* 23, 71-80.
- S. Bhanja, B. Sengupta, (2002), "*Investigations on the compressive strength of silica fume concrete using statistical methods*", *Cement and Concrete Research* 32, 1391-1394.
- M. F. M. Zain, S. M. Abd, (2009), "*Multiple regression model for compressive strength prediction of high performance concrete*", *Journal of Applied Sciences* 9, 155-160.
- De-Cheng Fenga, Zhen-Tao Liu, Xiao-Dan Wang, Yin Chen, Jia-Qi Chang, Dong-Fang Wei, Zhong-Ming Jiang, (2020), "*Machine learning-based compressive strength prediction for concrete: an adaptive boosting approach*", *Construction and Building Materials* 230:117000.
- Zhu Xue-bing, (2011), "*Strength prediction of high strength concrete using two nonlinear methods*". *Concrete* 12, 28–30.
- H. Salehi, R. Burgueño, (2008), "*Emerging artificial intelligence methods in structural engineering*", *Engineering Structures*, 170-189.
- Daihong Li, Zhili Tang, Qian Kang, Xiaoyu Zhang, and Youhua Li, (2023), "*Machine Learning-Based Method for Predicting Compressive Strength of Concrete*", <https://www.mdpi.com/2227-9717/11/2/390>
- Serkan Kiranyaz, Onur Avci, Osama Abdeljaber, Turker Ince, Moncef Gabbouj, Daniel J. Inman, (2019), "*1D Convolutional Neural Networks and Applications*" – A Survey.
- I.-C. Yeh, (2008), "*Modeling slump of concrete with fly ash and superplasticizer*", *Computers and Concrete* 5, 559-572.

### Abstract:

#### APPLYING CNN-1D ALGORITHM TO PREDICT COMPRESSIVE STRENGTH OF CONCRETE USED FOR MARINE STRUCTURES

*The compressive strength of concrete plays an important role in determining the load-bearing capacity and durability of the project. For normal concrete, compressive strength can be predicted through available empirical formulas. With concrete used for marine structures, predicting the compressive strength is more difficult because the material composition is complex and there are no available empirical formulas for this type of concrete. The paper mentions the use of machine learning models with the CNN-1D algorithm to predict the compressive strength of concrete using additives for marine structure. The model running data set includes 1093 samples divided into 2 parts according to the train: test ratio of 70:30, in addition, 42 samples are used to test the accuracy of the model. The test results show that the accuracy of the built model is relatively good. Model results can help researchers in specialized fields use it as a tool to support the accurate calculation process, determine concrete composition, reduce time, and improve experimental quality.*

**Keywords:** Machine learning, algorithm, prediction, compressive strength of concrete, marine structure.

---

Ngày nhận bài: 15/3/2024

Ngày chấp nhận đăng: 30/3/2024