

PHÁT TRIỂN MÔ HÌNH HỌC SÂU HƯỚNG DỮ LIỆU ĐỂ DỰ ĐOÁN KHUYẾT TẬT BỀ MẶT VẬT ĐÚC

Bùi Văn Biên

Khoa Điện Cơ, Trường Đại học Hải Phòng

Email: bienbv80@dhhp.edu.vn

Nguyễn Ngọc Tú

Trường Đại học Hàng Hải Việt Nam

Ngày nhận bài: 31/10/2023

Ngày PB đánh giá: 28/11/2023

Ngày duyệt đăng: 15/12/2023

TÓM TẮT: Quá trình đúc nổi lên như là một quá trình sản xuất công nghiệp điển hình bởi tính đa dạng và phức tạp của nó. Một trong những hướng tiếp cận để xây dựng xưởng đúc thông minh là ứng dụng trí tuệ nhân tạo vào việc cải tiến quá trình đúc. Bài viết này trình bày một cách tiếp cận liên quan đến ứng dụng học sâu trong việc dự đoán các khuyết tật bề mặt vật đúc. Phương pháp này cho phép dữ liệu sản xuất từ hai xưởng đúc thép có thể được sử dụng để phát triển mô hình dự đoán khuyết tật liên quan đến bề mặt vật đúc đã được chứng minh. Dữ liệu được sử dụng để phát triển mô hình được thu thập từ quá trình đúc cát CO₂, trong đó các chi tiết có trọng lượng từ 1 đến 100 kg được sản xuất từ vật liệu thép. Kết quả chỉ ra rằng mô hình học sâu hướng dữ liệu đã chọn có tác động rõ ràng đến việc dự đoán khuyết tật của quá trình đúc cát CO₂.

Từ khóa: Đúc cát CO₂, Học sâu, Khuyết tật đúc, Mô hình hóa quá trình hướng dữ liệu.

DEVELOPMENT OF DATA-DRIVEN DEEP LEARNING MODELS FOR THE PREDICTION OF CASTING SURFACE DEFECTS

ABSTRACT: The casting process emerges as a specific manufacturing process because of its diversity and complexity. One of the trends of smart foundry design is the application of artificial intelligence in the improvement of the casting process. This paper shows an approach for the application of deep

learning in the prediction of casting surface related defects. The approach enabling the production data from two steel foundries to be used to develop a model for predicting casting surface related defects has been proved. The data used for the model development were collected from CO₂ casting process in which parts ranging from 1 to 100 kg in weight are produced from steel materials. The result indicates that the selected data-driven deep learning model significantly affects the defect prediction of CO₂ casting.

Keywords: CO₂ casting, deep learning, casting defects, data-driven process modeling.

1. Đặt vấn đề

Trong những năm tới, cuộc cách mạng số đã và đang tác động sâu rộng tới rất nhiều lĩnh vực như công nghệ thông tin - truyền thông, chăm sóc sức khỏe, giáo dục và ngành sản xuất cũng không nằm ngoài sự ảnh hưởng đó. Sự bùng nổ của dữ liệu lớn và khả năng tính toán trên nền tảng công nghệ mới - cùng với những tiến bộ trong các lĩnh vực khác như trí tuệ nhân tạo, tự động hóa và robot, công nghệ bồi đắp và giao diện tương tác người - máy - đang mở ra cuộc cách mạng làm thay đổi bản chất tự nhiên của quá trình sản xuất công nghiệp. Quá trình sản xuất công nghiệp số (digital manufacturing) là một phương pháp tích hợp để sản xuất tập trung xung quanh một hệ thống máy tính. Trong đó việc mô hình hóa, mô phỏng và phân tích tất cả máy móc, dụng cụ cũng như vật liệu đầu vào để tối ưu hóa quá trình sản xuất là những

nhiệm vụ quan trọng của quá trình sản xuất số.

Ngành đúc trên thế giới nói chung và ở Việt Nam nói riêng sẽ phải đối mặt với những thách thức lớn hơn bao giờ hết về tối ưu hóa tài nguyên và năng lượng do sự thay đổi kinh tế và sinh thái dự kiến hướng tới mục tiêu giảm phát thải ròng bằng không theo như cam kết tại COP 26 [1]. Ngành công nghiệp đúc tại Hải Phòng - một trong những ngành sử dụng nhiều năng lượng nhất, với hơn 10.000 người trong khoảng 300 xưởng đúc đứng trước áp lực cạnh tranh ngày càng tăng: Cạnh tranh từ các xưởng đúc trong và ngoài nước, nhu cầu về tính linh hoạt ngày càng tăng, áp lực về thời gian giao hàng và chất lượng sản phẩm, mục tiêu chiến lược về một Hải Phòng xanh đang thúc đẩy các phương pháp sản xuất mới. Trong bối cảnh đó, để có thể tồn tại vững chắc đòi hỏi sự phát triển hơn nữa cả về công nghệ xử

lý và kiểm soát quá trình thông qua ứng dụng công nghệ thông minh nhằm tối ưu hóa các quy trình cũng như đáp ứng các yêu cầu ngày càng phức tạp trong quá trình đúc [2].

Quá trình đúc cát đã tồn tại từ lâu trong ngành sản xuất công nghiệp và vẫn được sử dụng trong nhiều xưởng đúc do tính linh hoạt và hiệu quả chi phí của nó. Chất lượng của các sản phẩm đúc thực hiện bởi quá trình đúc cát đã được nghiên cứu bởi nhiều nhà khoa học [3-5]. Chất lượng của vật đúc phụ thuộc vào các biến đổi liên quan đến khuôn, liên quan đến vật liệu khuôn, việc chuẩn bị liên quan đến vật liệu đúc, liên quan đến thành phần vật liệu và các biến thiên liên quan đến môi trường trong quy trình. Đúc cát CO₂ sử dụng khuôn bền hơn nhiều so với khuôn làm bằng cát tươi hoặc cát xanh và tăng cường độ hoàn thiện bề mặt của sản phẩm đúc. Tuy nhiên, bề mặt hoàn thiện của vật đúc kim loại được tạo ra phụ thuộc vào một số biến số của quá trình đúc. Việc tối ưu hóa các tham số quá trình như cường độ, độ ẩm, độ thấm thấu, nhiệt độ rót và độ cứng của khuôn để giảm thiểu các khuyết tật trong sản phẩm đúc được thực hiện bằng cách sử dụng thiết kế thí nghiệm và phương pháp bề mặt phản ứng [3, 6]. Mức độ tối ưu của các tham số này để đạt được vật đúc có

chất lượng tốt hơn được thiết lập bằng cách phát triển một mô hình hiệu ứng được thể hiện thông qua các nghiên cứu điển hình.

Các thuật toán tiến hóa như thuật toán di truyền và tối ưu hóa bầy đàn hạt được sử dụng để tối ưu hóa cường độ nén, độ thấm, độ cứng và khối lượng riêng trong trạng thái của các biến quá trình như độ mịn của hạt, tỷ lệ sét, tỷ lệ nước và số cửa [7]. Mối quan hệ toán học giữa các biến và tham số được thiết lập và các tham số khuôn tối ưu được thiết lập. Ngoài ra, một nỗ lực đã được thực hiện bằng cách sử dụng mạng nơ-ron lan truyền ngược và thuật toán di truyền để phát triển mô hình phân tích biểu thị các tham số quy trình đúc cát dưới ảnh hưởng của một số biến quá trình [8]. Hỗn hợp thành phần tối ưu của cát cũng được thiết lập bằng thực nghiệm bằng phương pháp bề mặt phản ứng và ảnh hưởng của nó đối với độ nhám bề mặt được phân tích. Khả năng của khuôn cát cho phép hóa rắn tốt hơn kim loại đã đồ được nghiên cứu bằng cách sử dụng mô phỏng số và sau đó, ảnh hưởng của năng suất khuôn đối với khuyết tật vật đúc được nghiên cứu. Để đáp ứng các yêu cầu liên quan đến độ nhám bề mặt, độ cứng, độ bền kéo, độ bền chảy và độ giãn dài của các cấu kiện đúc, mức độ tối ưu của các biến quá trình như độ ẩm, độ bền nén xanh,

hiệu suất đúc kim loại, độ cứng khuôn, kích thước hạt cát, hàm lượng chất kết dính, thời gian đông rắn, thành phần vật liệu của khuôn, kích thước ống phun, các biến số liên quan đến hệ thống công, kích thước ống đứng [9]. Hơn nữa, các khuyết tật khác nhau có thể được đưa ra trong quá trình đúc cát CO₂ và mức độ tối ưu của vật liệu thành phần hợp kim, vật liệu thành phần khuôn, nhiệt độ ban đầu của khuôn, nhiệt độ rót, mặt cắt ngang của đường dẫn, chiều dài của đường chạy bên, độ thấm khí, đường kính ống đứng, chiều rộng ống đứng, chiều cao ống đứng, độ dày ống đứng, trọng lượng ống đứng, trọng lượng ống dẫn. Hiện tại chưa có công trình nghiên cứu nào khai thác ưu thế của học sâu trong dự đoán khuyết tật đúc với các đặc điểm nổi bật quan trọng như dễ dàng xây dựng, điều chỉnh mô hình toán phù hợp với nhiều thuật toán khác nhau; có thể đưa ra các dự đoán và đánh giá phức tạp với độ chính xác rất cao và khả năng tự động hóa, tự điều chỉnh và tối ưu hóa chính nó.

Trong ngành công nghiệp đúc, nơi việc sản xuất các chi tiết máy được thực hiện bằng khuôn cát, lý do lớn nhất khiến các chi tiết máy có thể là phế phẩm sau đúc là do vật liệu làm khuôn và các đặc tính chất lượng của nó. Chất lượng khuôn và thao tác không đảm bảo có thể là nguyên nhân gây ra

tới 40-50% tỷ lệ phế phẩm trong một xưởng đúc. Các khuyết tật bề mặt vật đúc nếu không trực tiếp dẫn đến phế phẩm thì cũng gia tăng đáng kể quá trình hoàn thiện sản phẩm, và do đó dẫn đến chi phí sản xuất bổ sung. Trong số các nguyên nhân gây ra phế phẩm thì các khuyết tật bề mặt vật đúc, minh họa trong hình 1, là nguyên nhân chủ yếu. Các khuyết tật bề mặt vật đúc có thể phân loại thành khuyết tật cháy cát, khuyết tật lõm, khuyết tật đường hàn và khuyết tật rỗ khí. Các khuyết tật bề mặt vật đúc này hình thành do nhiều yếu tố như nhiệt độ kim loại nấu quá cao, thời gian nấu chảy, thời gian quá nhiệt không hợp lý, vật liệu làm khuôn không đạt yêu cầu, tạp chất cao, độ kết dính không đủ [1, 9].



Hình 1. Khuyết tật rỗ khí trên bề mặt vật đúc (hình chụp tại Công ty TNHH Cương Hưng)

Mục tiêu của bài viết này là đề xuất một ứng dụng của học sâu, như một tập hợp con của trí tuệ nhân tạo,

trong việc dự đoán khuyết tật bề mặt vật đúc trong quá trình đúc cát CO₂. Nhiệm vụ chủ yếu là phân tích các yếu tố kỹ thuật liên quan đến quá trình đúc cát CO₂ để dự đoán khuyết tật bề mặt vật đúc. Tầm quan trọng đặc biệt của bài viết này được thể hiện qua một tập hợp dữ liệu được thu thập trong suốt ba tháng tại hai xưởng đúc khác nhau trên địa bàn thành phố Hải Phòng, cũng như việc áp dụng thuật toán học sâu để dự đoán khuyết tật bề mặt vật đúc. Nhìn chung, nghiên cứu này là một bước tiến trong việc đưa quy trình đúc đến gần hơn với khái niệm liên quan tới cuộc cách mạng công nghiệp lần thứ 4 - Công nghiệp 4.0 - chính là hình thành xưởng đúc thông minh.

2. Cơ sở lý thuyết

Học sâu là một loại hình học máy và trí tuệ nhân tạo (AI) bắt chước cách con người thu được một số loại kiến thức nhất định [10, 11]. Học sâu là một yếu tố quan trọng của khoa học dữ liệu, bao gồm số liệu thống kê và mô hình dự đoán. Nó cực kỳ có lợi cho các nhà khoa học dữ liệu, những người được giao nhiệm vụ thu thập, phân tích và giải thích lượng lớn dữ liệu; học sâu làm cho quá trình này nhanh hơn và dễ dàng hơn. Học sâu sử dụng nhiều lớp tích chập được cấu trúc bên trong mạng nơ-ron nhân tạo, nơi các đặc điểm dữ liệu đầu vào được học để xử lý các tính

năng cấp thấp hơn thành các tính năng cấp cao trừu tượng hơn. Sau đó, các tính năng này được sử dụng để phân loại dữ liệu thành các danh mục đã học được từ quá trình đào tạo. Kết quả được thể hiện dưới dạng vectơ, bản đồ đặc trưng,... Dựa trên khả năng học tập mạnh mẽ và trích xuất tính năng của học sâu, nhiều nhà nghiên cứu đã sử dụng công nghệ này để phát hiện các khuyết tật và cải thiện hiệu quả cũng như chất lượng phát hiện tổng thể.

Trong thực tế, các thuật toán học sâu có thể được chia thành ba dạng chính dựa trên mục đích của chúng. Thuật toán học sâu có giám sát xảy ra khi mô hình học sâu học hỏi từ dữ liệu mẫu và các đáp ứng mục tiêu liên quan. Học sâu có giám sát thường được áp dụng trong các ứng dụng trong đó dữ liệu lịch sử dự đoán các sự kiện có khả năng trong tương lai. Nói chung, các bài toán học sâu có giám sát được phân loại thành bài toán phân loại và bài toán hồi quy. Trong các bài toán hồi quy, mô hình cố gắng dự đoán kết quả trong đầu ra liên tục dựa trên các chức năng liên tục [12]. Trái ngược với bài toán hồi quy, trong đầu ra của bài toán phân loại được dự đoán theo giá trị riêng biệt. Một ví dụ cụ thể, mạng nơ-ron nhân tạo tích chập kết hợp với mô hình trường ngẫu nhiên có điều kiện đồng thời sử dụng hàm năng

lượng trường ngẫu nhiên làm ràng buộc nhằm tối ưu hóa kết quả dự đoán qua đó phát hiện khuyết tật [13].

Không giống như thuật toán học sâu có giám sát, thuật toán học sâu không giám sát được chuẩn bị bằng cách suy ra các cấu trúc có trong dữ liệu đầu vào mà không có bất kỳ đáp ứng liên quan nào, bỏ qua thuật toán để tự xác định các mẫu dữ liệu [11]. Một ví dụ điển hình là hệ thống khuyến nghị, nó có thể xác định các phân khúc khách hàng có các đặc điểm tương tự, những người sau đó có thể được đối xử tương tự trong các chiến dịch tiếp thị. Thuật toán học sâu tăng cường, dạng thứ ba, liên quan đến bài toán làm thế nào để tương tác với môi trường và chọn hành động phù hợp trong một tình huống nhất định để tối ưu hóa quá trình [11].

Đối với bài toán dự đoán khuyết tật bề mặt vật đúc trong quá trình đúc cát CO₂, thuật toán được sử dụng là học sâu có giám sát kết hợp thuật toán Gradient Descent. Mô hình học sâu này bao gồm lớp đầu vào có 9 tham số, cụ thể là nhiệt độ rót của kim loại nóng chảy, 5 thành phần hóa học cơ bản của kim loại, 2 thành phần hóa học của lớp áo cát, thông tin về sơn khuôn bề mặt, lớp đầu ra có 1 tham số là dự đoán tỉ lệ xuất hiện khuyết tật trên bề mặt vật đúc và các lớp ẩn trong đó mỗi lớp gồm các nơ-ron tính toán. Tiến trình thực hiện cơ bản cho một dự án học sâu được tuân thủ theo các bước như trong hình 2.



Hình 2. Tiến trình thực hiện cơ bản của một dự án học sâu [1]

3. Phương pháp và kết quả nghiên cứu

3.1 Thu nhận dữ liệu

Trong thời gian 3 tháng, dữ liệu sản xuất được sử dụng để phát triển mô hình được thu nhận từ hai xưởng đúc thép bằng khuôn cát CO₂ tại Công ty TNHH Cơ khí Quốc Dương và Công ty TNHH Cường Hưng

trong đó các chi tiết được đúc từ vật liệu thép. Chúng loại của sản phẩm bao gồm nhiều loại khác nhau như xích, mũi khoan, neo tàu, bánh răng có trọng lượng từ 1 kg tới 100 kg. Kim loại được nấu chảy trong lò cảm ứng cao tần công suất từ 1 đến 1,5 tấn. Các dữ liệu liên quan đến quá trình trong sản xuất bao gồm quy

trình nấu chảy và rót cũng như dữ liệu thu nhận đầu tiên được trình bày trong bảng 1. chất lượng của nhà máy. Năm mẫu

Bảng 1. Năm mẫu dữ liệu thu nhận đầu tiên tại hai xưởng đúc Quốc Dương và Cương Hưng

Mẫu số	Mác vật liệu	Nhiệt độ rót (°C)	Thành phần kim loại					Thành phần cát khuôn		Sơn khuôn	Khuyết tật
			C	Si	Mn	P	S	Cát	H ₂ O		
1	C45	1560-1570	0.43	0.22	0.6	0.02	0.02	90	2	Có	Có
2	CT3	1550-1555	0.19	0.2	0.5	0.03	0.02	80	3	Không	Không
3	CT3	1550-1555	0.2	0.25	0.43	0.02	0.02	90	2	Không	Có
4	CT3	1550-1555	0.17	0.16	0.47	0.03	0.03	85	3	Không	Có
5	FC250	1340-1350	3.5	1.6	0.8	0.03	0.02	87	3	Có	Có

3.2 Tiền xử lý dữ liệu

Tiền xử lý liên quan đến việc làm sạch, xác minh và định dạng dữ liệu thành tập dữ liệu có thể sử dụng được. Đây là bước quan trọng nhất giúp xây dựng các mô hình học sâu chính xác hơn. Bước đầu tiên của quá trình tiền xử lý là xác định dữ liệu bị thiếu. Dữ liệu bị thiếu là phổ biến

trong hầu hết các bộ dữ liệu trong thế giới thực, những giá trị còn thiếu này trước tiên cần được xử lý để tận dụng tối ưu dữ liệu có sẵn. Chiến lược cơ bản khi sử dụng bộ dữ liệu không đầy đủ là loại bỏ toàn bộ hàng hoặc cột chứa các giá trị bị thiếu. Tuy nhiên, điều này phải trả giá bằng việc mất dữ liệu thông tin có thể có giá trị cho

việc đào tạo mô hình. Ngược lại, quy nạp cố gắng suy ra các giá trị còn thiếu từ phần dữ liệu đã biết. Một số phương pháp nổi tiếng bao gồm thay thế các giá trị bị thiếu bằng 0, trung bình, trung vị hoặc chế độ.

Nói chung, các thuật toán được hưởng lợi từ việc tiêu chuẩn hóa tập dữ liệu. Các cột khác nhau có thể có mặt trong các phạm vi khác nhau. Ví dụ, có thể có một cột có đơn vị khoảng cách và một cột khác có đơn vị nhiệt độ. Các cột đó sẽ có phạm vi rất khác nhau, khiến nhiều mô hình học sâu khó đạt được trạng thái tính toán đầu ra tối ưu. Có một số kỹ thuật để giải quyết vấn đề này, đó là tiêu chuẩn hóa, hoặc loại bỏ trung bình và nhân rộng phương sai; chia tỷ lệ các đối tượng địa lý thành một phạm vi, thường nằm trong khoảng từ 0 đến 1

hoặc sao cho giá trị tuyệt đối tối đa của mỗi đối tượng địa lý được chia tỷ lệ thành kích thước đơn vị.

Trong nhiều trường hợp, dữ liệu ở định dạng không thể xử lý bằng thuật toán. Chẳng hạn, một cột có giá trị chuỗi hoặc văn bản sẽ không có ý nghĩa gì đối với một mô hình chỉ chấp nhận các giá trị số làm đầu vào. Vì vậy, cần phải chuyển đổi các tính năng phân loại thành mã số nguyên để giúp mô hình giải thích nó. Phương pháp này được gọi là mã hóa phân loại. Như với dữ liệu cột “Sơn khuôn”, một mã hóa nóng gán giá trị dương 1 trong bất kỳ hàng nào có danh mục đó và 0 khi không có danh mục đó. Năm mẫu dữ liệu thu nhận đầu tiên được tiền xử lý và trình bày trong bảng 2.

Bảng 2. Năm mẫu dữ liệu thu nhận đầu tiên được tiền xử lý

Temp	C	Si	Mn	P	S	Sand	H ₂ O	Paint	Error
1565	0.43	0.22	0.6	0.02	0.02	90	2	1	1
1552	0.19	0.2	0.6	0.03	0.02	95	2	0	0
1552	0.2	0.25	0.42	0.02	0.02	90	3	0	1
1552	0.17	0.16	0.47	0.03	0.03	91	3	0	1
1345	0.35	1.6	0.8	0.03	0.02	88	2	1	1

3.3 Huấn luyện mô hình

Khi tập dữ liệu đã sẵn sàng để huấn luyện, bước tiếp theo bao gồm việc cung cấp tập huấn luyện cho thuật toán để nó có thể tìm hiểu các tham số và tính năng phù hợp được sử dụng trong quá trình học. Mô hình học sâu được chọn sẽ được huấn luyện bởi Tensorflow trên môi trường Python 3.5. Môi trường này được cài đặt trên máy tính cá nhân có cấu hình cụ thể, CPU Intel (R) Core i7-4790 3,6GHz; RAM 16GB;


Card đồ họa RX 580 8GB và ổ cứng SSD 256 GB. Hàm Loss được áp dụng trong mô hình là hàm tổng độ lệch bình phương, các tham số độ lệch và trọng số được khởi tạo ngẫu nhiên theo phương pháp Xavier, sử dụng thuật toán Adam để tối ưu hóa hàm Loss cùng hệ số học đặt giá trị là 0,001. Quá trình huấn luyện mô hình học sâu được thể hiện trong hình 3 bao gồm số lượng các vòng lặp, thời gian xử lý và chỉ số Loss cho vòng lặp đó.

```
Epoch 1/300
1/1 [=====] - 1s 532ms/step - loss: 0.2017
Epoch 2/300
1/1 [=====] - 0s 4ms/step - loss: 0.2002
Epoch 3/300
1/1 [=====] - 0s 3ms/step - loss: 0.1989
Epoch 4/300
1/1 [=====] - 0s 2ms/step - loss: 0.1975
Epoch 5/300
1/1 [=====] - 0s 3ms/step - loss: 0.1961
Epoch 6/300
1/1 [=====] - 0s 4ms/step - loss: 0.1948
Epoch 7/300
1/1 [=====] - 0s 3ms/step - loss: 0.1934
Epoch 8/300
1/1 [=====] - 0s 3ms/step - loss: 0.1921
Epoch 9/300
1/1 [=====] - 0s 4ms/step - loss: 0.1908
Epoch 10/300
```

Hình 3. Quá trình huấn luyện mô hình

Mô hình bắt đầu với mức độ lỗi từ 1,4 giảm về dưới 0,1 trong 150 vòng lặp. Mức độ giảm lỗi khá tốt, phản ánh

mức độ hội tụ của mô hình tốt. Độ lỗi của mô hình trong quá trình huấn luyện được trình bày trong hình 4.



Hình 4. Độ lỗi của mô hình trong quá trình huấn luyện

Kết quả mô hình dự đoán khuyết tật bề mặt vật đúc và tính toán độ chính xác trong quá trình dự đoán được thể hiện ở hình 5. Trong

đó độ lệch dự đoán cho từng hàng trong dữ liệu thực nghiệm thể hiện dưới dạng lỗi phần trăm tuyệt đối (APE).

	Temperature	C	Si	Mn	P	S	Sand	HO	Paint	Error	PredictedError	APE
0	1565.0	0.43	0.22	0.60	0.02	0.02	90.0	2.0	1.0	1.0	0.785472	21.452820
1	1552.0	0.20	0.25	0.42	0.02	0.02	90.0	3.0	0.0	1.0	0.896678	10.332245

Hình 5. Mô hình đưa ra dự đoán và độ chính xác trong quá trình dự đoán

3.4 Đánh giá mô hình

Mô hình đưa ra dự đoán có độ chính xác khá tốt, với 150 vòng lặp huấn luyện, mô hình đưa ra dự đoán

lên tới trên 80%, chỉ số Loss trung bình là 0,16 với tốc độ xử lý mỗi vòng lặp trung bình là 3ms theo đó thời gian để khởi tạo mô hình rồi cho ra dự đoán

trong 1 phút. Điều này phản ánh khả năng học của mô hình là rất nhanh, đã được tối ưu tốt. Qua thực nghiệm các mô hình với các tham số khác nhau, mô hình có kết quả tốt nhất sử dụng 3 lớp ẩn với mỗi lớp gồm 5 nơ-ron, huấn luyện qua 150 vòng lặp đem lại độ chính xác trên 84,1%.

Tuy nhiên có thể thấy rằng, rõ ràng là phải có nhiều hơn tham số ảnh hưởng đến khả năng xuất hiện khuyết tật bề mặt vật đúc mà mô hình đã không sử dụng, chưa được thống kê, đo đạc để đưa vào tập dữ liệu đã cho. Các tham số có thể kể tới như thời gian rót hay các tham số chi tiết hơn về hỗn hợp lớp cát áo như độ thấm khí, thời gian nén chặt, phân tích phân bố kích thước hạt. Các yếu tố đó đã không được cho vào mô hình do giới hạn về mặt thời gian làm thực nghiệm, do sự hạn chế về công nghệ của doanh nghiệp, số lượng vật mẫu có thể tiếp cận là chưa đủ lớn. Dữ liệu liên quan đến chất lượng cát chỉ được đo từ một số mẫu cát nhất định lấy ra khỏi quá trình sản xuất. Hiện tại, không thể xác định chất lượng chính xác của hỗn hợp cát đã sử dụng, do đó chỉ có thể đánh giá các mẫu đã được thử nghiệm trong phòng thí nghiệm. Vì vậy khả năng dự đoán, độ chính xác và độ tin cậy của mô hình đã chọn không đạt được như kỳ vọng đã đặt ra.

4. Kết luận

Trong bài báo này, các tác giả đã đề xuất một phương pháp ứng dụng mô hình học sâu hướng dữ liệu trong việc dự đoán các khuyết tật liên quan đến bề mặt vật đúc trong quá trình đúc cát CO₂. Qua kết quả thực nghiệm cho thấy, độ chính xác của mô hình đã chọn là 84,1%. Cũng từ kết quả trên giúp đánh giá phân tích và điều chỉnh lại các tham số như nhiệt độ, thành phần kim loại, khuôn cát giúp cho thiết kế quá trình đúc cát CO₂ đem lại năng suất, đạt hiệu quả cao hơn, hạn chế được khuyết tật sinh ra. Tuy nhiên, cũng qua kết quả thực nghiệm, có rất nhiều vấn đề cần phải được nghiên cứu và phát triển để cải thiện mô hình đã đề xuất như một số tham số ảnh hưởng chưa được đưa vào tập dữ liệu cụ thể là thời gian nóng chảy của kim loại lỏng, thời gian giữ nhiệt hay các tham số chi tiết hơn về hỗn hợp lớp cát áo như độ thấm khí, thời gian nén chặt, phân tích phân bố kích thước hạt của cát khuôn. Trong nghiên cứu tiếp theo, các tác giả sẽ ứng dụng mô hình mạng nơ-ron học sâu cho các loại khuyết tật bề mặt và khuyết tật trong lòng vật đúc cũng như với các quy trình sản xuất đúc khác như đúc áp lực, đúc khuôn kim loại đồng thời tăng số

lượng tham số để cải thiện mô hình đã đề xuất.

TÀI LIỆU THAM KHẢO

1. Chen S, Kaufmann T (2022), *Development of data-driven machine learning models for the prediction of casting surface defects*, Metals (Basel) 12:1-15.
2. Dučić N, Manasijević S, Jovičić A, et al (2022), *Casting Process Improvement by the Application of Artificial Intelligence*, Appl Sci 12.
3. Noorul A, Guharaja S, Karuppannan KM (2009), *Parameter optimization of CO2 casting process by using Taguchi method*, Int J Interact Des Manuf 3:41-50.
4. Ferguson M, Ak R, Lee YTT, Law KH (2017), *Automatic localization of casting defects with convolutional neural networks*, Proc - 2017 IEEE Int Conf Big Data, Big Data 2017 1726-1735.
5. Dučić N, Jovičić A, Manasijević S, et al (2020), *Application of Machine Learning in the Control of Metal Melting Production Process*, Appl Sci 10:6048
6. Kumar S, Satsangi PS, Prajapati DR (2011), *Optimization of green sand casting process parameters of a foundry by using Taguchi's method*, Int J Adv Manuf Technol 55:23-34.
7. Surekha B, Kaushik LK, Pandey AK, et al (2012), *Multi-objective optimization of green sand mould system using evolutionary algorithms*, Int J Adv Manuf Technol 58:9-17.
8. Parappagoudar MB, Pratihari DK, Datta GL (2008), *Forward and reverse mappings in green sand mould system using neural networks*, Appl Soft Comput J 8:239-260.
9. Suthar J, Persis J, Gupta R (2023), *Predictive modeling of quality characteristics - A case study with the casting industry*, Comput Ind 146:103855.
10. Dong S, Wang P, Abbas K (2021), *A survey on deep learning and its applications*, Comput Sci Rev 40:100379.
11. Sarker IH (2021), *Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions*. SN Comput Sci 2:1-20.
12. Mery D (2020), *Aluminum Casting Inspection Using Deep Learning: A Method Based on Convolutional Neural Networks*, J Nondestruct Eval 39.
13. Gu J, Wang Z, Kuen J, et al (2018), *Recent advances in convolutional neural networks*, Pattern Recognit 77:354-377.