

Ứng dụng học máy trong dự đoán độ dày vật liệu nhôm sử dụng phổ tia X truyền qua: so sánh giữa mạng neuron truyền thẳng (FNN), mạng neuron tích chập (CNN) và mạng neuron hồi quy (RNN)

Nguyễn Thị Trúc Linh^{1,2,*}, Lê Thị Ngọc Trang^{1,2}, Huỳnh Đình Chuong¹, Hoàng Đức Tâm³



Use your smartphone to scan this QR code and download this article

¹Phòng thí nghiệm Kỹ thuật hạt nhân, Trường Đại học Khoa học tự nhiên, ĐHQG-HCM, Việt Nam

²Khoa Vật lý - Vật lý kỹ thuật, Trường Đại học Khoa học tự nhiên, ĐHQG-HCM, Việt Nam

³Khoa Vật lý, Trường Đại học Sư phạm Thành phố Hồ Chí Minh, Việt Nam

Liên hệ

Nguyễn Thị Trúc Linh, Phòng thí nghiệm Kỹ thuật hạt nhân, Trường Đại học Khoa học tự nhiên, ĐHQG-HCM, Việt Nam

Khoa Vật lý - Vật lý kỹ thuật, Trường Đại học Khoa học tự nhiên, ĐHQG-HCM, Việt Nam

Email: nttlinh@hcmus.edu.vn

Lịch sử

- Ngày nhận: 05-02-2025
- Ngày sửa đổi: 28-11-2025
- Ngày chấp nhận: 12-12-2025
- Ngày đăng: 31-12-2025

DOI:

<https://www.doi.org/10.32508/stdjns.v9i4.1435>



Bản quyền

© ĐHQG Tp.HCM. Đây là bài báo công bố mở được phát hành theo các điều khoản của the Creative Commons Attribution 4.0 International license.



TÓM TẮT

Bài báo này trình bày một phương pháp ứng dụng học máy trong dự đoán độ dày của tấm nhôm dựa trên phổ tia X truyền qua. Ba mô hình được sử dụng bao gồm mạng neuron truyền thẳng (FNN), mạng neuron tích chập (CNN), và mạng neuron hồi quy (RNN). Thí nghiệm được thực hiện với nguồn phóng xạ ^{241}Am có tổng hoạt độ khoảng 1776 MBq, dùng để kích thích một mẫu hợp chất chứa các nguyên tố Zr, Sb và Ba, qua đó tạo ra các tia X đặc trưng tại sáu mức năng lượng: 15,78 keV (Zr-K_α), 17,67 keV (Zr-K_β), 26,36 keV (Sb-K_α), 29,73 keV (Sb-K_β), 32,2 keV (Ba-K_α) và 36,38 keV (Ba-K_β). Các chùm bức xạ này được chuẩn trực và truyền qua các tấm nhôm có độ dày khác nhau và ghi nhận bằng đầu dò bán dẫn Si(Li). Từ dữ liệu phổ thu được, mối liên hệ giữa sự suy giảm cường độ tia X và độ dày vật liệu được sử dụng làm dữ liệu để huấn luyện mô hình và đánh giá khả năng dự đoán. Đồng thời các siêu tham số được tối ưu hóa nhằm đạt cấu hình hiệu quả nhất. Sau đó, dữ liệu phổ của các mẫu nhôm có độ dày khác nhau được đưa vào mô hình để kiểm chứng khả năng dự đoán. Kết quả cho thấy cả ba mô hình FNN, CNN, và RNN đều cho độ chính xác cao với sai số dự đoán nhỏ hơn 5% so với số liệu tham khảo, qua đó khẳng định tính khả thi của việc kết hợp học máy với phương pháp truyền qua đa năng lượng trong dự đoán độ dày vật liệu nhôm và triển vọng ứng dụng trong kiểm tra không phá hủy.

Từ khoá: Tia X truyền qua, FNN, CNN, RNN

MỞ ĐẦU

Trong bối cảnh công nghiệp hiện đại, kiểm tra không phá hủy (Non-Destructive Testing, NDT) được xem là một trong những kỹ thuật quan trọng để đánh giá chất lượng và độ bền của vật liệu mà không gây ảnh hưởng đến cấu trúc ban đầu. Một trong những ứng dụng nổi bật của NDT là xác định độ dày của vật liệu, đặc biệt đối với nhôm - kim loại được sử dụng phổ biến trong hàng không, xây dựng và chế tạo. Độ dày vật liệu không chỉ liên quan trực tiếp đến các đặc tính cơ học như độ bền, độ cứng hay khả năng chịu lực, mà còn quyết định khả năng chống ăn mòn, hạn chế biến dạng và làm chậm quá trình hư hỏng, từ đó góp phần đảm bảo an toàn và kéo dài tuổi thọ của sản phẩm^{1,2}. Các kỹ thuật sử dụng tia X để xác định độ dày đã được nghiên cứu và ứng dụng rộng rãi, bao gồm huỳnh quang tia X (XRF)³, phản xạ tia X (XRR)⁴ và tia X truyền qua⁵. Trong đó, phương pháp truyền qua với cấu hình đa mức năng lượng đã cho thấy khả năng đo độ dày vật liệu một cách chính xác trong dải từ vài trăm micromet đến vài milimet. Tuy nhiên, cách

tiếp cận phân tích truyền thống như đường cong hiệu chuẩn (Calibration Curve Fitting, CCF)⁵ thường đòi hỏi nhiều bước xử lý phức tạp và yêu cầu kinh nghiệm cho các thao tác xử lý, làm hạn chế tính tự động hóa và giảm tính hiệu quả khi áp dụng trong lĩnh vực công nghiệp.

Sự phát triển của học máy (Machine Learning) đã mở ra một hướng tiếp cận mới trong việc xử lý dữ liệu phức tạp và tìm ra các mối quan hệ phi tuyến. Các kiến trúc mạng neuron phổ biến như mạng neuron truyền thẳng (Feedforward Neural Network, FNN), mạng neuron tích chập (Convolutional Neural Network, CNN) và mạng neuron hồi quy (Recurrent Neural Network, RNN) đã được ứng dụng thành công trong nhiều lĩnh vực, từ xử lý hình ảnh⁶, phân tích phổ⁷, đến xử lý chuỗi thời gian^{8,9}. Trong nghiên cứu phổ gamma và tia X, nhiều công trình trước đây^{5,10-12} đã cho thấy tiềm năng của việc ứng dụng mạng neuron nhân tạo (Artificial Neural Network, ANN) trong dự đoán độ dày vật liệu với độ chính xác cao. FNN và CNN có thể tái tạo quá trình phân tích phổ bằng cách nhận diện các đỉnh phổ, phân biệt tín

Trích dẫn bài báo này: Linh N T T, Trang L T N, Chuong H D, Tâm H D. Ứng dụng học máy trong dự đoán độ dày vật liệu nhôm sử dụng phổ tia X truyền qua: so sánh giữa mạng neuron truyền thẳng (FNN), mạng neuron tích chập (CNN) và mạng neuron hồi quy (RNN). *Sci. Tech. Dev. J. - Nat. Sci.* 2025; 9(4):3517-3526.

hiệu từ nền và xác định các đặc tính quan trọng. Đặc biệt, CNN cho thấy ưu thế trong việc xử lý cấu trúc không gian của phổ, trong khi RNN phù hợp hơn với dữ liệu chuỗi. Những kết quả này gợi mở triển vọng ứng dụng học máy trong dự đoán độ dày vật liệu từ phổ tia X.

Bài báo này tập trung vào việc đánh giá hiệu quả của ba mô hình học máy FNN, CNN, và RNN trong việc dự đoán độ dày của mẫu nhôm mỏng dựa trên phổ tia X truyền qua đa năng lượng. Các mô hình được huấn luyện và tối ưu hóa dựa trên dữ liệu phổ thực nghiệm, với mục tiêu nâng cao độ chính xác và tính khả thi trong kiểm tra không phá hủy. Những kết quả thu được kỳ vọng sẽ đóng góp vào phát triển các phương pháp đo lường tiên tiến, đáp ứng yêu cầu ngày càng cao của các ngành công nghiệp hiện đại.

MẠNG NEURON NHÂN TẠO (ANNS)

Mạng neuron nhân tạo là một mô hình tính toán được phát triển dựa trên nguyên lý mô phỏng hoạt động hoạt động của hệ thần kinh sinh học, trong đó các đơn vị xử lý thông tin (neuron) liên kết với nhau để thực hiện các phép biến đổi tín hiệu. ANNs được thiết kế để học và biểu diễn các mối quan hệ phi tuyến phức tạp giữa đầu vào và đầu ra, từ đó thực hiện các nhiệm vụ như phân loại, hồi quy, nhận dạng mẫu, và dự đoán. Bài báo trình bày sự phát triển ba kiến trúc khác nhau của ANNs, bao gồm mô hình mạng neuron truyền thẳng (FNN), mạng neuron tích chập 1D (1D-CNN, gọi tắt là CNN) và mạng neuron hồi quy dựa trên bộ nhớ dài hạn ngắn hạn (LSTM-RNN, gọi tắt là RNN) để dự đoán độ dày của các tấm nhôm phẳng.

Mạng neuron truyền thẳng

Mạng neuron truyền thẳng là một dạng kiến trúc cơ bản và phổ biến nhất của mạng neuron nhân tạo, được ứng dụng rộng rãi trong nhiều bài toán học máy. Kiến trúc của mạng neuron truyền thẳng bao gồm một lớp đầu vào, một hoặc nhiều lớp ẩn và một lớp đầu ra. Mỗi lớp trong mạng chứa các nút (neuron) đóng vai trò là đơn vị cơ bản để xử lý thông tin của mạng. Ở các lớp ẩn, các neuron được kết nối đầy đủ với các neuron của lớp trước và lớp sau thông qua các trọng số. Trong quá trình xử lý, mỗi neuron thực hiện phép tính tổng có trọng số của các tín hiệu nhận được, cộng với một hệ số hiệu chỉnh, sau đó biến đổi giá trị này qua một hàm kích hoạt phi tuyến (như ReLU, sigmoid, tanh hoặc softsign) để tạo đầu ra mới. Nhờ cơ chế này, các lớp ẩn có khả năng học và mô hình hóa các quan hệ phi tuyến giữa dữ liệu đầu vào và đại lượng dự đoán. Đặc trưng nổi bật của mô hình FNN là tín hiệu được lan truyền theo một chiều: dữ liệu xuất phát từ lớp đầu vào, được xử lý lần lượt qua các lớp ẩn và cuối cùng

được đưa đến lớp đầu ra để tạo ra giá trị dự đoán. Do không có cơ chế hồi tiếp, mạng chỉ cho phép thông tin di chuyển theo hướng duy nhất này, tạo nên đặc trưng “truyền thẳng” của mô hình.

Mạng neuron tích chập 1D

Mạng neuron tích chập là một trong những kiến trúc mạnh mẽ trong mạng neuron nhân tạo, được phát triển nhằm xử lý hiệu quả dữ liệu chuỗi một chiều. CNN vận hành dựa trên cơ chế tích chập, trong đó các bộ lọc được dịch chuyển dọc theo trục chuỗi để trích xuất các đặc trưng cục bộ. Đây là một kiến trúc “trích xuất đặc trưng” đơn giản nhưng hiệu quả, với khả năng tự động học các mẫu đặc trưng quan trọng trong dữ liệu mà không yêu cầu thiết kế đặc trưng thủ công.

Kiến trúc của CNN bao gồm một lớp đầu vào, các lớp tích chập, các lớp gộp, và cuối cùng là lớp kết nối đầy đủ. Ở lớp đầu vào, dữ liệu được đưa vào dưới dạng ma trận một chiều. Các lớp tích chập đảm nhiệm vai trò trích xuất các đặc trưng cục bộ từ chuỗi dữ liệu thông qua việc áp dụng các bộ lọc được trượt qua chuỗi. Mỗi bộ lọc có kích thước xác định trước và sẽ học các thông tin quan trọng trong chuỗi. Các lớp gộp thường được đặt ngay sau lớp tích chập để giảm kích thước dữ liệu, giữ lại các đặc trưng quan trọng và giảm độ phức tạp tính toán. Phương pháp gộp trong nghiên cứu này là lấy giá trị cực đại trong một vùng. Sau các bước tích chập và gộp, dữ liệu được làm phẳng thành một vector một chiều và chuyển đến lớp kết nối đầy đủ, nơi mỗi neuron kết hợp toàn bộ đặc trưng đã học thông qua các phép tính trọng số và hàm kích hoạt (ReLU, sigmoid, softmax) để tạo ra đầu ra cuối cùng của mô hình. Nhờ chuỗi xử lý này, CNN tạo ra một biểu diễn súc tích nhưng giàu thông tin về dữ liệu ban đầu, hỗ trợ hiệu quả cho các nhiệm vụ dự đoán và phân loại.

Mạng neuron hồi quy dựa trên bộ nhớ dài hạn ngắn hạn

RNN là một kiến trúc học sâu tiên tiến, được thiết kế nhằm để xử lý dữ liệu chuỗi. Khác với các mô hình truyền thống, RNN có khả năng lưu trữ và sử dụng thông tin từ các bước trước đó trong chuỗi, giúp mô hình nhận diện được các mối quan hệ phụ thuộc theo thời gian dữ liệu. Đây là một kiến trúc hồi quy với cơ chế ghi nhớ và quên, cho phép xử lý cả thông tin cục bộ lẫn toàn cục trong chuỗi dữ liệu.

Kiến trúc của RNN bao gồm một lớp đầu vào, một hoặc nhiều lớp bộ nhớ thời gian ngắn hạn dài hạn (LSTM), và một lớp đầu ra. Lớp đầu vào tiếp nhận chuỗi dữ liệu và chuyển thông tin đến các lớp LSTM. Lớp LSTM đóng vai trò là thành phần trung tâm của

mô hình, được cấu trúc với các ô nhớ và các cổng để kiểm soát luồng thông tin. Nhờ vào cơ chế này, LSTM có thể học và duy trì các mối quan hệ phụ thuộc dài hạn trong chuỗi dữ liệu, đồng thời bỏ qua những phần thông tin không cần thiết. Lớp đầu ra của RNN nhận thông tin từ lớp LSTM cuối cùng và đưa ra dự đoán. RNN hoạt động dựa trên cơ chế hồi quy theo thời gian, cho phép dữ liệu từ các bước trước trong chuỗi được truyền trở lại mô hình để học các mối quan hệ liên thời gian. Tại mỗi bước thời gian, mô hình nhận đầu vào từ bước hiện tại, kết hợp với thông tin được lưu trữ từ các bước trước, và quyết định phần thông tin nào cần giữ lại hoặc loại bỏ.

Trong cả ba mô hình, lớp đầu vào được thiết kế với 4330 neuron, mỗi neuron biểu diễn một giá trị số đếm tại từng kênh trên vùng phổ tia X quan tâm. Lớp đầu ra chứa một neuron, có nhiệm vụ dự đoán độ dày. Quá trình huấn luyện các mạng neuron nhân tạo được thực hiện thông qua việc điều chỉnh các trọng số và hệ số điều chỉnh thông qua thuật toán tối ưu hóa, nhằm giảm thiểu sự khác biệt giữa giá trị dự đoán và giá trị thực tế. Sự khác biệt này được đo lường bằng hàm mất mát MSE (Mean Squared Error). Sau khi tính toán giá trị mất mát, quá trình truyền ngược (backpropagation) được áp dụng để tính toán độ dốc (gradient) của hàm mất mát đối với từng trọng số trong mạng, từ đó cập nhật các trọng số và hệ số điều chỉnh theo hướng giảm sai số dự đoán. Trong nghiên cứu này, thuật toán tối ưu hóa ADAM (Adaptive Moment Estimation)¹³ được áp dụng để nâng cao hiệu quả huấn luyện. ADAM cập nhật trọng số dựa trên sự kết hợp giữa trung bình động của gradient và bình phương gradient, giúp quá trình tối ưu diễn ra ổn định và giúp hàm mất mát giảm đều qua các vòng huấn luyện (epoch). Nhờ đó, mô hình đạt được độ chính xác dự đoán cao hơn và học được các mối quan hệ phức tạp có trong dữ liệu phổ.

Đánh giá hiệu suất của các mô hình học máy là bước quan trọng nhằm đảm bảo độ chính xác và độ tin cậy các kết quả dự đoán. Ba mô hình được kiểm định bằng các chỉ số đánh giá thông dụng bao gồm MSE, RMSE, MAPE và hệ số tương quan R^2 .

Các chỉ số này được định nghĩa như sau:

$$MSE = \frac{1}{N} \sum_{i=1}^N \left(d_i^{ref} - d_i^{pred} \right)^2 \quad (1)$$

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N \left(d_i^{ref} - d_i^{pred} \right)^2 \right]^{1/2} \quad (2)$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{d_i^{ref} - d_i^{pred}}{d_i^{ref}} \right| \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N \left(d_i^{ref} - d_i^{pred} \right)^2}{\sum_{i=1}^N \left(d_i^{ref} - \overline{d^{pred}} \right)^2} \quad (4)$$

Ở đây d_i^{ref} và d_i^{pred} là độ dày tham khảo và độ dày dự đoán của mẫu thứ i ; $\overline{d^{pred}}$ là giá trị trung bình của tất cả độ dày dự đoán và n là số mẫu.

VẬT LIỆU VÀ PHƯƠNG PHÁP

Vật liệu

Bộ ba nguồn bức xạ ^{241}Am có tổng hoạt độ khoảng 1776 MBq phát ra tia gamma có năng lượng 59,54 keV được dùng để kích thích các nguyên tố trong mẫu oxit (bao gồm ZrO_2 , Sb_2O_3 và BaSO_4). Quá trình kích thích tạo ra các tia X huỳnh quang đặc trưng có năng lượng 15,78 keV (Zr-K_α), 17,67 keV (Zr-K_β), 26,36 keV (Sb-K_α), 29,73 keV (Sb-K_β), 32,2 keV (Ba-K_α) và 36,38 keV (Ba-K_β). Chùm tia X được định hướng truyền qua các mẫu nhôm có độ dày thay đổi trong khoảng từ 0,051 cm đến 1,154 cm. Cường độ của chùm tia X bị suy giảm khi truyền qua mẫu đo và được ghi lại bởi một đầu dò bán dẫn Si(Li), có độ phân giải 157 eV tại năng lượng 5,9 keV. Bố trí thí nghiệm được mô tả chi tiết trong nghiên cứu trước đây của chúng tôi⁵. Phổ năng lượng được thu nhận với 8192 kênh, trong đó vùng phổ từ kênh 2402 đến kênh 6731 (tương ứng với 4330 kênh) bao phủ toàn bộ các đỉnh huỳnh quang K_α và K_β của các nguyên tố Zr, Sb và Ba. Mỗi phần tử trong phổ đại diện cho số đếm photon tương ứng với một khoảng năng lượng xác định. Dữ liệu số đếm trong vùng kênh này được trích xuất để tạo thành tập dữ liệu đầu vào cho các mô hình học máy.

Thu thập dữ liệu

Bài báo này sử dụng lại các dữ liệu thực nghiệm đã được công bố trong nghiên cứu trước đây⁵. Dữ liệu bao gồm phổ tại 95 mức độ dày khác nhau của tấm nhôm. Ứng với mỗi giá trị độ dày, phép đo được lặp lại ba lần, và mỗi lần đo có thời gian ghi nhận là 10800 s. Như vậy, tổng số phổ thực nghiệm thu được là 285 phổ. Các dữ liệu này được phân chia thành ba tập con: tập huấn luyện, tập xác thực và tập kiểm tra. Mỗi tập con đảm nhiệm một chức năng riêng trong quá trình xây dựng mô hình. Trong đó, tập huấn luyện được sử dụng như nguồn dữ liệu chính để mô hình học các đặc trưng của phổ và thiết lập quan hệ giữa độ dày và tín hiệu ghi nhận. Tập huấn luyện bao gồm 135 phổ tương ứng với 45 độ dày mẫu. Tập xác thực được sử dụng để điều chỉnh các siêu tham số của mô hình,

Bảng 1: Độ dày mẫu nhôm ứng với các tập dữ liệu ⁵

Độ dày (cm)								
Huấn luyện			Xác thực			Thử nghiệm		
0,051(1)	0,366(2)	0,581(3)	0,880(5)	0,131(2)	0,896(5)	0,064(1)	0,395(2)	0,803(4)
0,080(1)	0,379(2)	0,590(4)	0,925(4)	0,160(1)	1,023(5)	0,098(1)	0,413(2)	0,829(4)
0,115(2)	0,408(2)	0,637(5)	0,952(6)	0,211(2)	1,120(7)	0,144(2)	0,459(3)	0,845(4)
0,149(2)	0,426(3)	0,661(3)	0,989(5)	0,253(2)		0,162(2)	0,493(3)	0,867(5)
0,178(2)	0,450(2)	0,674(4)	1,040(6)	0,293(4)		0,195(3)	0,530(3)	0,885(5)
0,202(1)	0,475(2)	0,694(4)	1,069(6)	0,346(3)		0,213(3)	0,563(2)	0,918(6)
0,224(2)	0,488(3)	0,757(4)	1,087(6)	0,392(3)		0,229(3)	0,573(3)	0,927(5)
0,248(1)	0,501(3)	0,787(4)	1,138(7)	0,442(3)		0,242(3)	0,597(3)	0,965(6)
0,275(3)	0,526(3)	0,816(4)	1,154(7)	0,517(2)		0,266(2)	0,627(3)	1,016(7)
0,282(2)	0,539(3)	0,838(5)		0,610(3)		0,299(2)	0,666(4)	1,056(6)
0,304(3)	0,555(3)	0,856(6)		0,725(5)		0,315(1)	0,717(5)	1,074(6)
0,328(2)	0,568(3)	0,863(4)		0,821(4)		0,351(3)	0,765(3)	

Chú thích: 0,051(1) có nghĩa là $0,051 \pm 0,001$.

đồng thời giúp hạn chế tình trạng quá khớp (over fitting). Tập dữ liệu này bao gồm 45 phổ được tách hoàn toàn khỏi tập huấn luyện. Các dữ liệu này không được sử dụng trực tiếp trong quá trình đào tạo mà đóng vai trò là điểm kiểm tra để đánh giá hiệu suất của mô hình. Điều này giúp đảm bảo rằng mô hình phù hợp tốt với dữ liệu mới. Tập kiểm tra được sử dụng sau khi mô hình ANNs đã được đào tạo đầy đủ để đánh giá hiệu suất cuối cùng. Tập dữ liệu này bao gồm 105 phổ tương ứng với 35 độ dày mẫu. Việc phân chia này bảo đảm rằng mỗi độ dày chỉ xuất hiện trong một tập dữ liệu duy nhất, qua đó loại bỏ hiện tượng rò rỉ dữ liệu và duy trì tính độc lập giữa các tập dữ liệu. Giá trị độ dày và độ không đảm bảo của các dữ liệu trong từng tập con được trình bày trong Bảng 1.

KẾT QUẢ VÀ THẢO LUẬN

Tối ưu hóa các mô hình

Tối ưu hóa mô hình là quá trình lựa chọn các siêu tham số phù hợp nhằm cải thiện hiệu suất dự đoán của mô hình học sâu. Các siêu tham số này bao gồm số lượng lớp ẩn, số lượng neuron trong mỗi lớp ẩn, hàm kích hoạt, tốc độ học (learning rate), kích thước lô (batch size) và số vòng lặp (epochs). Việc lựa chọn các siêu tham số hợp lý giữ vai trò quan trọng trong khả năng hội tụ của mô hình và độ chính xác cuối cùng. Tuy nhiên, quá trình tìm kiếm các siêu tham số tối ưu thường tốn nhiều thời gian và yêu cầu tài nguyên tính toán đáng kể.

Trong nghiên cứu này, phương pháp tìm kiếm ngẫu nhiên (Random Search) ¹⁴ được sử dụng để xác định tổ hợp siêu tham số phù hợp cho các mô hình được khảo sát. Cách tiếp cận này được chọn dựa trên ba tiêu chí là: *i/* quy mô không gian siêu tham số lớn; *ii/* giới hạn tài nguyên tính toán; và *iii/* nhu cầu đánh giá hiệu quả của nhiều mô hình khác nhau trong cùng một dữ liệu. Phương pháp tìm kiếm ngẫu nhiên cho phép khảo sát không gian siêu tham số một cách tiết kiệm, thay vì kiểm tra toàn bộ các tổ hợp có thể, phương pháp này lựa chọn ngẫu nhiên một tập hợp giá trị, qua đó giảm đáng kể thời gian và chi phí tính toán. Đồng thời, nó vẫn đảm bảo khả năng tìm ra các siêu tham số tốt nhất, góp phần cải thiện hiệu suất của mô hình.

Cụ thể, quá trình tìm siêu tham số tối ưu được thực hiện 20 lần cho mô hình FNN, 50 lần cho các mô hình CNN và RNN. Trong mỗi lần thực hiện, một tổ hợp siêu tham số được chọn ngẫu nhiên từ không gian tìm kiếm đã xác định trước, sau đó hiệu suất của mô hình với tổ hợp này được đánh giá trên tập xác thực. Quá trình lựa chọn hàm kích hoạt và tối ưu hóa các siêu tham số được định hướng bởi mục tiêu giảm thiểu các chỉ số đánh giá thống kê như MSE, RMSE và MAPE. Cấu hình cho kết quả tốt nhất được giữ lại và sử dụng trong quá trình huấn luyện chính thức của mô hình; kết quả chi tiết được trình bày trong Hình 1 và Bảng 2.

Bảng 3 cung cấp các chỉ số đánh giá hiệu suất của ba mô hình (FNN, CNN, RNN) trên tập huấn luyện và

Bảng 2: Giá trị của các siêu tham số trong mô hình FNN, CNN và RNN tối ưu [Nguồn: nhóm tác giả]


Mô hình FNN	Mô hình CNN	Mô hình RNN
Lớp ẩn thứ 1: Số neuron: 150 Hàm kích hoạt: Sigmoid	Lớp tích chập thứ 1: Số bộ lọc (filters): 32 Kích thước kernel: 5	Lớp LSTM 1: Số neuron: 150 Hàm kích hoạt: Tanh
Lớp ẩn thứ 2: Số neuron: 50 Hàm kích hoạt: Softsign	Kích thước pooling: 2 Hàm kích hoạt: ReLU	Lớp LSTM 2: Số neuron: 50 Hàm kích hoạt: Sigmoid
Lớp ẩn thứ 3: Số neuron: 32 Hàm kích hoạt: ReLU Tốc độ học: 0,003241 Kích thước lô: 32 Số vòng lặp: 300	Lớp tích chập thứ 2: Số bộ lọc (filters): 64 Kích thước kernel: 5 Kích thước pooling: 2 Hàm kích hoạt: ReLU	Lớp kết nối: Số neuron: 128 Hàm kích hoạt: Softsign Tốc độ học: 0,006388 Kích thước lô: 32 Số vòng lặp: 300
	Lớp tích chập thứ 3: Số bộ lọc (filters): 128 Kích thước kernel: 5 Kích thước pooling: 1 Hàm kích hoạt: ReLU	
	Lớp kết nối: Số neuron: 64 Hàm kích hoạt: Sigmoid Tốc độ học: 0,001006 Kích thước lô: 32 Số vòng lặp: 300	

Bảng 3: Các chỉ số MSE, RMSE, MAPE và R^2 tương ứng với các mô hình tối ưu [Nguồn: nhóm tác giả]

	Chỉ số	FNN	CNN	RNN
Tập huấn luyện	MSE	0,0000024	0,0000046	0,0000016
	RMSE	0,00154	0,00214	0,00126
	MAPE	0,18762	0,28916	0,18029
	R^2	0,99995	0,99990	0,99997
Tập xác thực	MSE	0,0000085	0,0000071	0,0000075
	RMSE	0,00291	0,00267	0,00274
	MAPE	0,33082	0,34033	0,30734
	R^2	0,99982	0,99985	0,99984

tập xác thực. Về chỉ số MSE, mô hình RNN đạt hiệu suất tốt nhất trên tập huấn luyện với giá trị MSE thấp nhất (0,0000016), cho thấy khả năng học và ghi nhớ dữ liệu rất tốt. Tuy nhiên, trên tập xác thực, mô hình CNN lại có MSE thấp nhất (0,0000071), phản ánh khả năng tổng quát hóa vượt trội, phù hợp với nghiên cứu trước đây¹⁵ về khả năng trích xuất đặc trưng hiệu quả của CNN và khả năng hoạt động ổn định trên dữ liệu có cấu trúc tuyến tính một chiều. Dù phổ tia X không mang tính chuỗi thời gian theo nghĩa truyền thống, tính liên tục theo năng lượng vẫn cho phép CNN phát huy ưu thế trong việc học hình dạng và cấu trúc phổ. Tương tự, các chỉ số RMSE trên tập huấn luyện cho thấy RNN có giá trị thấp nhất (0,00126), sau đó là FNN và CNN. CNN tiếp tục có RMSE tốt nhất trên

tập xác thực (0,00267), cho thấy khả năng dự đoán chính xác và chống quá khớp (overfitting) hiệu quả hơn. Về chỉ số MAPE, RNN duy trì hiệu suất dự đoán tốt nhất cả trên tập huấn luyện (0,18029) và tập xác thực (0,30734), cho thấy khả năng xử lý mối quan hệ thời gian mạnh mẽ. Tuy nhiên, có nguy cơ quá khớp khi hiệu suất trên tập xác thực không vượt trội như CNN. Cuối cùng, chỉ số R^2 phản ánh khả năng giải thích biến thiên dữ liệu. Trên tập huấn luyện, RNN đạt R^2 cao nhất (0,99997), nhưng CNN lại có R^2 tốt nhất trên tập xác thực (0,99985), chứng tỏ khả năng khái quát hóa tốt của mô hình CNN. Như vậy, RNN thể hiện khả năng học sâu mạnh mẽ nhưng gặp rủi ro quá khớp, trong khi CNN cho thấy



Hình 1: Các mô hình học máy tối ưu của a) FNN, b) CNN và c) RNN [Nguồn: nhóm tác giả]




hiệu suất tổng quát hóa tốt hơn trên dữ liệu mới. FNN, dù có hiệu suất ổn định, không vượt trội trong việc xử lý các đặc trưng phức tạp như hai mô hình còn lại.

Dự đoán độ dày mẫu nhôm


Ba mô hình học máy gồm FNN, CNN và RNN đã được triển khai để dự đoán độ dày của tấm nhôm thông qua phương pháp phổ tia X truyền qua, với các tham số tối ưu được trình bày trong Bảng 2. Mục tiêu chính là đánh giá khả năng dự đoán và mức độ tổng quát hóa của từng mô hình thông qua so sánh độ sai biệt giữa giá trị dự đoán và giá trị tham khảo.

Các kết quả dự đoán, được minh họa trong Hình 2, cho thấy cả ba mô hình đều có khả năng dự đoán chính xác độ dày nhôm, với sự phù hợp cao giữa giá trị dự đoán và giá trị tham khảo. Dựa trên các chỉ số thống kê và độ lệch tương đối (RD) trình bày trong Hình 3 và Bảng 4, có thể nhận thấy độ lệch cực đại của FNN, CNN và RNN lần lượt là 4,66%, 3,44% và 4,72%, trong khi độ lệch trung bình tương ứng là 1,22%, 0,92% và 0,85%. Như vậy, các mô hình đều đạt sai số dự đoán dưới 5%, đáp ứng yêu cầu về độ chính xác trong các ứng dụng đo lường thực tiễn.

Mô hình FNN: Các chỉ số MSE, RMSE và MAPE trên cả hai tập huấn luyện và xác thực đều cao hơn so với CNN và RNN, phản ánh hạn chế của FNN khi phải xử lý các dữ liệu phức tạp. Do đó, FNN có thể phù



Hình 2: So sánh độ dày tham khảo với độ dày dự đoán từ mô hình FNN, CNN và RNN [Nguồn: nhóm tác giả]



Hình 3: Phân bố độ lệch tương đối của mô hình FNN, CNN và RNN so với giá trị tham khảo [Nguồn: nhóm tác giả]

Bảng 4: Các chỉ số thống kê và độ lệch tương đối của các mô hình FNN, CNN và RNN [Nguồn: nhóm tác giả]

Chỉ số	FNN	CNN	RNN
MSE	0,0000133	0,0000112	0,0000115
RMSE	0,00365	0,00335	0,00340
MAPE	0,43280	0,45823	0,42220
R^2	0,99973	0,99977	0,99976
Độ lệch tương đối cực đại (%)	4,66	3,44	4,72
Độ lệch tương đối trung bình (%)	1,22	0,92	0,85

hợp hơn với các bài toán có đặc trưng đơn giản hoặc ít yêu cầu về sự tinh vi trong mô hình hóa.

Mô hình CNN: CNN chứng tỏ khả năng tổng quát hóa tốt nhất, thể hiện qua giá trị MSE thấp nhất trên tập xác thực (0,0000071), RMSE thấp nhất (0,00267) và độ lệch tương đối thấp nhất (3,44% cực đại, 0,92% trung bình). Mặc dù MAPE trên tập huấn luyện cao hơn RNN, nhưng CNN vẫn chứng minh được tính ổn định, khả năng chống quá khớp (overfitting) hiệu quả và khả năng trích xuất đặc trưng tối ưu, khiến nó trở thành lựa chọn phù hợp nhất cho các bài toán dự đoán độ dày nhôm trong điều kiện thực tế.

Mô hình RNN: RNN có ưu thế trong việc học và ghi nhớ các mối quan hệ thời gian, thể hiện qua MSE thấp nhất trên tập huấn luyện (0,0000016) và RMSE thấp nhất (0,00126). Tuy nhiên, trên tập xác thực, RNN không đạt hiệu suất tổng quát hóa tốt như CNN, với độ lệch tương đối cực đại lên tới 4,72%, cho thấy nguy cơ quá khớp (overfitting) nếu không được điều chỉnh phù hợp. Dù vậy, với độ chính xác cao (MAPE: 0,4222%), RNN vẫn cho thấy hiệu suất dự đoán tốt. Tuy nhiên, phổ tia X là một tín hiệu một chiều có trật tự theo năng lượng - tương tự chuỗi thời gian nhưng không mang yếu tố thời gian thực. Do đó, hiệu quả của RNN trong bài toán này có thể không đến từ khả năng khai thác thông tin theo thời gian, mà chủ yếu xuất phát từ khả năng học các mối liên hệ phi tuyến và dài hạn giữa các vùng năng lượng trong phổ.

Điểm đáng chú ý là các mô hình được huấn luyện trực tiếp trên phổ truyền qua đo thực nghiệm, trong đó tín hiệu chứa các thăng giáng thống kê số đếm photon, nhiễu điện tử của hệ đo, và biến thiên cường độ phát xạ của nguồn phóng xạ. Tập dữ liệu này phản ánh các đặc trưng nhiễu và biến thiên thường gặp trong phép đo phổ, qua đó cho phép đánh giá độ ổn định của mô hình. Trong các điều kiện đó, cả ba mô hình vẫn duy trì sai số thấp và ổn định, khẳng định tiềm năng tích hợp mô hình này vào các hệ thống đo phổ trực tuyến hoặc thiết bị kiểm tra không phá hủy, nơi yêu cầu đồng thời độ chính xác và tốc độ xử lý cao.

So sánh với nghiên cứu⁵, cả hai cùng sử dụng bộ dữ liệu phổ tia X truyền qua nhưng mục tiêu và hướng tiếp cận mô hình hóa là hoàn toàn khác biệt: nghiên cứu⁵ tập trung đánh giá khả năng dự đoán độ dày đối với một mô hình cụ thể, trong khi nghiên cứu này so sánh hiệu suất của ba kiến trúc học sâu. Dù độ lệch tương đối cực đại trong nghiên cứu này cao hơn (dưới 5%) so với kết quả trong nghiên cứu⁵ (khoảng 3%), độ lệch trung bình vẫn duy trì ở mức rất thấp (dưới 1,3%) và các mô hình thể hiện tính ổn định cao trên tập kiểm tra. Việc sử dụng phổ thô không qua xử lý đặc trưng cùng khả năng tổng quát hóa tốt cho thấy hướng tiếp cận hiện tại mang tính mở rộng cao, phù hợp với các ứng dụng thực tế khi phổ có thể biến đổi hình dạng hoặc chứa nhiễu. Do đó, hai nghiên cứu cần được nhìn nhận như các định hướng bổ sung cho nhau, kết quả của nghiên cứu này tiếp tục khẳng định tính hiệu quả của mô hình học sâu trong phân tích phổ tia X truyền qua.

Về mặt hiệu suất tính toán, nghiên cứu chưa tiến hành đo định lượng cụ thể thời gian huấn luyện và dự đoán. Tuy nhiên, dựa trên đặc trưng kiến trúc có thể nhận định rằng FNN có thời gian huấn luyện ngắn nhất do cấu trúc đơn giản; CNN yêu cầu thời gian trung bình vì bao gồm các tầng tích chập và trích xuất đặc trưng; trong khi RNN có thời gian huấn luyện dài nhất do cơ chế lan truyền ngược qua chuỗi. Việc bổ sung đánh giá định lượng thời gian tính toán sẽ được xem xét trong các nghiên cứu tiếp theo để hoàn thiện hơn việc so sánh toàn diện giữa các mô hình.

KẾT LUẬN

Nghiên cứu này giới thiệu và triển khai thành công ba kiến trúc học máy FNN, CNN, và RNN để dự đoán độ dày của vật liệu nhôm dựa trên dữ liệu phổ tia X truyền qua đa năng lượng. Các mô hình đã được tối ưu hóa cả về cấu trúc lẫn siêu tham số, nhằm đảm bảo khả năng xử lý hiệu quả các dữ liệu phức tạp và phát hiện các mối quan hệ phi tuyến một cách chính xác. Kết quả so sánh giữa giá trị tham khảo và giá trị dự

đoán từ các mô hình cho thấy độ chính xác cao, với độ lệch tương đối dưới 5% trong tất cả các trường hợp. Các chỉ số thống kê như MSE, RMSE, MAPE và R^2 đều đạt giá trị rất tốt, minh chứng cho khả năng dự đoán đáng tin cậy và tính hiệu quả của các mô hình học máy được phát triển. Đặc biệt, CNN và RNN thể hiện ưu thế trong việc xử lý dữ liệu phổ, với độ lệch tương đối trung bình giữa giá trị dự đoán và giá trị tham khảo thấp lần lượt là 0,92% và 0,85%. Điều này khẳng định khả năng của CNN trong việc trích xuất các đặc trưng không gian và của RNN trong việc nắm bắt các quan hệ thời gian trong dữ liệu.

Những kết quả thu được không chỉ khẳng định tính khả thi và hiệu quả của các mô hình học máy trong việc dự đoán độ dày vật liệu nhôm mà còn mở ra triển vọng lớn cho việc ứng dụng các phương pháp này trong kiểm tra không phá hủy. Với khả năng dự đoán chính xác và hiệu suất cao, các mô hình FNN, CNN, và RNN có thể được mở rộng ứng dụng cho nhiều loại vật liệu khác, góp phần nâng cao độ tin cậy và hiệu quả trong các quy trình kiểm tra công nghiệp và nghiên cứu khoa học. Bên cạnh đó, các mô hình học máy nêu trên đều có thời gian tính toán nhanh, do đó rất phù hợp để xử lý khối lượng lớn dữ liệu trong thời gian ngắn cũng như trong các ứng dụng phân tích thời gian thực. Kết quả này tạo nền tảng cho các hướng nghiên cứu tiếp theo nhằm hoàn thiện thuật toán, tối ưu hóa mô hình và mở rộng ứng dụng học máy trong phân tích phổ và kiểm tra chất lượng vật liệu.

DANH MỤC TỪ VIẾT TẮT

ANN: Mạng neuron nhân tạo

FNN: Mạng neuron truyền thẳng

CNN: Mạng neuron tích chập

RNN: Mạng neuron hồi quy

MSE: Trung bình bình phương sai số

RMSE: Căn bậc hai của trung bình bình phương sai số

MAPE: Sai số phần trăm trung bình tuyệt đối

XUNG ĐỘT LỢI ÍCH

Nhóm tác giả cam kết không mâu thuẫn quyền lợi và nghĩa vụ của các thành viên.

ĐÓNG GÓP CỦA TÁC GIẢ

Nguyễn Thị Trúc Linh xây dựng và tối ưu mô hình, viết bản thảo. Lê Thị Ngọc Trang xây dựng và tối ưu mô hình. Huỳnh Đình Chương lên ý tưởng, phân tích số liệu. Hoàng Đức Tâm lên ý tưởng sửa và góp ý bản thảo.

LỜI CẢM ƠN

Nghiên cứu này được tài trợ bởi Quỹ Phát triển khoa học và công nghệ Quốc gia (NAFOSTED) trong đề tài mã số 103.04-2021.20.

TÀI LIỆU THAM KHẢO

1. Suh CH, Jung YC, Kim YS. Effects of thickness and surface roughness on mechanical properties of aluminum sheets. *Journal of Mechanical Science and Technology*. 2010;24(10):2091–8.
2. Yan Y, Lu M, Guo WW, Li XW. Effect of pre-fatigue deformation on thickness-dependent tensile behavior of coarse-grained pure aluminum sheets. *Materials Science and Engineering A*. 2014;600:99–107.
3. Gójska AM, Miśta-Jakubowska EA, KoziolK, Wasilewski A, Diduszko R. The K-X-ray intensity ratios as a tool of examination and thickness measurements of coating layers. *Measurement: Journal of the International Measurement Confederation*. 2024;224. Available from: <https://doi.org/10.1016/j.measurement.2023.113871>.
4. Matyi RJ, Hatzistergos MS, Lifshin E. X-ray reflectometry analyses of chromium thin films. *Thin Solid Films*. 2006;515(4):1286–93. Available from: <https://doi.org/10.1016/j.tsf.2006.03.016>.
5. Linh NT, Khang NH, Trang LT, Chuong HD, Thanh TT, Phuong HT, et al. Determining the thickness of a thin aluminum sheet using the transmission measurement of X-rays with varying energies: A comparative analysis between calibration curve fitting and artificial neural network approaches. *Nucl. Instruments Methods Phys. Res. Sect. A Accel. Spectrometers. Nuclear Instruments & Methods in Physics Research Section A, Accelerators, Spectrometers, Detectors and Associated Equipment*. 2024;1068. Available from: <https://doi.org/10.1016/j.nima.2024.169740>.
6. Krizhevsky A, Sutskever I, Hinton GE. ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*. 2017;60(6):84–90. Available from: <https://doi.org/10.1145/306538>.
7. Kim W, Ko K, Park J, Lee S, Yun H, Cho G. Deep learning-based gamma spectroscopic analysis considering multiple variables for in situ applications. *Radiation Physics and Chemistry*. 2025;226. Available from: <https://doi.org/10.1016/j.radphyschem.2024.112261>.
8. Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*. 1997;9(8):1735–80. Available from: <https://doi.org/10.1162/neco.1997.9.8.1735>.
9. Li W, Law KL, Li W. K. L. EDDIE LAW. Deep Learning Models for Time Series Forecasting: A Review. *IEEE Access: Practical Innovations, Open Solutions*. 2024;12:92306–27. Available from: <https://doi.org/10.1109/ACCESS.2024.3422528>.
10. Santos AGMD, de Freitas Dam RS, da Cruz PA, Salgado WL, Salgado CM. Thickness prediction in metal alloys using nuclear techniques and artificial neural network: modelling. *Applied Radiation and Isotopes*. 2023;191. Available from: <https://doi.org/10.1016/j.apradiso.2022.110531>.
11. Nazemi E, Aminipour M, Olfateh A, Golgoun SM, Davarpanah MR. Proposing an intelligent approach for measuring the thickness of metal sheets independent of alloy type. *Applied Radiation and Isotopes*. 2019;149:65–74. Available from: <https://doi.org/10.1016/j.apradiso.2019.03.023>.
12. Kamuda M, Zhao J, Huff K. A comparison of machine learning methods for automated gamma-ray spectroscopy. *Nuclear Instruments & Methods in Physics Research Section A, Accelerators, Spectrometers, Detectors and Associated Equipment*. 2020;954. Available from: <https://doi.org/10.1016/j.nima.2018.10.063>.
13. Kingma DP, Ba JL. Adam: A method for stochastic optimization. In: and others, editor. 3rd Int Conf Learn Represent ICLR 2015 - Conf Track Proc; 2015. p. 1–15.

14. Bergstra J, Bengio Y. Random Search for Hyper-Parameter Optimization. Journal of Machine Learning Research. 2012;13:281–305.
15. Gopali S, Abri F, Siami-Namini S, Namin AS. A comparative study of detecting anomalies in time series data using LSTM and TCN models. arXiv:2112.09293v1. 2021;Available from: <https://doi.org/10.48550/arXiv.2112.09293>.

Machine Learning Applications in Predicting Aluminum Material Thickness from Transmission X-ray Spectra: A Comparative Study of Feedforward Neural Network (FNN), Convolutional Neural Network (CNN), and Recurrent Neural Network (RNN) Models

Nguyen Thi Truc Linh^{1,2,*}, Le Thi Ngoc Trang^{1,2}, Huynh Dinh Chuong¹, Hoang Duc Tam³



Use your smartphone to scan this QR code and download this article

¹Nuclear Technique Laboratory, University of Science, VNU-HCM, Vietnam

²Faculty of Physics and Engineering Physics, University of Science, VNU-HCM, Vietnam

³Faculty of Physics, Ho Chi Minh City University of Education, Vietnam

Correspondence

Nguyen Thi Truc Linh, Nuclear Technique Laboratory, University of Science, VNU-HCM, Vietnam

Faculty of Physics and Engineering Physics, University of Science, VNU-HCM, Vietnam

Email: nttlinh@hcmus.edu.vn

History

- Received: 05-02-2025
- Revised: 28-11-2025
- Accepted: 12-12-2025
- Published Online: 31-12-2025

DOI :

<https://www.doi.org/10.32508/stdjns.v9i4.1435>



Check for updates

Copyright

© VNUHCM Press. This is an open-access article distributed under the terms of the Creative Commons Attribution 4.0 International license.



ABSTRACT

This study presents a machine-learning approach for predicting the thickness of aluminum plates using multi-energy X-ray transmission spectra. Three neural network architectures are investigated, including a Feedforward Neural Network (FNN), a Convolutional Neural Network (CNN) and a Recurrent Neural Network (RNN). The experiment setup employs a ²⁴¹Am radioactive source with a total activity of approximately 1776 MBq to excite a composite target containing Zr, Sb, and Ba, thereby generating six characteristic X-ray lines at 15.78 keV (Zr-K α), 17.67 keV (Zr-K β), 26.36 keV (Sb-K α), 29.73 keV (Sb-K β), 32.2 keV (Ba-K α), and 36.38 keV (Ba-K β). The collimated radiation beams are transmitted through aluminum samples of varying thicknesses, and the resulting spectra are recorded using a Si(Li) semiconductor detector. From the measured spectral, the attenuation behaviour of X-ray intensity as a function of material thickness is extracted and used to train and evaluate the machine-learning models. The hyperparameters are subsequently optimized to obtain the most effective model configuration. After optimization, transmission spectra corresponding to aluminum samples of various thicknesses are input into the models to further validate their prediction capability. The results show that all three architectures - FNN, CNN, and RNN - achieve high predictive accuracy, with relative errors below 5% compared with the reference values. Such results confirm the effectiveness of integrating machine-learning techniques with multi-energy X-ray transmission for the quantitative determination of aluminum thickness and demonstrate the potential of this approach for practical non-destructive testing applications.

Key words: X-ray transmission, FNN, CNN, RNN

Cite this article : Linh N T T, Trang L T N, Chuong H D, Tam H D. **Machine Learning Applications in Predicting Aluminum Material Thickness from Transmission X-ray Spectra: A Comparative Study of Feedforward Neural Network (FNN), Convolutional Neural Network (CNN), and Recurrent Neural Network (RNN) Models.** *Sci. Tech. Dev. J. - Nat. Sci.* 2025; 9(4):3517-3526.