

XÂY DỰNG MÔ HÌNH TIÊU HAO NHIÊN LIỆU CHO TÀU THỦY

DEVELOPMENT OF A FUEL CONSUMPTION MODEL FOR SHIPS

Trần Phúc Hoàng^{1,2}, Lương Đình Thi^{1,*}

DOI: <https://doi.org/10.57001/huih5804.2025.289>

TÓM TẮT

Bài báo trình bày quá trình xây dựng mô hình dự báo tiêu hao nhiên liệu cho tàu kéo cứu hộ thuộc lớp tàu TK3500, sử dụng mạng nơ-ron nhân tạo (ANN). Dữ liệu thực nghiệm được thu thập từ hệ thống điều khiển và giám sát của toàn tàu, sau đó được xử lý và chuẩn hóa để huấn luyện mô hình trên nền tảng Matlab. Mạng ANN gồm hai lớp ẩn với số lượng nơ-ron lần lượt là 10 và 5, được lựa chọn nhằm đảm bảo độ chính xác và khả năng hội tụ nhanh. Kết quả kiểm định cho thấy sai số RMSE đạt 9,87 lít/giờ và MAPE là 2,51%. Mô hình cũng giữ được độ ổn định khi kiểm chứng trong điều kiện môi trường biển khắc nghiệt. Nghiên cứu có thể tích hợp vào hệ thống giám sát năng lượng trên tàu, hỗ trợ tiết kiệm nhiên liệu, kiểm kê phát thải CO₂ và góp phần chuyển đổi xanh trong lĩnh vực cơ khí - động lực.

Từ khóa: Mạng nơ-ron nhân tạo; tàu TK3500; tiêu hao nhiên liệu.

ABSTRACT

This paper presents the development of a fuel consumption prediction model for the TK3500 class rescue tugboat, which is operated by the military, using an artificial neural network (ANN). Real-world operational data were collected from the ship's control and monitoring system, then preprocessed and normalized for model training in Matlab. The ANN model consists of two hidden layers with 10 and 5 neurons, respectively, chosen to balance prediction accuracy and convergence speed. Evaluation results show that the model achieved a RMSE of 9.87 LPH and a MAPE of 2.51%. The ANN also demonstrated stable performance under stress test conditions with harsh marine environments. This research can be integrated into onboard energy management systems to support fuel-saving strategies, CO₂ emission estimation, and green transition initiatives in the field of marine mechanical engineering and propulsion systems

Keywords: Artificial Neural Network; TK3500 tugboat; fuel consumption prediction.

¹Viện Cơ khí động lực, Học viện Kỹ thuật Quân sự

²Khoa Cơ điện, Học viện Hải quân

*Email: thiluongdinh@gmail.com

Ngày nhận bài: 28/4/2025

Ngày nhận bài sửa sau phản biện: 04/7/2025

Ngày chấp nhận đăng: 28/7/2025

1. GIỚI THIỆU

Trong bối cảnh ngành hàng hải toàn cầu đang đối mặt với áp lực cắt giảm phát thải khí nhà kính, đặc biệt là CO₂ - loại khí chủ yếu sinh ra từ quá trình đốt cháy nhiên liệu hóa thạch trên tàu thủy, việc tối ưu hóa tiêu hao nhiên liệu trên các phương tiện vận tải thủy, bao gồm cả các loại tàu chuyên dụng trở nên cấp thiết. Theo Tổ chức Hàng hải Quốc tế (IMO), lượng phát thải CO₂ từ các tàu biển chiếm khoảng 2,89% tổng lượng phát thải toàn cầu, tạo ra thách thức lớn cho các quốc gia trong việc thực hiện cam kết chuyển đổi xanh và phát triển bền vững [1].

Trong lĩnh vực tàu thủy, mức tiêu hao nhiên liệu bị chi phối bởi nhiều yếu tố như tốc độ di chuyển của tàu, tải trọng chuyên chở, điều kiện thời tiết, trạng thái mặt biển cũng như đặc tính kỹ thuật của hệ thống động lực. Để tối ưu hóa vận hành, việc xây dựng một mô hình dự báo tiêu hao nhiên liệu chính xác là cần thiết, giúp người vận hành điều chỉnh hành trình hiệu quả hơn, giảm thiểu lãng phí nhiên liệu và kiểm soát phát thải CO₂. Một số nghiên cứu trước đây đã chứng minh tiềm năng của các phương pháp học máy trong lĩnh vực này: Coraddu và cộng sự [2] đã đề xuất áp dụng học máy trong bảo trì dự đoán để nâng cao hiệu suất hệ thống động lực tàu, qua đó gián tiếp hỗ trợ giảm mức tiêu thụ nhiên liệu; trong khi Baldi và cộng sự [3] cho thấy phương pháp phân tích dữ liệu có thể được khai thác để quản lý năng lượng trên tàu một cách hiệu quả và linh hoạt hơn. Trong những năm gần đây, nhiều nghiên cứu đã ứng dụng các phương pháp học máy và trí tuệ nhân tạo vào bài toán dự báo tiêu hao nhiên liệu và phát thải cho tàu thủy. Chẳng hạn, nghiên cứu của Wang và cộng sự đã sử dụng mạng nơ-ron hồi tiếp để dự báo tiêu hao nhiên liệu dựa trên dữ liệu AIS và điều kiện vận hành tàu thương mại [4]. Tương tự, Jeong và cộng sự ứng dụng mạng nơ-ron tích chập (CNN) để phân tích ảnh hưởng của sóng và gió đến mức tiêu hao năng lượng [5]. Tại Việt Nam, Nguyễn Văn Giao và cộng sự đã công bố bài tổng quan hệ thống về ứng dụng ANN


trong dự báo tiêu hao nhiên liệu tàu thủy, nhấn mạnh tiềm năng của ANN trong việc mô hình hóa các mối quan hệ phi tuyến phức tạp và đề xuất hướng phát triển mô hình chuẩn trong tương lai [6]. Tuy nhiên việc áp dụng ANN vào bài toán dự báo tiêu hao nhiên liệu vẫn còn nhiều hạn chế, chủ yếu dừng lại ở các nghiên cứu về tàu thương mại và chưa xét đến các điều kiện vận hành thực tế cùng những yếu tố ảnh hưởng phức tạp trong môi trường hoạt động đặc thù.

Cho đến nay, chưa có nghiên cứu nào công bố mô hình dự báo tiêu hao nhiên liệu ứng dụng mạng nơ-ron nhân tạo cho tàu chuyên dụng tại Việt Nam như tàu cứu kéo lớp TK3500 - một loại tàu cứu chuyên dụng. Từ khoảng trống đó, nghiên cứu này đề xuất một mô hình dự báo tiêu hao nhiên liệu cho lớp tàu TK3500, ứng dụng mạng nơ-ron nhân tạo được huấn luyện trên dữ liệu thực tế từ hệ thống điều khiển và giám sát của toàn tàu.

2. CƠ SỞ LÝ THUYẾT VÀ PHƯƠNG PHÁP NGHIÊN CỨU

2.1. Cơ sở lý thuyết

Mạng nơ-ron nhân tạo (ANN) là một trong những mô hình cốt lõi của trí tuệ nhân tạo, được thiết kế để mô phỏng khả năng học hỏi và xử lý thông tin của não bộ con người. Một mạng ANN điển hình gồm ba thành phần chính: lớp đầu vào (input layer), một hoặc nhiều lớp ẩn (hidden layers), và lớp đầu ra (output layer). Các nơ-ron ở mỗi lớp được kết nối với các nơ-ron ở lớp tiếp theo thông qua các liên kết mang trọng số (weights), thể hiện mức độ tác động và điều chỉnh tín hiệu truyền giữa các nơ-ron [7, 8]. Cấu trúc tổng quan này được minh họa trong hình 1.



Hình 1. Cấu tạo của mạng nơ-ron nhân tạo

Khi một tập dữ liệu được đưa vào, tín hiệu sẽ lan truyền theo chiều xuôi (forward propagation), qua từng lớp nơ-ron và tạo ra đầu ra dự đoán. Độ sai lệch giữa đầu ra dự đoán và giá trị thực được tính toán bằng hàm sai số, sau đó lan truyền ngược (back propagation) để điều chỉnh trọng số theo thuật toán tối ưu như gradient descent

hoặc các biến thể nâng cao như Adam hoặc RMSprop [7, 8]. Chính nhờ cơ chế này, mạng ANN có thể tự học và điều chỉnh cấu trúc nội tại để cải thiện độ chính xác theo từng vòng huấn luyện.

Trong quá trình lan truyền tiến, tín hiệu đầu vào được xử lý qua từng lớp nơ-ron để sinh ra đầu ra dự đoán. Sai số giữa đầu ra dự đoán và đầu ra thực tế sẽ được tính toán và truyền ngược lại trong quá trình lan truyền ngược, nhằm điều chỉnh trọng số theo thuật toán tối ưu. Quá trình này lặp lại nhiều lần để mô hình đạt được độ chính xác tối ưu.

Ưu điểm nổi bật của ANN là khả năng mô hình hóa các mối quan hệ phi tuyến phức tạp, đặc biệt hữu ích trong các hệ thống có nhiều biến đầu vào và mối quan hệ không rõ ràng, chẳng hạn như tiêu hao nhiên liệu của tàu thủy. Khác với các mô hình thống kê truyền thống vốn chỉ xử lý tốt các quan hệ tuyến tính, ANN có thể tự học từ dữ liệu thực tế và khái quát hóa tốt trong nhiều điều kiện vận hành khác nhau [6]. Theo định hướng của IPCC về kiểm kê phát thải, có thể ứng dụng các công cụ như ANN để nâng cao độ chính xác tính toán khí nhà kính.

Những đặc điểm ưu việt trên cho thấy ANN là công cụ phù hợp và tiềm năng để xây dựng mô hình dự báo tiêu hao nhiên liệu cho tàu TK3500 - loại tàu chuyên dụng có đặc thù vận hành trong nhiều chế độ làm việc và điều kiện biển khắc nghiệt.


2.2. Phương pháp nghiên cứu

Trong quá trình xây dựng mô hình mạng nơ-ron nhân tạo để dự báo tiêu hao nhiên liệu, việc lựa chọn số lớp ẩn và số lượng nơ-ron ở mỗi lớp đóng vai trò then chốt, ảnh hưởng trực tiếp đến độ chính xác và khả năng hội tụ của mô hình. Nếu mạng quá đơn giản, mô hình không đủ khả năng học các quan hệ phi tuyến phức tạp; ngược lại, mạng quá sâu hoặc quá nhiều nơ-ron sẽ dễ dẫn đến hiện tượng quá khớp (overfitting), làm giảm khả năng khái quát và kéo dài thời gian huấn luyện.

Việc xác định kiến trúc mạng nơ-ron nhân tạo, cụ thể là số lớp ẩn và số lượng nơ-ron trong từng lớp, trong nghiên cứu này được thực hiện thông qua quá trình thử nghiệm thực nghiệm (Grid Search) trên nhiều cấu hình khác nhau. Mục tiêu là tìm ra cấu trúc mạng tối ưu, vừa đảm bảo sai số dự báo thấp, tốc độ hội tụ nhanh, vừa hạn chế hiện tượng quá khớp quá mức. Nhiều nghiên cứu trước đây về mô hình hóa vận tốc và tiêu hao nhiên liệu tàu thủy cũng cho thấy rằng việc lựa chọn số lượng nơ-ron ở các lớp ẩn không có công thức cố định, mà thường phải thông qua kiểm tra, đánh giá và tối ưu trực tiếp trên dữ

liệu thực tế. Điều này xuất phát từ đặc điểm phi tuyến và phức tạp cao của bài toán, cũng như sự phụ thuộc mạnh mẽ vào chất lượng và quy mô dữ liệu. Theo nghiên cứu của Wieslaw Tarelko và Krzysztof Rudzki [9], cấu trúc mạng ANN phù hợp cho bài toán dự báo vận tốc và tiêu hao nhiên liệu tàu thủy thường được xác định bằng cách thử nghiệm nhiều phương án số lượng nơ-ron và lớp ẩn khác nhau, từ đó chọn ra mô hình có hiệu suất tốt nhất trên tập dữ liệu nghiên cứu. Đây cũng chính là cách tiếp cận được áp dụng trong nghiên cứu này, với kết quả lựa chọn cấu trúc mạng gồm hai lớp ẩn, tương ứng số nơ-ron là 10 và 5:

- Lớp ẩn thứ nhất (10 nơ-ron): trích xuất các đặc trưng phi tuyến mạnh từ đầu vào.
- Lớp ẩn thứ hai (5 nơ-ron): có chức năng tinh chỉnh và ổn định đầu ra từ lớp trước.



Hình 2. Kiến trúc mạng của mô hình

Trong số các thuật toán huấn luyện được MATLAB hỗ trợ, Levenberg–Marquardt (trainlm) được chọn vì đây là phương pháp tối ưu hóa phi tuyến có tốc độ hội tụ nhanh, đặc biệt phù hợp với các mạng có quy mô trung bình. Ưu điểm chính của thuật toán này gồm:

- Hội tụ nhanh hơn so với các thuật toán gradient truyền thống (trainingd, trainscg);
- Giảm thiểu sai số tốt hơn trên tập huấn luyện;
- Tương thích tốt với dữ liệu đã chuẩn hóa (như Min-Max).

Với mạng [10, 5], tổng số nơ-ron là 15 - phù hợp để áp dụng trainlm nhằm đảm bảo hiệu quả huấn luyện trong thời gian hợp lý. Trong quá trình huấn luyện, hàm sai số chính được sử dụng là Mean Squared Error (MSE) - trung bình bình phương sai số giữa giá trị đầu ra dự đoán và thực tế. Đây là tiêu chí chuẩn trong các bài toán hồi quy và được Matlab mặc định áp dụng trong trainlm. Để đánh giá hiệu quả mô hình trên tập kiểm tra, hai chỉ số đánh giá được sử dụng là:

RMSE (Root Mean Square Error) - căn bậc hai của MSE, biểu thị mức sai số trung bình theo đơn vị đo gốc (lít/giờ). Theo Chai và Draxler [10], RMSE là chỉ số quan trọng trong đánh giá chất lượng mô hình khi đơn vị đo gốc có ý nghĩa thực tiễn rõ ràng.

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

MAPE (Mean Absolute Percentage Error) - sai số phần trăm tuyệt đối trung bình, giúp đánh giá độ chính xác mô hình dưới góc nhìn tương đối. Chỉ số này phù hợp để so sánh mức độ chính xác của các mô hình dự báo trong các điều kiện khác nhau [11].

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \quad (2)$$

Trong đó: y_i - giá trị thực tế tại mẫu thứ i ; y'_i - giá trị dự đoán tại mẫu thứ i ; n - tổng số mẫu dữ liệu. Hai chỉ số này sẽ được sử dụng trong Mục 3.1 để đánh giá và so sánh hiệu suất mô hình trên tập kiểm tra và các kịch bản kiểm chứng.

Để xây dựng mô hình tiêu hao nhiên liệu cho tàu TK3500 bằng mạng nơ-ron nhân tạo, quy trình nghiên cứu gồm ba bước chính được thực hiện: (1) xử lý dữ liệu đầu vào, (2) chuẩn hóa dữ liệu và thiết lập mô hình ANN, (3) huấn luyện và đánh giá mô hình. Tất cả các bước đều được triển khai trên nền tảng phần mềm MATLAB.

(1) Xử lý dữ liệu đầu vào

Dữ liệu đầu vào được thu thập từ hệ thống điều khiển và giám sát trên tàu TK3500, bao gồm 7 biến đặc trưng liên quan đến điều kiện vận hành và môi trường biển: tốc độ tàu, tải trọng, độ cao sóng, tốc độ gió, hệ số cản, tốc độ dòng chảy, công suất động cơ. Các bước xử lý dữ liệu bao gồm:

- Thay thế giá trị bằng 0 ở các cột như tốc độ gió và độ cao sóng bằng giá trị trung bình;
- Loại bỏ các mẫu ngoại lệ (outliers) bằng phương pháp khoảng tứ phân vị IQR (Interquartile Range);
- Lưu dữ liệu sạch ra tệp mới để phục vụ cho huấn luyện ở bước tiếp theo.

(2) Chuẩn hóa và thiết lập mô hình mạng ANN

Sau khi dữ liệu đã được làm sạch, tiến hành chuẩn hóa toàn bộ các biến đầu vào về khoảng [0, 1] bằng phương pháp Min-Max Scaling, theo công thức:

$$x = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

Nhằm đảm bảo tất cả các biến có cùng đơn vị chuẩn, giúp tăng hiệu quả hội tụ của mạng nơ-ron trong quá trình huấn luyện. Sau đó, mô hình mạng nơ-ron được xây dựng với các cấu hình như sau: Số lớp ẩn: 2; số nơ-ron ở mỗi lớp: 10 và 5; hàm kích hoạt: tansig cho các lớp ẩn, purelin cho lớp đầu ra; thuật toán huấn luyện: Levenberg–Marquardt (trainlm); hàm sai số: RMSE.

Tập dữ liệu được chia tự động theo tỷ lệ: 80% huấn luyện (train); 10% kiểm định (validation); 10% kiểm tra (test). Tỷ lệ chia này là phương pháp được sử dụng trong

các nghiên cứu học máy hiện đại, đặc biệt khi quy mô dữ liệu ở mức trung bình. Cách chia này giúp đảm bảo mô hình có đủ dữ liệu để học, đồng thời vẫn giữ được một tập kiểm định độc lập để theo dõi quá trình học và tránh khớp quá mức. Tập kiểm tra cuối cùng không tham gia vào quá trình huấn luyện - được dùng để đánh giá khách quan độ khái quát của mô hình [7, 8].

(3) Huấn luyện và đánh giá mô hình


Dữ liệu huấn luyện được đưa vào mô hình ANN để học mối quan hệ giữa các biến đầu vào và lượng nhiên liệu tiêu hao. Sau khi huấn luyện hoàn tất, mô hình được đánh giá trên tập kiểm tra với các chỉ số: RMSE và MAPE. Ngoài ra, mô hình còn được kiểm chứng thêm bằng kịch bản stress test, áp dụng cho các mẫu riêng biệt có tốc độ gió > 8m/s và sóng cao > 2m, nhằm kiểm tra độ ổn định trong điều kiện môi trường khắc nghiệt.

3. KẾT QUẢ VÀ THẢO LUẬN

3.1. Kết quả huấn luyện mô hình

Mô hình mạng nơ-ron nhân tạo được thiết kế nhằm dự báo tiêu hao nhiên liệu của lớp tàu TK3500 trên cơ sở dữ liệu thực nghiệm lấy từ hệ thống giám sát trên tàu. Cụ thể, dữ liệu được ghi nhận tự động với tần suất 1 giờ/mẫu trong suốt quá trình tàu thực hiện nhiều chuyến hành trình khác nhau trên biển, dưới các điều kiện vận hành và môi trường biển khác nhau. Điều này đảm bảo độ phủ rộng về kịch bản hoạt động thực tế, giúp mô hình học được đặc trưng tiêu hao trong nhiều trạng thái vận hành.

Sau khi xử lý và chuẩn hóa dữ liệu theo phương pháp Min-Max, mô hình được huấn luyện bằng thuật toán tối ưu hóa Levenberg-Marquardt (trainlm) trong môi trường Matlab, với cấu trúc mạng gồm hai lớp ẩn (10 và 5 nơ-ron) như đã trình bày tại Mục 2.2. Kết quả huấn luyện cho thấy mô hình đạt độ hội tụ tốt, với sai số huấn luyện giảm ổn định và nhanh chóng qua các vòng lặp. Hiệu suất huấn luyện được minh họa trong hình 3.



Hình 3. Đồ thị hiệu suất huấn luyện ANN

Biểu đồ thể hiện quá trình huấn luyện của mô hình ANN thông qua chỉ số sai số bình phương trung bình trên ba tập dữ liệu: huấn luyện, xác minh và kiểm tra. Kết quả cho thấy cả ba đường cong đều giảm mạnh trong giai đoạn đầu và hội tụ nhanh chóng sau khoảng 10 vòng lặp. Tại vòng lặp thứ 27, mô hình đạt sai số thấp nhất trên tập xác minh - là thời điểm tối ưu để dừng huấn luyện, giúp tránh hiện tượng quá khớp.

Đặc biệt, các đường huấn luyện, xác minh và kiểm tra gần như trùng khớp trong suốt quá trình học, chứng tỏ tính ổn định cao và khả năng khái quát hóa tốt của mô hình. Sai số MSE giảm từ mức ban đầu trên 10^5 xuống ngưỡng dưới 10^2 , phản ánh hiệu suất dự báo đạt yêu cầu. Đây là minh chứng cho thấy mạng ANN với cấu trúc [10, 5] và thuật toán huấn luyện Levenberg-Marquardt không chỉ hội tụ nhanh mà còn giữ được độ chính xác cao và ổn định trên nhiều tập dữ liệu khác nhau.


Mô hình được đánh giá trên tập kiểm tra với các chỉ số:

- RMSE (Root Mean Square Error):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} = 9,87 \text{ (lít/giờ)} \quad (4)$$

- MAPE (Mean Absolute Percentage Error):

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| = 2,51 \% \quad (5)$$




Hình 4. So sánh giá trị thực tế và dự đoán trên tập kiểm tra

Hình 4 trình bày các đồ thị hồi quy thể hiện mối quan hệ giữa giá trị dự đoán của mô hình ANN và giá trị thực tế, được phân tích trên các tập dữ liệu: tập huấn luyện (training), tập kiểm định (validation), tập kiểm tra (test), toàn bộ dữ liệu (all data).

Hình 5 trình bày kết quả so sánh giữa giá trị thực tế và giá trị đầu ra của mô hình mạng nơ-ron nhân tạo trên bốn tập dữ liệu: huấn luyện, kiểm định, kiểm tra và toàn bộ dữ liệu. Tất cả các biểu đồ đều cho thấy mối quan hệ tuyến tính rất mạnh giữa giá trị thực và dự đoán, thể hiện qua

hệ số tương quan R lần lượt là 0,99567 (huấn luyện); 0,99516 (kiểm định); 0,99546 (kiểm tra) và 0,99560 (toàn bộ dữ liệu). Các điểm dữ liệu phân bố gần sát với đường chéo $y = x$, cho thấy sai số dự đoán thấp và mô hình hoạt động ổn định trên toàn dải giá trị từ 0 đến 600.



Hình 5. Đồ thị hồi quy giữa giá trị thực tế và giá trị dự đoán của mô hình ANN


Độ tương đồng cao giữa hệ số tương quan R ở cả ba tập dữ liệu (huấn luyện, kiểm định và kiểm tra) cho thấy mô hình không bị quá khớp và có khả năng khái quát tốt. Không xuất hiện các cụm sai lệch lớn hay ngoại lệ đáng kể, điều này càng khẳng định tính nhất quán của mô hình ANN khi áp dụng trên dữ liệu thực tế. Như vậy, mô hình đã học được quan hệ ẩn giữa các biến đầu vào và đầu ra một cách hiệu quả, phù hợp để áp dụng trong dự báo tiêu hao nhiên liệu cho tàu thủy trong điều kiện vận hành thực.

3.2. Kết quả kiểm chứng mô hình (Stress Test)

Để đánh giá khả năng tổng quát và độ tin cậy của mô hình ANN trong các tình huống thực tế khắc nghiệt, một bài kiểm chứng đặc biệt đã được thực hiện trên tập dữ liệu có điều kiện môi trường bất lợi. Tập này bao gồm các mẫu dữ liệu có: tốc độ gió > 8m/s, chiều cao sóng > 2m. Các điều kiện này tương ứng với trạng thái biển cấp 5 - 6 trở lên, có thể ảnh hưởng đáng kể đến mức tiêu hao nhiên liệu của tàu cứu kéo TK3500. Tập dữ liệu này được trích lọc từ toàn bộ cơ sở dữ liệu ban đầu, bao gồm 2.000 mẫu dữ liệu độc lập, không được sử dụng trong quá trình huấn luyện, xác minh hay kiểm tra mô hình nhằm đảm bảo tính khách quan tuyệt đối khi đánh giá hiệu suất dự báo.

Tập dữ liệu kiểm chứng được xử lý và chuẩn hóa theo công thức Min-Max Scaling sử dụng lại bộ thông số $X_{\min}$ và $X_{\max}$ từ tập huấn luyện ban đầu. Dữ liệu sau chuẩn hóa được đưa vào mô hình ANN đã huấn luyện với kiến trúc [10, 5], sử dụng hàm kích hoạt tansig và thuật toán huấn luyện Levenberg-Marquardt (trainlm) trong môi trường MATLAB. Mô hình dự báo lượng tiêu hao nhiên liệu trên từng mẫu, sau đó so sánh với giá trị thực tế để tính sai số.

Kết quả cho thấy mô hình đạt sai số bình phương căn RMSE là 24,82 (tương đương 6,6% so với mức tiêu hao trung bình) và sai số phần trăm tuyệt đối trung bình MAPE là 4,36%. Đây là mức sai số nhỏ, rất đáng tin cậy; đặc biệt trong bối cảnh tập kiểm chứng phản ánh các điều kiện vận hành ngoài dự kiến và khắc nghiệt. Hình 6 thể hiện sự tương đồng cao giữa giá trị thực tế và dự báo, đường cong dự đoán bám sát đường thực nghiệm với phân bố sai số đều, không xuất hiện xu hướng lệch hệ thống hay trôi mô hình. Kết quả kiểm chứng này khẳng định khả năng khái quát hóa của mô hình ANN, cho thấy mô hình không chỉ học tốt từ dữ liệu huấn luyện mà còn duy trì được độ chính xác cao trong các tình huống mới. Mô hình có thể tích hợp vào các hệ thống giám sát năng lượng trên tàu TK3500, hỗ trợ tối ưu hóa nhiên liệu, dự báo phát thải CO₂ và hướng tới số hóa toàn bộ quy trình vận hành của tàu chuyên dụng trong tương lai.



Hình 6. So sánh tiêu hao nhiên liệu thực tế và dự đoán của mô hình ANN trên tập dữ liệu Stress Test

4. KẾT LUẬN

Bài báo đã trình bày một phương pháp xây dựng mô hình dự báo tiêu hao nhiên liệu cho tàu cứu kéo TK3500 bằng mạng nơ-ron nhân tạo (ANN), sử dụng dữ liệu thực nghiệm thu thập từ hệ thống điều khiển và giám sát trên tàu. Mô hình ANN được thiết kế hai ẩn có số lượng nơ-ron lần lượt là 10 và 5, được huấn luyện bằng thuật toán Levenberg-Marquardt trong môi trường Matlab. Quá trình tối ưu hóa kiến trúc mạng và lựa chọn hàm kích hoạt được thực hiện thông qua phương pháp Grid Search.

Kết quả thực nghiệm cho thấy mô hình đạt sai số RMSE là 9,87 (lít/giờ) và MAPE là 2,51% trên tập kiểm tra. Trên tập dữ liệu kiểm chứng độc lập gồm 2.000 mẫu, sai số RMSE và MAPE lần lượt là 24,82 (lít/giờ) và 4,36%, cho thấy khả năng dự báo ổn định và độ tin cậy cao ngay cả trong điều kiện vận hành khắc nghiệt. Các biểu đồ hồi quy và so sánh giá trị thực tế dự đoán cho thấy mô hình bám sát thực nghiệm, không xuất hiện hiện tượng overfitting, và có hệ số tương quan R rất cao trên tất cả các tập dữ liệu.

TÀI LIỆU THAM KHẢO

- [1]. International Maritime Organization, *Fourth IMO Greenhouse Gas Study 2020*. IMO, London, UK, 2020.
- [2]. A. Coraddu, L. Oneto, F. Baldi, D. Anguita, M. Figari, "Machine learning approaches for improving condition-based maintenance of naval propulsion plants," *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, 230, 1, 136-153, 2016.

[3]. F. Baldi, M. Figari, L. Oneto, "Energy analysis of marine systems using data-driven methods: Applications and potential," *Applied Energy*, 138, 246-258, 2015.

[4]. J. Wang, X. Zhao, L. Wu, "Fuel consumption prediction for ships based on recurrent neural network," *Ocean Engineering*, 166, 321-331, 2018.

[5]. B. Jeong, H. Park, M. Yoon, "A CNN-based prediction model of ship fuel consumption considering sea states," *Journal of Marine Science and Technology*, 25, 2, 175-187, 2020.

[6]. V. G. Nguyen, S. Rajamohan, K. Rudzki, J. Kozak, P. Sharma, N. D. K. Pham, P. Q. P. Nguyen, P. N. Xuan, "Using Artificial Neural Networks for Predicting Ship Fuel Consumption," *Polish Maritime Research*, 30, 2, 39-60, 2023.

[7]. I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, MIT Press, 2016.

[8]. A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow* (2nd ed.). O'Reilly Media, 2019.

[9]. Wieslaw Tarelko, Krzysztof Rudzki, "Applying artificial neural networks for modelling ship speed and fuel consumption," *Neural Computing and Applications*, 32, 17379-17395, 2020.

[10]. T. Chai, R. R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)? - Arguments against avoiding RMSE in the literature," *Geoscientific Model Development*, 7, 3, 1247-1250, 2014.

[11]. R. J. Hyndman, A. B. Koehler, "Another look at measures of forecast accuracy," *International Journal of Forecasting*, 22, 4, 679-688, 2006.

AUTHORS INFORMATION

Tran Phuc Hoang^{1,2}, Luong Dinh Thi¹

¹Institute of Vehicle and Energy Engineering, Le Quy Don Technical University, Vietnam

²Faculty of Mechanical and Electrical Engineering, Vietnam Naval Academy, Vietnam