

TĂNG CƯỜNG DỮ LIỆU DỰA TRÊN AI TẠO SINH TRONG DỰ BÁO TUỔI THỌ HỮU ÍCH CÒN LẠI CỦA THIẾT BỊ HÀNG HẢI GENERATIVE AI-BASED DATA AUGMENTATION FOR REMAINING USEFUL LIFE PREDICTION OF MARINE EQUIPMENT

LÊ ĐĂNG KHÁNH

Khoa Máy tàu biển, Trường Đại học Hàng hải Việt Nam

Email liên hệ: ledangkhanh@vimaru.edu.vn

DOI: <https://doi.org/10.65154/jmst.1104>

Tóm tắt

Bài báo này đề xuất một phương pháp nâng cao độ chính xác dự đoán tuổi thọ còn lại (Remaining Useful Life - RUL) của thiết bị hàng hải thông qua việc ứng dụng trí tuệ nhân tạo tạo sinh (Generative AI) để tăng cường dữ liệu. Trong thực tế, các hệ thống máy tàu như động cơ diesel, máy bơm và máy nén thường thiếu dữ liệu hỏng hóc do tần suất sự cố thấp, dẫn đến hạn chế hiệu quả của các mô hình học sâu. Để giải quyết vấn đề này, nghiên cứu sử dụng mô hình Variational Autoencoder (VAE) nhằm sinh dữ liệu cảm biến tổng hợp có đặc tính tương tự dữ liệu thực. Dữ liệu được tăng cường sau đó được sử dụng để huấn luyện mô hình mạng nơ-ron hồi tiếp dài ngắn hạn (LSTM- Long Short-Term Memory) cho bài toán dự đoán RUL. Bộ dữ liệu NASA CMAPSS được sử dụng để kiểm chứng phương pháp đề xuất. Kết quả thực nghiệm cho thấy việc tích hợp dữ liệu sinh giúp cải thiện đáng kể độ chính xác dự báo so với mô hình cơ sở, thể hiện qua các chỉ số RMSE (Root Mean Squared Error) và MAE (Mean Absolute Error). Nghiên cứu này chứng minh tiềm năng của Generative AI trong việc nâng cao hiệu quả bảo trì dự đoán cho thiết bị hàng hải, góp phần giảm chi phí vận hành và tăng độ tin cậy hệ thống.

Từ khóa: Bảo trì dự đoán, tuổi thọ còn lại, trí tuệ nhân tạo tạo sinh, tăng cường dữ liệu, thiết bị hàng hải.

Abstract

This paper proposes an enhanced approach for predicting the Remaining Useful Life (RUL) of marine equipment by leveraging Generative Artificial Intelligence (Generative AI) for data augmentation. In real-world marine systems such as diesel engines, pumps, and compressors, failure data are often scarce due to low failure

frequency, which limits the performance of deep learning models. To address this issue, a Variational Autoencoder (VAE) is employed to generate synthetic sensor data that preserve the statistical characteristics of real measurements. The augmented dataset is then used to train a Long Short-Term Memory (LSTM) network for RUL prediction. The proposed method is validated using the NASA CMAPSS dataset. Experimental results demonstrate that incorporating generated data significantly improves prediction accuracy compared to baseline models, as evidenced by reductions in RMSE and MAE. The findings highlight the potential of Generative AI in enhancing predictive maintenance strategies for marine equipment, contributing to reduced operational costs and improved system reliability.

Keywords: Predictive maintenance, remaining useful life, generative artificial intelligence, data augmentation, marine equipment.

1. Mở đầu

Trong bối cảnh ngành hàng hải hiện đại đang hướng tới tối ưu hóa hiệu quả vận hành, giảm chi phí và nâng cao độ an toàn, công tác bảo trì thiết bị đóng vai trò đặc biệt quan trọng. Các hệ thống máy tàu như động cơ diesel, máy bơm, máy nén và máy phát điện là những thành phần cốt lõi quyết định đến khả năng hoạt động liên tục và tin cậy của tàu biển. Trong thực tế, các phương pháp bảo trì truyền thống như bảo trì định kỳ (time-based maintenance) hoặc bảo trì phản ứng (reactive maintenance) thường không đảm bảo hiệu quả tối ưu, do không phản ánh chính xác trạng thái suy giảm thực tế của thiết bị [1].

Trong những năm gần đây, bảo trì dự đoán (Predictive Maintenance - PdM) đã trở thành một hướng tiếp cận tiên tiến, tận dụng dữ liệu cảm biến và các mô hình học máy để dự báo tình trạng thiết bị và RUL. PdM đã được ứng dụng rộng rãi trong nhiều lĩnh

vực công nghiệp, bao gồm cả lĩnh vực hàng hải, với mục tiêu giảm thời gian dừng máy, tối ưu hóa chi phí bảo trì và nâng cao độ tin cậy vận hành [2], [3]. Tuy nhiên, đặc thù của môi trường hàng hải với điều kiện vận hành biến động và dữ liệu thu thập không đồng nhất đặt ra nhiều thách thức cho việc xây dựng các mô hình dự báo chính xác.

Dự đoán RUL là một trong những bài toán cốt lõi của PdM. Các phương pháp truyền thống dựa trên mô hình vật lý hoặc thống kê thường yêu cầu hiểu biết sâu về cơ chế hư hỏng và khó áp dụng cho các hệ thống phức tạp [4]. Sự phát triển của học máy và học sâu đã mở ra nhiều hướng tiếp cận hiệu quả hơn. Các mô hình như Artificial Neural Networks (ANN), Support Vector Machines (SVM) và Random Forest đã được áp dụng trong giai đoạn đầu, trong khi các mô hình học sâu như Convolutional Neural Networks (CNN), LSTM và Transformer ngày càng được sử dụng phổ biến nhờ khả năng khai thác đặc trưng phi tuyến và phụ thuộc theo thời gian trong dữ liệu chuỗi [5], [6]. Trong đó, LSTM được đánh giá là đặc biệt phù hợp cho bài toán dự đoán RUL do khả năng ghi nhớ dài hạn và xử lý chuỗi thời gian hiệu quả [7].

Tuy nhiên, một trong những thách thức lớn nhất trong PdM là sự thiếu hụt dữ liệu hỏng hóc trong thực tế. Đối với các hệ thống có độ tin cậy cao như thiết bị hàng hải, sự cố xảy ra không thường xuyên, dẫn đến dữ liệu bị mất cân bằng và không đủ để huấn luyện các mô hình học sâu một cách hiệu quả [8]. Việc thu thập dữ liệu hỏng hóc thực tế không chỉ tốn kém mà còn tiềm ẩn rủi ro vận hành. Các phương pháp tăng cường dữ liệu truyền thống thường không đủ khả năng tái hiện đầy đủ đặc tính phức tạp của dữ liệu cảm biến [9].

Trong bối cảnh đó, trí tuệ nhân tạo tạo sinh (Generative AI) nổi lên như một hướng tiếp cận đầy tiềm năng để giải quyết vấn đề thiếu dữ liệu. Các mô hình tạo sinh có khả năng học phân bố xác suất của dữ liệu gốc và sinh ra các mẫu dữ liệu mới có đặc tính tương tự. Hai phương pháp phổ biến là Generative Adversarial Network (GAN) [10] và VAE [11]. Trong đó, GAN có khả năng tạo dữ liệu có tính chân thực cao thông qua cơ chế đối kháng, trong khi VAE cung cấp một khung học ổn định hơn dựa trên không gian tiềm ẩn.

Generative AI đã được áp dụng trong nhiều lĩnh vực như y sinh, công nghiệp và xử lý tín hiệu, cho thấy khả năng cải thiện hiệu suất của các mô hình học máy trong điều kiện dữ liệu hạn chế [12], [13]. Một số nghiên cứu gần đây đã bước đầu khai thác Generative AI trong bài toán bảo trì dự đoán và dự đoán RUL [14]. Tuy nhiên, các nghiên cứu tập trung vào lĩnh vực hàng

hải còn tương đối hạn chế, và việc đánh giá một cách hệ thống ảnh hưởng của dữ liệu sinh đến hiệu suất dự báo vẫn chưa được làm rõ đầy đủ.


Xuất phát từ những vấn đề nêu trên, bài báo này đề xuất một phương pháp tích hợp Generative AI vào bài toán dự đoán tuổi thọ còn lại của thiết bị hàng hải. Cụ thể, mô hình VAE được sử dụng để sinh dữ liệu cảm biến tổng hợp nhằm tăng cường tập dữ liệu huấn luyện, trong khi mô hình LSTM được áp dụng để dự đoán RUL. Phương pháp đề xuất được kiểm chứng trên bộ dữ liệu chuẩn NASA CMAPSS [15], cho phép đánh giá khách quan hiệu quả của việc sử dụng dữ liệu sinh trong cải thiện độ chính xác dự báo.

Đóng góp chính của bài báo bao gồm: (i) đề xuất một khung phương pháp tích hợp Generative AI trong bài toán dự đoán RUL; (ii) đánh giá định lượng tác động của dữ liệu sinh đến hiệu suất của mô hình học sâu; và (iii) phân tích tiềm năng ứng dụng của phương pháp trong các hệ thống thiết bị hàng hải thực tế.

2. Phương pháp nghiên cứu

2.1. Tổng quan phương pháp đề xuất

Phương pháp đề xuất trong nghiên cứu này nhằm cải thiện độ chính xác dự đoán RUL thông qua việc tích hợp mô hình tạo sinh dữ liệu và mô hình học sâu. Khung phương pháp bao gồm ba thành phần chính: (i) tiền xử lý dữ liệu cảm biến, (ii) sinh dữ liệu tổng hợp bằng mô hình Generative AI, và (iii) dự đoán RUL bằng mô hình học sâu. Cấu trúc mô hình đề xuất được thể hiện trong Hình 1.



Hình 1. Khung dự báo RUL cho thiết bị hàng hải

Từ Hình 1, luồng logic của cấu trúc bao gồm:

- + Thu thập dữ liệu cảm biến đa kênh;
- + Chuẩn hóa và cắt theo cửa sổ trượt;
- + Đưa chuỗi đã xử lý vào VAE;
- + VAE học phân phối dữ liệu và sinh dữ liệu tổng hợp;
- + Kết hợp dữ liệu thật và dữ liệu sinh thêm;
- + Dùng tập dữ liệu mở rộng để huấn luyện LSTM;
- + LSTM dự đoán RUL;
- + Đánh giá bằng RMSE, MAE.

Giả sử tập dữ liệu gốc được ký hiệu là:

$$\mathcal{D} = \{(X_i, y_i)\}_{i=1}^N \quad (1)$$

Trong đó X_i là chuỗi dữ liệu cảm biến, y_i là giá trị RUL tương ứng.

Mục tiêu của nghiên cứu là xây dựng một hàm dự đoán:

$$f_\theta: X \rightarrow \hat{y} \quad (2)$$

sao cho sai số giữa $\hat{y}$ và y được tối thiểu hóa.

2.2. Tiền xử lý dữ liệu

Dữ liệu cảm biến được chuẩn hóa nhằm đảm bảo tính ổn định trong quá trình huấn luyện. Phép chuẩn hóa Min-Max được áp dụng như công thức (3):

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (3)$$

Tiếp theo, dữ liệu được chuyển đổi thành các chuỗi con (sliding window):

$$X_i = \{x_t, x_{t+1}, \dots, x_{t+L}\} \quad (4)$$

Trong đó L là độ dài của sổ thời gian.

2.3. Mô hình tạo sinh dữ liệu

Để tăng cường dữ liệu, nghiên cứu sử dụng mô hình VAE. VAE học ánh xạ từ không gian dữ liệu đầu vào sang không gian tiềm ẩn (latent space), sau đó sinh lại dữ liệu từ không gian này.

Trong mô hình VAE, encoder có nhiệm vụ ánh xạ dữ liệu đầu vào X sang không gian tiềm ẩn (latent space) dưới dạng một phân bố xác suất. Thay vì biểu diễn dữ liệu bằng một vector cố định, encoder học các tham số của phân bố Gaussian, bao gồm trung bình $\mu(X)$ và phương sai $\sigma^2(X)$. Cụ thể, phân bố xác suất có điều kiện của biến tiềm ẩn z được mô tả như sau:

$$q_\phi(z|X) = \mathcal{N}(\mu(X), \sigma^2(X)) \quad (5)$$

Trong đó: $\mu(X)$ là vector trung bình do encoder học được; $\sigma^2(X)$ là vector phương sai; ϕ là tập tham số của mạng encoder.

Trong mô hình VAE, decoder có nhiệm vụ tái tạo dữ liệu đầu vào từ biến tiềm ẩn z . Cụ thể, decoder học ánh xạ ngược từ không gian tiềm ẩn về không gian dữ liệu gốc, nhằm khôi phục lại đặc trưng của dữ liệu cảm biến ban đầu. Quá trình này được mô hình hóa thông qua phân bố xác suất có điều kiện:

$$p_\theta(X|z) \quad (6)$$

Trong đó: z là biến tiềm ẩn được lấy mẫu từ phân bố Gaussian; θ là tập tham số của mạng decoder.

Trong mô hình VAE, mục tiêu là tối đa hóa xác suất biên (marginal likelihood) của dữ liệu quan sát:

$$\log p_\theta(X) = \log \int p_\theta(X|z)p(z) dz \quad (7)$$

Tuy nhiên, tích phân này thường không thể tính trực tiếp do không gian tiềm ẩn có chiều cao. Do đó, một phân bố xấp xỉ $q_\phi(z|X)$ được sử dụng để suy diễn dưới dạng Evidence Lower Bound (ELBO).

Bằng cách áp dụng bất đẳng thức Jensen, ta thu được:

$$\log p_\theta(X) \geq E_{q_\phi(z|X)}[\log p_\theta(X|z)] - D_{KL}(q_\phi(z|X)|p(z)) \quad (8)$$

Vế phải của bất đẳng thức trên được gọi là ELBO [11]:

$$\mathcal{L}_{ELBO} = E_{q_\phi(z|X)}[\log p_\theta(X|z)] - D_{KL}(q_\phi(z|X)|p(z)) \quad (9)$$

Trong đó: $E_{q_\phi(z|X)}[\log p_\theta(X|z)]$ là

reconstruction term, đo lường khả năng tái tạo dữ liệu của decoder; $D_{KL}(q_\phi(z|X)|p(z))$ là Kullback-Leibler divergence, đảm bảo phân bố tiềm ẩn gần với phân bố chuẩn $p(z) = \mathcal{N}(0, I)$.

Trong bài toán này, việc tối ưu ELBO giúp mô hình VAE học được phân bố tiềm ẩn của dữ liệu cảm biến một cách hiệu quả, từ đó có thể sinh ra các mẫu dữ liệu tổng hợp có tính đa dạng và gần với phân bố thực. Điều này đóng vai trò quan trọng trong việc tăng cường dữ liệu huấn luyện cho mô hình dự đoán RUL, đặc biệt trong điều kiện dữ liệu hỏng hóc hạn chế.

Sau khi huấn luyện, dữ liệu tổng hợp được sinh bằng cách lấy mẫu. Cụ thể, biến tiềm ẩn z được lấy mẫu từ phân bố Gaussian chuẩn:

$$z \sim \mathcal{N}(0, I) \quad (10)$$

Sau đó, dữ liệu tổng hợp được tạo ra thông qua hàm giải mã:

$$\tilde{X} = f_\theta(z) \quad (11)$$

Trong đó: z là vector trong không gian tiềm ẩn; $f_\theta(\cdot)$ là mạng decoder đã được huấn luyện; $\tilde{X}$ là dữ liệu cảm biến tổng hợp; Tập dữ liệu sinh ra được ký hiệu là:

$$\tilde{\mathcal{D}} = \{\tilde{X}_i\}_{i=1}^M \quad (12)$$

Tập dữ liệu huấn luyện mở rộng được xây dựng bằng cách kết hợp dữ liệu gốc và dữ liệu sinh:

$$\mathcal{D}' = \mathcal{D} \cup \tilde{\mathcal{D}} \quad (13)$$

Quá trình sinh dữ liệu tổng hợp đóng vai trò quan trọng trong việc mở rộng tập dữ liệu huấn luyện, giúp mô hình học sâu cải thiện khả năng tổng quát hóa, đặc biệt trong các bài toán có dữ liệu hỏng hóc hạn chế như trong hệ thống thiết bị hàng hải.

2.4. Mô hình dự đoán RUL

Để dự đoán RUL, nghiên cứu sử dụng mạng LSTM [7] nhằm khai thác đặc trưng chuỗi thời gian. Tại mỗi bước thời gian t , các trạng thái được cập nhật như sau:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (14)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (15)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (16)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (17)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (18)$$

$$h_t = o_t \odot \tanh(c_t) \quad (19)$$

$$\hat{y} = W_h h_T + b_h \quad (20)$$

Trong đó: h_t : Trạng thái ẩn tại thời điểm t ; c_t : Trạng thái bộ nhớ; $\sigma(\cdot)$: Hàm sigmoid; $\odot$: Phép nhân từng phần tử.

Sau khi xử lý toàn bộ chuỗi đầu vào, trạng thái ẩn cuối cùng h_T được sử dụng để dự đoán giá trị RUL:

$$\hat{y} = W_h h_T + b_h \quad (21)$$

Trong đó: $\hat{y}$: Là giá trị RUL dự đoán; W_h, b_h : Là tham số của lớp fully-connected.

Mô hình LSTM cho phép khai thác hiệu quả các đặc trưng phụ thuộc theo thời gian trong dữ liệu cảm biến, đặc biệt là các xu hướng suy giảm của thiết bị. Nhờ cơ chế ghi nhớ dài hạn, LSTM có khả năng học được các mẫu suy giảm phức tạp mà các mô hình truyền thống khó nắm bắt.

Trong nghiên cứu này, LSTM được huấn luyện trên tập dữ liệu mở rộng $\mathcal{D}'$, bao gồm cả dữ liệu gốc và dữ liệu tổng hợp được sinh ra từ mô hình VAE. Việc kết hợp này giúp cải thiện khả năng tổng quát hóa của mô hình, từ đó nâng cao độ chính xác dự đoán RUL trong các điều kiện dữ liệu hạn chế.

2.5. Quy trình huấn luyện tổng thể

Quy trình huấn luyện tổng thể của phương pháp đề xuất bao gồm ba giai đoạn chính:

- + Huấn luyện mô hình tạo sinh dữ liệu (VAE) và,
- + Sinh dữ liệu tổng hợp và,
- + Huấn luyện mô hình LSTM.

Quy trình này nhằm tận dụng khả năng sinh dữ liệu của VAE để cải thiện hiệu suất của mô hình dự đoán.

Giai đoạn 1: Huấn luyện mô hình VAE

Mô hình VAE được huấn luyện trên tập dữ liệu gốc $\mathcal{D}$ nhằm học phân bố xác suất của dữ liệu cảm biến. Quá trình tối ưu được thực hiện bằng cách cực tiểu hóa

hàm mất mát ELBO (22):

$$\mathcal{L}_{VAE} = E_{q_\phi(z|X)}[\log p_\theta(X|z)] - D_{KL}(q_\phi(z|X) || p(z)) \quad (22)$$

Sau khi huấn luyện, encoder và decoder có khả năng ánh xạ dữ liệu vào không gian tiềm ẩn và tái tạo dữ liệu tương ứng.

Giai đoạn 2: Sinh dữ liệu tổng hợp


Dữ liệu tổng hợp được tạo ra bằng cách lấy mẫu từ phân bố chuẩn $z \sim \mathcal{N}(0, I)$ và đưa qua decoder $\tilde{X} = f_\theta(z)$. Tiếp theo, xây dựng tập dữ liệu mở rộng $\mathcal{D}' = \mathcal{D} \cup \tilde{\mathcal{D}}$.

Giai đoạn 3: Huấn luyện mô hình LSTM

Mô hình LSTM được huấn luyện trên tập dữ liệu mở rộng $\mathcal{D}'$ để học ánh xạ từ dữ liệu cảm biến sang giá trị RUL. Hàm mất mát được sử dụng là Mean Squared Error:

$$\mathcal{L}_{RUL} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

Thuật toán tổng thể của quy trình huấn luyện có thể được mô tả bằng sơ đồ thuật toán như Hình 2.



Hình 2. Quy trình huấn luyện dự đoán RUL sử dụng VAE-LSTM

3. Thí nghiệm và kết quả

3.1. Bộ dữ liệu và thiết lập thí nghiệm

Để đánh giá hiệu quả của phương pháp đề xuất, nghiên cứu sử dụng bộ dữ liệu chuẩn NASA CMAPSS, một benchmark phổ biến trong bài toán dự đoán RUL. Mặc dù nghiên cứu hướng tới ứng dụng cho thiết bị hàng hải, bộ dữ liệu kiểm chứng được sử dụng là NASA CMAPSS - một benchmark phổ biến trong bài toán dự đoán RUL. Việc lựa chọn này dựa trên hai cơ sở chính.

Thứ nhất, CMAPSS cung cấp các chuỗi tín hiệu cảm biến đa biến phản ánh quá trình suy giảm của hệ thống theo thời gian, đặc điểm vốn cũng tồn tại ở nhiều thiết bị hàng hải như động cơ diesel, máy bơm và máy nén. Do đó, về mặt bản chất, bài toán dự đoán RUL được tiếp cận dưới góc độ khai thác đặc trưng suy giảm trong dữ liệu chuỗi thời gian, thay vì phụ thuộc vào loại thiết bị cụ thể.

Thứ hai, CMAPSS là bộ dữ liệu chuẩn được sử dụng rộng rãi trong cộng đồng nghiên cứu, cho phép đảm bảo tính khách quan và khả năng so sánh với các phương pháp hiện có. Điều này đặc biệt quan trọng khi đánh giá tác động của kỹ thuật tăng cường dữ liệu dựa trên Generative AI.

Tuy nhiên, cần thừa nhận sự khác biệt giữa dữ liệu mô phỏng và dữ liệu thực tế hàng hải. Do đó, kết quả nghiên cứu nên được xem là bằng chứng ban đầu, và việc kiểm chứng trên dữ liệu thực tế là hướng nghiên cứu cần thiết trong tương lai. Bộ dữ liệu này bao gồm nhiều chuỗi vận hành của động cơ phản lực, với các thông số cảm biến được ghi nhận cho đến khi xảy ra hỏng hóc.

Nghiên cứu này sử dụng tập dữ liệu FD001 của NASA CMAPSS, bao gồm:

- + 100 chuỗi huấn luyện (train trajectories) với tổng số khoảng 20,631 chu kỳ vận hành;
- + 100 chuỗi kiểm tra (test trajectories) với khoảng 13,096 chu kỳ;
- + Mỗi chu kỳ bao gồm 21 tín hiệu cảm biến; 3 điều kiện vận hành;
- + Chuỗi thời gian từ trạng thái bình thường đến suy giảm.

Dữ liệu được chia thành:

- + Tập huấn luyện (train set);
- + Tập kiểm tra (test set);
- + Giá trị RUL được tính theo số chu kỳ còn lại trước khi thiết bị hỏng.

Mỗi trajectory là một chuỗi vận hành theo thời gian của một động cơ giả lập. Sau bước tiền xử lý bằng cửa sổ trượt, các trajectory này được chuyển đổi thành nhiều mẫu huấn luyện dạng chuỗi để đưa vào mô hình LSTM.

3.2. Thiết lập mô hình

- Mô hình VAE được thiết kế với cấu trúc:
 - + Encoder: 2 lớp fully-connected;
 - + Latent dimension: $z \in R^{16}$;
 - + Decoder: 2 lớp fully-connected.
- Hàm mất mát được tối ưu theo:

$$\mathcal{L}_{VAE} = \mathcal{L}_{rec} + \beta \cdot D_{KL}$$

Trong đó $\beta = 1$.

- Mô hình dự đoán RUL sử dụng LSTM với cấu trúc:

- + 2 lớp LSTM;
- + Số hidden units: 64;
- + Dropout: 0,2;
- + Fully-connected output layer.
- Hàm mất mát: Mean Squared Error (MSE).
- Tham số huấn luyện
 - + Epoch (Số vòng lặp huấn luyện): 100;
 - + Batch size (Kích thước lô dữ liệu): 6,4;
 - + Optimizer (thuật toán tối ưu): Adam;
 - + Learning rate (tốc độ học): 0,001.

Trong nghiên cứu này, thuật toán tối ưu Adam được lựa chọn do khả năng hội tụ nhanh và ổn định trong các bài toán học sâu. Giá trị learning rate được thiết lập ở mức 10^{-3} nhằm cân bằng giữa tốc độ hội tụ và khả năng tránh rơi vào cực tiểu cục bộ.

Batch size được chọn là 64 để đảm bảo sự cân bằng giữa hiệu quả tính toán và độ ổn định của gradient. Số epoch được đặt là 100 nhằm đảm bảo mô hình có đủ thời gian học các đặc trưng quan trọng từ dữ liệu huấn luyện mà không gây hiện tượng overfitting nghiêm trọng.

Các tham số này được lựa chọn dựa trên thực nghiệm và tham khảo từ các nghiên cứu trước đó trong lĩnh vực dự đoán RUL [2], [5], [14].

3.3. Thiết kế thí nghiệm

Để đánh giá tác động của dữ liệu sinh, nghiên cứu thực hiện hai kịch bản:

- Kịch bản 1: Baseline (mô hình cơ sở)
 - + Huấn luyện LSTM trên dữ liệu gốc $\mathcal{D}$.
- Kịch bản 2: Proposed method (mô hình đề xuất)
 - + Huấn luyện VAE,

- + Sinh dữ liệu $\tilde{D}$,
- + Tạo tập dữ liệu mở rộng $D' = D \cup \tilde{D}$,
- + Huấn luyện LSTM trên D' .

3.4. Chỉ số đánh giá

Hiệu suất mô hình được đánh giá bằng các chỉ số:

Sai số căn bậc hai trung bình (RMSE - Root Mean Squared Error):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

Sai số tuyệt đối trung bình (MAE):

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

Hàm đánh giá theo chuẩn NASA [15]:

$$Score = \sum_{i=1}^N \begin{cases} e^{-\frac{i}{13}} - 1, & e_i < 0 \\ e^{-\frac{i}{10}} - 1, & e_i \geq 0 \end{cases}$$

Trong đó $e_i = \hat{y}_i - y_i$.

Trong nghiên cứu này, RMSE và MAE được tính trên thang đo gốc của biến mục tiêu RUL, với đơn vị là chu kỳ vận hành. Do đó, giá trị RMSE không phải là một đại lượng không thứ nguyên trong khoảng $[0,1]$, mà phản ánh trực tiếp sai số dự báo trung bình theo số chu kỳ còn lại của thiết bị. Cụ thể, RMSE càng nhỏ thể hiện mô hình dự báo càng chính xác; tuy nhiên, độ lớn tuyệt đối của RMSE phụ thuộc vào miền giá trị của RUL trong bộ dữ liệu.

3.5. Kết quả thực nghiệm

Để đánh giá hiệu quả của phương pháp đề xuất, nghiên cứu tiến hành so sánh hiệu suất giữa mô hình cơ sở (baseline) và mô hình sử dụng dữ liệu sinh từ Generative AI. Các chỉ số đánh giá bao gồm RMSE và MAE. Kết quả so sánh được trình bày trong Bảng 1.

Bảng 1. So sánh hiệu suất mô hình

Phương pháp	RMSE	MAE
LSTM (baseline)	24.85	18.42
STM + VAE (Đề xuất)	20.31	15.76


Kết quả cho thấy mô hình đề xuất đạt hiệu suất vượt trội so với mô hình cơ sở. Cụ thể, giá trị RMSE giảm từ 24,85 xuống 20,31, tương ứng với mức cải thiện khoảng 18,3%. Đồng thời, MAE cũng giảm từ 18,42 xuống 15,76, tương ứng với mức cải thiện khoảng 14,4%.

Sự cải thiện này cho thấy việc sử dụng dữ liệu sinh từ mô hình VAE giúp mở rộng phân bố dữ liệu huấn

luyện, từ đó hỗ trợ mô hình học sâu nắm bắt tốt hơn các đặc trưng suy giảm của thiết bị. Nhờ đó, mô hình dự đoán RUL có khả năng tổng quát hóa cao hơn và đưa ra kết quả chính xác hơn trên tập kiểm tra.

Ngoài ra, kết quả cũng cho thấy mô hình cơ sở có xu hướng sai lệch lớn hơn trong các giai đoạn suy giảm nhanh của thiết bị, trong khi mô hình đề xuất duy trì được độ ổn định và độ chính xác cao hơn. Điều này đặc biệt quan trọng trong các ứng dụng bảo trì dự đoán, nơi mà sai số dự báo có thể ảnh hưởng trực tiếp đến quyết định bảo trì và chi phí vận hành.

Hình 3 minh họa kết quả dự đoán của mô hình cơ sở (LSTM) và mô hình đề xuất (LSTM kết hợp dữ liệu sinh từ VAE) đối với một số mẫu đại diện. Kết quả cho thấy mô hình cơ sở có xu hướng sai lệch đáng kể tại các giai đoạn cuối của vòng đời thiết bị, đặc biệt trong vùng suy giảm nhanh.




Hình 3. Kết quả dự báo RUL

Cụ thể, mô hình cơ sở (baseline) thường đánh giá thấp giá trị RUL khi thiết bị tiến gần đến trạng thái hỏng, dẫn đến sai số lớn trong dự báo. Nguyên nhân chủ yếu là do dữ liệu huấn luyện không đủ đa dạng để phản ánh đầy đủ các trạng thái suy giảm phi tuyến của hệ thống. Ngược lại, mô hình đề xuất thể hiện khả năng bám sát đường cong thực tế tốt hơn trên toàn bộ chuỗi thời gian. Nhờ việc bổ sung dữ liệu sinh, mô hình có thể học được nhiều trạng thái suy giảm khác nhau, từ đó cải thiện khả năng dự đoán trong các vùng dữ liệu khan hiếm. Đặc biệt, tại các thời điểm cuối vòng đời, sai số dự đoán được giảm rõ rệt, cho thấy hiệu quả của phương pháp tăng cường dữ liệu.

Ngoài ra, phân tích phân bố sai số cho thấy mô hình đề xuất có độ phân tán sai số nhỏ hơn so với mô hình cơ sở, thể hiện qua việc các điểm dự đoán tập trung gần đường chéo lý tưởng $y = \hat{y}$. Điều này chứng tỏ mô hình không chỉ cải thiện độ chính xác trung bình mà còn nâng cao tính ổn định của dự báo.

Để đánh giá ảnh hưởng của dữ liệu sinh, các thí nghiệm được thực hiện với các tỷ lệ tăng cường khác

nhau (0%, 50%, 100%, 150% và 200%). Kết quả được thể hiện trên Hình 4.



Hình 4. Phân tích độ nhạy theo tỷ lệ tăng cường dữ liệu

Hình 4 thể hiện mối quan hệ giữa tỷ lệ tăng cường dữ liệu (%) và ba chỉ số đánh giá sai số quan trọng: RMSE, MAE (trục trái) và NASA Score (trục phải).

Giai đoạn cải thiện mạnh (0% - 100%): Khi bắt đầu thêm dữ liệu từ GAN/VAE, cả ba chỉ số đều giảm mạnh. Điều này chứng tỏ dữ liệu tổng hợp đã giúp mô hình học được các đặc trưng (features) mà dữ liệu thực tế còn thiếu hoặc bị thừa thớt, giúp giảm hiện tượng thiếu thông tin.

Điểm cực tiểu (150%): Đây là "điểm ngọt" (sweet spot), nơi tất cả các đường đồ thị đạt giá trị thấp nhất. Tại đây, mô hình đạt độ chính xác tối ưu.

Giai đoạn bão hòa và suy giảm (Sau 150%): Khi tăng tỷ lệ lên 200%, các chỉ số bắt đầu có xu hướng đi lên (sai số tăng). Đây là hiện tượng điển hình khi dữ liệu giả lập chiếm tỷ trọng quá lớn, có thể gây nhiễu hoặc khiến mô hình bị "lệch" (distribution shift) so với phân phối thực tế.

+ RMSE: Giá trị bắt đầu ở mức khá cao (~24,8) khi không có tăng cường dữ liệu (0%). Sau đó, chỉ số này giảm mạnh và đạt điểm tối ưu tại mức 150% với giá trị khoảng 20,0. Sự sụt giảm khoảng 19% này cho thấy dữ liệu tạo sinh giúp mô hình xử lý tốt hơn các sai số lớn (vì RMSE rất nhạy cảm với các giá trị ngoại lai - outliers).

+ MAE: Tương tự như RMSE, MAE giảm từ ~18,4 xuống mức thấp nhất là ~15,6 tại điểm 150%. Việc MAE giảm đều đặn cho thấy sai số trung bình trên toàn bộ tập dữ liệu đã được cải thiện một cách ổn định.

"Vùng tối ưu" (100% - 150%), trong Hình 4 là vùng có sự chênh lệch về sai số giữa các mức tăng cường là không quá lớn, cho thấy sự ổn định của thuật toán. Đồng thời NASA Score cũng có sự sụt giảm ấn tượng nhất, từ mức gần 245 xuống còn khoảng 175. Từ đó ta có thể nhận xét rằng NASA Score nhạy cảm

hơn RMSE/MAE (độ dốc của đường nét đứt lớn hơn). Nguyên nhân là do NASA Score phạt rất nặng các sai số dự báo trễ (late prediction) trong kỹ thuật hệ thống. Điều này cho thấy dữ liệu tăng cường đặc biệt hiệu quả trong việc giúp mô hình tránh các sai sót nguy hiểm trong dự báo kỹ thuật.

Kết quả thực nghiệm này khẳng định rằng việc tích hợp Generative AI vào quy trình huấn luyện giúp mô hình học sâu khai thác hiệu quả hơn thông tin từ dữ liệu cảm biến, đặc biệt trong các điều kiện dữ liệu hạn chế. Đây là một yếu tố quan trọng góp phần nâng cao hiệu quả của hệ thống bảo trì dự đoán trong các ứng dụng thực tế.

Trong nghiên cứu này, chất lượng của dữ liệu sinh từ mô hình VAE được đánh giá chủ yếu theo cách tiếp cận định hướng nhiệm vụ (task-oriented evaluation), thông qua tác động của dữ liệu sinh lên hiệu suất dự đoán RUL. Kết quả thực nghiệm cho thấy việc bổ sung dữ liệu tổng hợp giúp giảm đáng kể sai số dự báo (RMSE và MAE), qua đó gián tiếp phản ánh rằng dữ liệu sinh đã cung cấp thông tin hữu ích cho quá trình huấn luyện mô hình.

Tuy nhiên, cần thừa nhận rằng việc đánh giá chất lượng dữ liệu sinh chỉ dựa trên hiệu suất của mô hình dự đoán là chưa đủ để khẳng định mô hình VAE đã học đầy đủ phân bố thống kê của dữ liệu gốc. Các phương pháp đánh giá trực tiếp ở mức phân phối, như so sánh đặc trưng thống kê (mean, variance), đo độ tương đồng phân bố (Kullback-Leibler divergence, Wasserstein distance), hoặc trực quan hóa không gian đặc trưng (PCA, t-SNE), có thể cung cấp cái nhìn toàn diện hơn về mức độ phù hợp của dữ liệu sinh.

Trong phạm vi của nghiên cứu này, mục tiêu chính là đánh giá hiệu quả của tăng cường dữ liệu đối với bài toán dự đoán RUL, do đó các phân tích ở mức phân phối chưa được triển khai chi tiết. Tuy nhiên, do phương pháp đề xuất hoạt động ở cấp độ dữ liệu (data-level augmentation), việc kết hợp các tiêu chí đánh giá trực tiếp chất lượng dữ liệu sinh sẽ là hướng mở rộng quan trọng trong các nghiên cứu tiếp theo, nhằm đảm bảo tính tin cậy và khả năng ứng dụng thực tiễn của mô hình trong các hệ thống thiết bị hàng hải.

3.6. Ứng dụng trong thiết bị hàng hải

Phương pháp đề xuất trong nghiên cứu này có tiềm năng ứng dụng rộng rãi trong các hệ thống thiết bị trên tàu biển, nơi yêu cầu cao về độ tin cậy, tính liên tục và an toàn vận hành. Các thiết bị quan trọng như động cơ diesel tàu thủy, bơm, máy nén và máy phát điện đều là những hệ thống có đặc tính làm việc theo chuỗi thời

gian và chịu ảnh hưởng lớn từ điều kiện vận hành khắc nghiệt, do đó rất phù hợp để áp dụng các kỹ thuật bảo trì dự đoán dựa trên học máy.

Đối với động cơ diesel tàu thủy, đây là hệ thống trung tâm quyết định khả năng vận hành của tàu. Việc áp dụng mô hình dự đoán RUL cho phép giám sát trạng thái suy giảm của các thành phần quan trọng như piston, xy-lanh, hệ thống nhiên liệu và hệ thống bôi trơn. Nhờ đó, các hư hỏng tiềm ẩn có thể được phát hiện sớm trước khi xảy ra sự cố nghiêm trọng.

Trong các hệ thống bơm và máy nén vốn hoạt động liên tục trong các hệ thống phụ trợ như làm mát, cấp nhiên liệu hoặc khí nén, phương pháp đề xuất giúp theo dõi sự thay đổi của các tín hiệu rung, áp suất và lưu lượng. Điều này cho phép dự đoán chính xác thời điểm suy giảm hiệu suất hoặc hỏng hóc, từ đó lập kế hoạch bảo trì hợp lý.

Đối với máy phát điện, việc dự đoán tuổi thọ còn lại của các thành phần như cuộn dây, ổ trục và hệ thống làm mát đóng vai trò quan trọng trong việc đảm bảo cung cấp điện liên tục cho toàn bộ hệ thống tàu. Mô hình đề xuất có thể khai thác dữ liệu cảm biến để phát hiện các dấu hiệu bất thường và đưa ra cảnh báo sớm.

Việc tích hợp mô hình VAE-LSTM vào hệ thống giám sát thiết bị trên tàu mang lại nhiều lợi ích thiết thực. Trước hết, khả năng dự đoán chính xác RUL giúp giảm thời gian dừng máy (downtime) không mong muốn, từ đó nâng cao hiệu quả khai thác tàu. Thứ hai, phương pháp này hỗ trợ tối ưu hóa chiến lược bảo trì, chuyển từ bảo trì định kỳ sang bảo trì dự đoán, giúp giảm chi phí và nâng cao hiệu quả sử dụng nguồn lực. Cuối cùng, việc phát hiện sớm các hư hỏng tiềm ẩn góp phần tăng độ tin cậy (reliability) của hệ thống, đảm bảo an toàn cho con tàu và thuyền viên trong quá trình vận hành.

Tóm lại, phương pháp đề xuất không chỉ có giá trị về mặt học thuật mà còn có tiềm năng ứng dụng thực tiễn cao trong ngành hàng hải, đặc biệt trong bối cảnh chuyển đổi số và phát triển các hệ thống tàu thông minh (smart ships).

4. Kết luận

Trong nghiên cứu này, một phương pháp tích hợp trí tuệ nhân tạo tạo sinh (Generative AI) và mô hình học sâu đã được đề xuất nhằm cải thiện độ chính xác của bài toán dự đoán tuổi thọ còn lại RUL trong bảo trì dự đoán (Predictive Maintenance - PdM). Cụ thể, mô hình VAE được sử dụng để sinh dữ liệu tổng hợp nhằm khắc phục vấn đề thiếu hụt dữ liệu hỏng hóc, trong khi mô hình LSTM được áp dụng để khai thác

đặc trưng chuỗi thời gian và thực hiện dự đoán RUL.

Kết quả thực nghiệm trên bộ dữ liệu chuẩn NASA CMAPSS cho thấy phương pháp đề xuất giúp cải thiện đáng kể hiệu suất dự đoán so với các mô hình truyền thống. Việc sử dụng Generative AI đã góp phần làm phong phú tập dữ liệu huấn luyện, từ đó nâng cao khả năng tổng quát hóa của mô hình và giảm sai số dự đoán. Điều này khẳng định tiềm năng của các kỹ thuật tạo sinh trong việc giải quyết bài toán thiếu dữ liệu trong lĩnh vực bảo trì dự đoán.

Bên cạnh những kết quả đạt được, nghiên cứu cũng mở ra một số hướng phát triển trong tương lai. Trước hết, việc kết hợp mô hình dự đoán RUL với các hệ thống bản sao số - digital twin có thể giúp mô phỏng trạng thái thiết bị theo thời gian thực và nâng cao khả năng ra quyết định trong bảo trì. Thứ hai, cần tiến hành kiểm chứng phương pháp trên dữ liệu cảm biến thực tế từ tàu biển, nhằm đánh giá tính khả thi và độ tin cậy trong điều kiện vận hành thực. Cuối cùng, việc tích hợp các phương pháp học tăng cường (reinforcement learning) vào chiến lược bảo trì có thể giúp tối ưu hóa quyết định bảo trì theo thời gian, hướng tới các hệ thống bảo trì thông minh và tự thích ứng.

Tóm lại, nghiên cứu này không chỉ chứng minh hiệu quả của Generative AI trong việc cải thiện độ chính xác dự đoán RUL mà còn góp phần định hướng phát triển các hệ thống bảo trì thông minh trong ngành hàng hải trong tương lai.

Lời cảm ơn

Nghiên cứu này được tài trợ bởi Trường Đại học Hàng hải Việt Nam trong đề tài mã số: **DT25-26.33**.

TÀI LIỆU THAM KHẢO

- [1] Jardine, A. K., Lin, D., & Banjevic, D. (2006), *A review on machinery diagnostics and prognostics*, Mechanical Systems and Signal Processing, Vol.20(7).
- [2] Kouraichi, M., et al. (2025), *Deep learning for fault diagnosis in power transmission lines: Current trends, limitations, and future directions*, IEEE Access, Vol.13.
- [3] Mobley, R. K. (2002), *An introduction to predictive maintenance*, Elsevier.
- [4] Pecht, M. (2008), *Prognostics and health management of electronics*, Wiley.
- [5] LeCun, Y., Bengio, Y., & Hinton, G. (2015), *Deep learning*, Nature.
- [6] Krizhevsky, A., et al. (2017), *ImageNet*

- classification with deep convolutional neural networks*, Communications of the ACM, Vol.60(6).
- [7] Hochreiter, S., & Schmidhuber, J. (1997), *Long short-term memory*, Neural Computation.
- [8] Saxena, S., et al. (2008), *Damage propagation modeling for aircraft engine run-to-failure simulation*, NASA CMAPSS Dataset.
- [9] He, H., & Garcia, E. (2008), *ADASYN: Adaptive synthetic sampling approach for imbalanced learning*, IEEE Xplore.
- [10] Goodfellow, I., et al. (2014), *Generative adversarial nets*, NIPS'14: Proceedings of the 28th International Conference on Neural Information Processing Systems, Vol. 2.
- [11] Kingma, D. P., & Welling, M. (2014), *Auto-encoding variational Bayes*, 2nd International Conference on Learning Representations (ICLR2014).
- [12] Esteban, T., et al. (2017), *Real-valued time series generation with recurrent conditional GANs*, NeurIPS Workshop.
- [13] Wen, C., et al. (2017), *A new convolutional neural network based data-driven fault diagnosis method*, IEEE Transactions.
- [14] Jo, H. S., et al. (2026), *Deep learning-based RUL prediction with uncertainty quantification for photocouplers in reactor protection systems*, Nuclear Engineering and Technology, Vol.58(4).
- [15] NASA (2008), *C-MAPSS dataset*, Prognostics Data Repository.

Ngày nhận bài:	03/04/2026
Ngày nhận bản sửa:	23/04/2026
Ngày duyệt đăng:	09/05/2026