

ĐÁNH GIÁ TÌNH TRẠNG VÀ DỰ BÁO TUỔI THỌ HỮU ÍCH CÒN LẠI CỦA BỘ TRAO ĐỔI NHIỆT DẠNG TẤM THÔNG QUA DỰ BÁO NGẮN HẠN GIÁ TRỊ CHÈNH ÁP DÒNG NƯỚC BIỂN

Trần Ngọc Trung, Nguyễn Thành Trung, Nguyễn Duy Minh, Đào Quang Khoa, Trần Vũ Tùng, Trần Đức Thắng

Công ty Điều hành Dầu khí Biển Đông

Email: trungtn@biendongpoc.vn

<https://doi.org/10.47800/PVSI.2024.01-09>

Tóm tắt

Bảo trì tiên đoán giúp tối đa hóa thời gian vận hành của thiết bị thông qua việc ước tính tuổi thọ hữu ích của thiết bị hay thời điểm có thể xảy ra hỏng hóc. Nhóm tác giả đã thực hiện dự báo ngắn hạn giá trị chênh áp dòng nước biển tại bộ trao đổi nhiệt dạng tấm bằng mạng bộ nhớ dài - ngắn hạn (long short-term memory, LSTM) và qua đó dự báo tuổi thọ hữu ích còn lại (remaining useful life, RUL) bằng mô hình hồi quy phi tuyến (nonlinear regression). Mô hình đề xuất đã đạt được độ chính xác cao bằng cách liên tục phát hiện các điểm lưu (checkpoint) và dự báo giá trị RUL liên tục mỗi 24 giờ. Các điểm lưu được phát hiện thông qua phát hiện giá trị chênh áp bất thường tại bộ trao đổi nhiệt dạng tấm trong quá trình hoạt động. Qua đó giúp cập nhật giá trị tuổi thọ hữu ích còn lại ngay khi có các biến động không lường trước được trong quá trình vận hành thiết bị.

Từ khóa: Tuổi thọ hữu ích còn lại, bộ trao đổi nhiệt dạng tấm.

1. Giới thiệu

Bộ trao đổi nhiệt dạng tấm (plate type heat exchanger) là thiết bị trao đổi nhiệt sử dụng các tấm kim loại để truyền nhiệt giữa 2 chất lỏng. Chất lỏng tiếp xúc với diện tích bề mặt lớn hơn nhiều so với các thiết bị trao đổi nhiệt thông thường vì được trải rộng trên các tấm, giúp tăng đáng kể tốc độ trao đổi nhiệt.

Nhóm tác giả đặt ra 2 nhiệm vụ bao gồm đánh giá tình trạng của bộ trao đổi nhiệt dạng tấm thông qua dự báo ngắn hạn giá trị chênh áp dòng nước biển và dự báo tuổi thọ hữu ích còn lại. Việc dự báo dài hạn tạo điều kiện xây dựng kế hoạch, phân phối và điều động nhân công phù hợp nhằm đảm bảo luôn biết trước thời điểm xảy ra sự cố. Tuy nhiên, trong quá trình hoạt động của thiết bị, nhiều yếu tố bất ngờ xảy ra có thể gây sai số lớn cho giá trị dự báo dài hạn. Vì vậy, nhiệm vụ dự báo ngắn hạn đóng vai trò bổ trợ giúp đảm bảo tính chính xác của mô hình dự báo dài hạn và tạo điều kiện cho nhân sự vận hành chủ động cập nhật tình trạng của thiết bị. Bộ dữ liệu thiết bị

trao đổi nhiệt dạng tấm chứa dữ liệu thô về thông số vận hành của bộ trao đổi nhiệt dạng tấm chưa phân chu kỳ cho năm 2020 và 2021, với các thuộc tính như nhiệt độ cửa vào/ra dòng nước biển, cảm biến nhiệt độ cửa ra dòng nước làm mát máy nén, cảm biến lưu lượng cửa vào dòng nước biển, cảm biến chênh áp cửa vào/ra dòng nước biển với tần suất lấy mẫu 1 lần/giờ.

Nghiên cứu của Chen đề xuất khung học sâu dự báo RUL của thiết bị tiến hành trên 2 bộ dữ liệu thực [1]. Mô hình mạng bộ nhớ dài - ngắn hạn (long short-term memory, LSTM) được sử dụng để tìm hiểu các tính năng tuần tự từ dữ liệu thô kết hợp đánh giá tầm quan trọng của các đặc trưng nhằm tối ưu quá trình gán trọng số.

Zuozhou Pan nghiên cứu phương pháp dự báo 2 giai đoạn dựa trên học máy để dự báo nhanh thời gian sử dụng hữu ích còn lại của ổ trục [2]. Phương pháp này sử dụng giá trị bình phương căn bậc 2 tương đối (relative root mean square, RRMS) để chia giai đoạn hoạt động của ổ trục thành 2 giai đoạn: hoạt động bình thường và xuống cấp. Trong giai đoạn hoạt động bình thường, mô hình học máy dự báo đơn biến (univariate prediction) được xây dựng để dự báo ngắn hạn theo thời gian thực về xu hướng xuống cấp của ổ trục. Khi giá trị dự báo cho thấy



Ngày nhận bài: 1/8/2024. Ngày phân biên đánh giá và sửa chữa: 15/8 - 15/9/2023.

Ngày bài báo được duyệt đăng: 27/12/2023.

vòng bi đã bước vào giai đoạn xuống cấp, các đặc trưng sẽ được chọn làm đầu vào bằng cách phân tích tương quan. Mô hình học máy đa biến được xây dựng để dự báo thời gian sử dụng hữu ích còn lại. Kết quả thực nghiệm cho thấy phương pháp đề xuất có độ chính xác dự báo ngắn hạn cao hơn và tốc độ hoạt động nhanh hơn trong trường hợp kích thước mẫu học tập có hạn. Tương tự, J. Deutsch giới thiệu cách tiếp cận dựa trên học sâu để dự báo RUL về các thành phần luân phiên với dữ liệu lớn. Phương pháp được kiểm nghiệm bằng cách sử dụng dữ liệu thu thập từ thử nghiệm phá hủy (run to error) bánh răng và ổ trục [3]. Kết quả thử nghiệm cho thấy hiệu suất dự báo RUL của phương pháp tiếp cận dựa trên học sâu.

James Carroll đề xuất phương án dự báo hỏng hóc và thời gian sử dụng hữu ích còn lại của hộp số cho turbine gió [4]. Sự cố và RUL được dự báo thông qua việc sử dụng các kỹ thuật học máy cho bộ dữ liệu giám sát turbine gió và dữ liệu dao động. Dữ liệu được sử dụng để dự báo sự cố có thể lên đến 1 tháng trước thời điểm xảy ra và dữ liệu rung động tần số cao được sử dụng để mở rộng khả năng dự báo chính xác có thể lên tới 5 - 6 tháng trước khi xảy ra sự cố. Các mạng thần kinh 2 lớp có thể dự báo chính xác lỗi hộp số từ 72,5 - 75% tùy vào chế độ hỏng hóc khi được huấn luyện với dữ liệu SCADA và 100% khi được huấn luyện với dữ liệu rung.

Kết quả của các nghiên cứu trên cho thấy có rất nhiều phương pháp để dự báo giá trị RUL tùy theo các bộ dữ liệu, trong đó nổi bật nhất là mô hình LSTM và các biến thể của mô hình này. Ngược lại, thuật toán hồi quy phi tuyến (nonlinear regression) ít được sử dụng, thường chỉ ứng dụng cho các nghiên cứu về tính toán giá trị RUL cho pin, với bộ số liệu có xu hướng thay đổi theo thời gian khá giống với bộ dữ liệu của bộ trao đổi nhiệt dạng tấm. Vì vậy, nhóm tác giả đã thống kê các nghiên cứu về RUL được công bố trong giai đoạn 2019 - 2023 như trong Bảng 1.

Dựa trên thống kê, có thể thấy từ năm 2019 - 2023, việc sử dụng các thuật toán LSTM năm 2023 chiếm tới 6,8% trong các nghiên cứu về RUL. Trong khi đó, thuật

toán hồi quy phi tuyến là một thuật toán ít được sử dụng khi chiếm chưa tới 1%. Đồng thời việc sử dụng kết hợp giữa thuật toán LSTM và thuật toán hồi quy phi tuyến trong việc nghiên cứu dự báo giá trị RUL gần như chưa có. Vì vậy nhóm tác giả đã đánh giá tính khả thi khi sử dụng kết hợp giữa 2 thuật toán thông qua một số nghiên cứu nổi bật.

Nghiên cứu của Yongmeng Zhu đề xuất sự kết hợp thông qua bộ read-first-LSTM (RLSTM) mã hóa (encoder) - giải mã (decoder) và broad learning system (BLS) để giám sát sự xuống cấp của ổ đỡ và ước tính tuổi thọ hữu ích còn lại nhằm mô tả các đặc tính phi tuyến của quá trình xuống cấp [5]. Kết quả sự kết hợp cho thấy dự báo có độ chính xác cao hơn 18% so với các phương pháp trong các nghiên cứu tương tự.

Xiaoyu Li đưa ra nghiên cứu ước tính trạng thái tình trạng ngắn hạn và dự báo giá trị của pin lithium dựa trên một multi-time-scale framework [6]. Phương pháp sẽ trích xuất 4 đặc trưng quan trọng thông qua phân tích chuyên sâu về dung lượng gia tăng từng phần và mô hình hồi quy tuyến tính quy trình Gaussian (Gaussian process regression) được áp dụng để dự báo điều kiện tình trạng của pin. Khả năng dự báo, sự chắc chắn và hiệu quả của phương pháp được đề xuất kiểm chứng bằng cách sử dụng 4 tập dữ liệu với các điều kiện thử nghiệm chu kỳ khác nhau và các mức độ tình trạng khác nhau. Kết quả cho thấy phương pháp trên có thể cung cấp dự báo chính xác.

Nghiên cứu của Venkat P. Nemani cũng đưa ra phương pháp dự báo RUL cho ổ đỡ bằng cách dự báo bằng mô hình 2 giai đoạn LSTM [7]. Ngoài ra, còn áp dụng ISO 10816 để xác định ngưỡng hỏng của ổ đỡ thông qua tần số lỗi đặc trưng trong miền vận tốc. Mỗi mô hình LSTM đều gồm 1 lớp Gaussian để xác định độ không đảm bảo "aleatoric" của các thông số dự báo. Sau đó, kết hợp chúng để xác định độ không đảm bảo "epistemic" trong việc dự báo giá trị RUL. Khi triển khai mô hình được đề xuất trên tập dữ liệu được công khai của Đại học Xi'an Jiaotong và Changxing Sumyoung Technology, kết quả cho thấy tính vượt trội của mô hình cả về độ chính xác cũng như tính

Bảng 1. Thống kê các nghiên cứu về RUL

Năm	Số lượng các nghiên cứu		
	Nghiên cứu về RUL	Nghiên cứu về RUL dựa trên LSTM	Nghiên cứu về RUL dựa trên hồi quy phi tuyến
2019	526	10	2
2020	690	30	4
2021	821	42	5
2022	1031	68	9
2023	875	60	4

toán độ không đảm bảo khi so sánh với các mô hình khác trong lĩnh vực tiên lượng RUL cho ổ đỡ.

Như vậy, sử dụng việc phân đoạn dự báo là phương pháp khả thi cũng như việc kết hợp giữa 2 mô hình LSTM và hồi quy phi tuyến có thể cho ra kết quả dự báo RUL phù hợp với bộ trao đổi nhiệt dạng tấm.

2. Giới thiệu thuật toán

2.1. Tổng quan

Xuất phát từ việc đánh giá tình trạng thiết bị bằng phương pháp sử dụng một số cảm biến đặc trưng giám sát - cụ thể ở đây dùng cảm biến chênh áp, thu được dữ liệu có xu hướng thay đổi theo thời gian. Đối với trường hợp này có thể đề xuất phương pháp hồi quy tuyến tính (linear regression), hồi quy phi tuyến hoặc hồi quy hàm mũ (exponential regression) để tìm giá trị RUL cho đến khi cảm biến chạm ngưỡng. Tuy nhiên, do các chế độ vận hành được thay đổi liên tục hoặc do có một số vấn đề phát sinh trong quá trình vận hành nên những dự báo RUL ban đầu của phương pháp trên sẽ không còn chính xác nữa. Trường hợp này được giải quyết bằng cách sử dụng mô hình LSTM, nếu sai số quá lớn so với xu hướng hiện tại sẽ đưa ra cảnh báo hoặc tiến hành chạy lại hồi quy tuyến tính.

2.2. Phương pháp hồi quy

2.2.1. Phương pháp hồi quy tuyến tính

Đối với các bài toán dự báo dài hạn cho chuỗi dữ liệu thời gian, 3 yếu tố sau thường được quan tâm:

- Độ chính xác: ảnh hưởng bởi tính chất và độ tương thích của giải thuật.
- Thời gian xử lý: ảnh hưởng bởi độ khó của giải thuật.
- Khả năng nội suy: ảnh hưởng bởi tính chất của giải thuật.

Mô hình hồi quy tuyến tính đáp ứng được yêu cầu về độ khó giải thuật, dễ dàng áp dụng với thời gian xử lý nhanh và khả năng nội suy vượt trội, tuy nhiên không thể hiện được các đoạn biến thiên có tính phi tuyến của dữ liệu và độ chính xác không cao đối với các dữ liệu có xu hướng phi tuyến. Các giải thuật học có giám sát như giải thuật rừng ngẫu nhiên (random forest), giải thuật extreme gradient boost (XGBoost) có độ chính xác cao đi kèm với độ khó giải thuật và thời gian xử lý tăng tiến nhiều. Ngoài ra, các giải thuật này không thể nội suy ngoài giới hạn tập đào tạo, khó có thể áp dụng với các chu kỳ dữ liệu không

ổn định về chiều dài như bộ dữ liệu của thiết bị trao đổi nhiệt dạng tấm.

Với các mô hình con được định nghĩa sẵn, kết hợp với khả năng hồi quy dựa trên hàm kết hợp thuận tiện cho quá trình nội suy, mô hình hồi quy phi tuyến sử dụng sai số trung bình bình phương gốc (root mean squared error, RMSE) đảm bảo cải thiện được độ chính xác với bộ dữ liệu của thiết bị trao đổi nhiệt dạng tấm so với mô hình hồi quy tuyến tính, đồng thời đảm bảo được khả năng nội suy và thời gian xử lý nhanh.

2.2.2. Mô hình hồi quy phi tuyến sử dụng sai số trung bình bình phương gốc

Kết tập hợp R gồm m phần tử có dạng $R = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ và mô hình có dạng $y = f(x, \beta)$ với x phụ thuộc vào β tham số. Vector β có dạng $\beta = \{\beta_1, \beta_2, \dots, \beta_n\}$ với $n \leq m$. Kết quả tối ưu khi tổng bình phương phần dư r_i là cực tiểu S được tính toán với công thức (1).

$$S = \sum_{i=1}^m r_i^2 \tag{1}$$

Trong đó mỗi giá trị phần dư được xác định bởi công thức sau:

$$r_i = y_i - f(x_i, \beta) \tag{2}$$

Tổng S đạt giá trị cực tiểu khi gradient bằng 0, nghĩa là tồn tại n phương trình gradient có dạng như phương trình (3).

$$\frac{\delta S}{\delta \beta_j} = 2 \times \sum_i \left(r_i \times \frac{\delta r_i}{\delta \beta_j} \right) \tag{3}$$

với $j = [1, n]$


Nghiệm của các phương trình gradient xác định vector β thỏa mãn điều kiện tối ưu nhằm xác định các hệ số của hàm hồi quy tương ứng với tập hợp dữ liệu đầu vào.

2.3. Mô hình mạng bộ nhớ dài - ngắn hạn (LSTM)

Mô hình đề xuất sử dụng mô hình LSTM là một dạng đặc biệt của mạng thần kinh hồi quy (recurrent neural network, RNN). LSTM được giới thiệu bởi Hochreiter và Schmidhuber nhằm giải quyết các bài toán về phụ thuộc xa (long-term dependency). LSTM lưu giữ các giá trị tính toán sau một khoảng thời gian tùy ý, nhằm loại bỏ phụ thuộc dài hạn. Mạng lưới cải tiến LSTM được biểu diễn ở Hình 1.

Một mạng lưới LSTM gồm có 4 thành phần chính: một đường trạng thái tế bào (cell state) C_t và 3 cổng (gates) với

hàm kích hoạt $\sigma: x \mapsto [0,1]$ (sigmoid activation) để kiểm soát mức độ thông qua của dữ liệu. Các cổng kết nối với đường trạng thái bằng một phép toán (hay được gọi là mắt xích).



Hình 1. Đồ thị minh họa mạng lưới và phương trình LSTM [8].

Đường trạng thái tế bào C_t là đường truyền chạy xuyên suốt các mắt xích giúp thông tin có thể được gán và truyền qua LSTM mà không bị thay đổi.

Cổng thứ nhất trong Hình 2a là tầng cổng quên (forget gate layer) với đầu vào $W_f h_{t-1} + b_f$ (dữ liệu từ đầu ra của mạng LSTM t-1) và $W_f x_t + b_f$ (dữ liệu bổ sung tại t) với tác dụng loại bỏ thông tin không mong muốn. Cổng thứ hai trong Hình 2b bao gồm một tầng cổng vào (input gate layer) với hàm kích hoạt σ để lựa chọn giá trị nào cập nhật vào tầng tanh: $x \mapsto [-1,1]$. Sau khi thu được vector giá trị tế bào mới \tilde{C}_t , trạng thái tế bào cũ C_{t-1} sẽ được cập nhật thành trạng thái mới C_t ở Hình 2c. Cuối cùng, tại cổng lọc (filter gate layer), hàm kích hoạt σ lựa chọn loại đầu ra cho C_t mà ta mong muốn, đầu ra của bộ lọc là tích của hàm σ và hàm tanh ở Hình 2d.


Qua phân tích cơ chế hoạt động của LSTM, có thể thấy mô hình xử lý loại bỏ hoàn toàn cơ chế lan truyền ngược (backpropagation) trong các mạng lưới RNN phổ biến khác [9]. Điều này giúp mạng LSTM tạo cầu nối giữa các tế bào trạng thái rất cũ với trạng thái hiện tại, tăng hiệu suất xử lý với độ phức tạp $\sim O(1)$.

3. Mô tả và tiền xử lý dữ liệu

3.1. Mô tả dữ liệu

Chu kỳ hoạt động của bộ trao đổi nhiệt trong khoảng 20 - 60 ngày, đa số có chung các đặc điểm như xu hướng suy giảm của lưu lượng, độ chênh áp tăng, tuy nhiên cường độ có sự sai khác và xu hướng tăng một số chu kỳ có sự đột biến vào giai đoạn cuối, nhiệt độ thay đổi ngẫu nhiên không có xu hướng cụ thể.

Sự sai khác về thời gian mỗi chu kỳ, cường độ tăng giảm, tần suất xuất hiện các điểm thiết bị lỗi của mỗi chu kỳ phụ thuộc nhiều yếu tố như: nhiệt độ nước biển không ổn định do đặc điểm tự nhiên của môi trường, mức độ hoạt động của sinh vật biển vào các mùa khác nhau dẫn tới tốc độ hình thành mảng bám cản trở dòng chảy khác nhau, nhu cầu sử dụng của máy nén khác nhau... Vì vậy, bộ dữ liệu sử dụng sẽ được loại bỏ các chu kỳ được cho là bất thường - không có xu hướng tăng rõ, ngắn bất thường, xuất hiện nhiều điểm lỗi và sử dụng dữ liệu chênh áp cũng như lưu lượng dòng



Hình 2. Các bộ phận cấu thành mạng lưới LSTM [8].

Bảng 2. Chu kỳ hoạt động của bộ trao đổi nhiệt

TT	Thời gian hoạt động của bộ trao đổi nhiệt theo chu kỳ
1	58 ngày 3 giờ
2	58 ngày 9 giờ
3	45 ngày
4	62 ngày 7 giờ
5	48 ngày 15 giờ
6	45 ngày 3 giờ
7	50 ngày 14 giờ
8	21 ngày

chảy nhằm đảm bảo tính chính xác và ổn định cho mô hình dự báo và đánh giá tình trạng của thiết bị trao đổi nhiệt.

Các kỹ thuật tiền xử lý tổng quát cho 2 nhiệm vụ được áp dụng đối với bộ dữ liệu của thiết bị bộ trao đổi nhiệt dạng tấm gồm xử lý dữ liệu bị khuyết, phân tách các bộ dữ liệu chu kỳ vận hành và co giãn dữ liệu. Đối với mỗi nhiệm vụ riêng, các kỹ thuật xử lý đặc trưng theo yêu cầu của phương pháp được áp dụng tương ứng.

3.2. Tiền xử lý dữ liệu

Các công việc cần thực hiện:

Xử lý dữ liệu bị khuyết gồm 3 giai đoạn tuần tự gồm: phát hiện vị trí khuyết dữ liệu, kiểm tra loại lỗi dữ liệu và lựa chọn phương án xử lý phù hợp.

Phân tách các bộ dữ liệu chu kỳ vận hành - dựa trên hàm điều kiện xây dựng trên giá trị ngưỡng do các chuyên gia vận hành đưa ra - nhằm chia bộ dữ liệu thành các chu kỳ hoạt động.

Chuẩn hóa dữ liệu thông qua phương pháp chuẩn hóa normalization được áp dụng với đầu ra mong muốn thuộc khoảng [-1,1] cho mô hình LSTM với nhận định dữ liệu phân bố trải trên miền giá trị tương đối đều và kết quả sau hiệu chỉnh của các lần thử đối với các hàm kích hoạt khác nhau.

3.3. Dự báo ngắn hạn bằng mô hình LSTM

Tập hợp dữ liệu các chu kỳ hoạt động được chia làm 3 phần: dữ liệu huấn luyện (training set), dữ liệu phê chuẩn (validation set) và dữ liệu kiểm tra (test set). Những điểm dữ liệu cho mỗi tập hợp tuân thủ tính độc lập rõ ràng giữa các tập dữ liệu.

Sau khi thực hiện phân tập dữ liệu, mỗi phần dữ liệu sau đó lần lượt được biến đổi thành các mảng dữ liệu 3 chiều đúng định dạng đầu vào theo yêu cầu của mô hình LSTM là: mẫu dữ liệu (sample) - bước nhảy k (time steps) - đặc điểm (feature). Ví dụ, đối với dữ liệu đào tạo yêu cầu đầu ra 24 điểm dữ liệu dự báo, 48 điểm dữ liệu quá khứ, đầu vào 1 đặc trưng và đầu ra 1 đặc trưng sẽ được thiết lập trích xuất từ khung dữ liệu.

3.4. Dự báo dài hạn bằng mô hình hồi quy phi tuyến

Sử dụng trực tiếp dữ liệu chênh áp của dòng nước biển làm mát theo thời gian. Các tệp dữ liệu sau khi đưa lên khung dữ liệu được lọc các giá trị không phải số (not a number - NaN) và chuyển thành mảng một chiều với chỉ

số của mảng (array index) tương ứng với số giờ hoạt động của chu kỳ hoạt động của thiết bị.

Mảng 1 chiều sau đó được phân tách thành 2 mảng con theo thứ tự tuân thủ ràng buộc về thời gian là mảng chứa dữ liệu đào tạo và mảng chứa dữ liệu kiểm tra với dữ liệu đào tạo tính từ thời điểm bắt đầu hoạt động tới các điểm trạm lần lượt sau mỗi 48 giờ, kể từ thời điểm 300 giờ vận hành; số dữ liệu còn lại là tệp dữ liệu kiểm tra. Một mảng một chiều được xây dựng tương ứng với chỉ số tương đồng với bộ dữ liệu kiểm tra làm đầu vào cho mô hình để trả giá trị dự báo tương ứng.

4. Mô hình dự báo tuổi thọ hữu ích còn lại

4.1. Dự báo ngắn hạn bằng mô hình LSTM

Mô hình LSTM đề xuất để dự báo 24 giờ tiếp theo so với thời điểm hiện tại tương ứng với 48 điểm dữ liệu, thời gian lấy mẫu 1 giờ. Dữ liệu đầu vào của mô hình LSTM dựa vào 48 điểm giá trị cảm biến lưu lượng cửa vào dòng nước biển, cảm biến chênh áp cửa vào/ra dòng nước biển (tương đương với 48 giờ) trong quá khứ. Mô hình LSTM được thiết kế thông qua các bước tuần tự bao gồm: xây dựng mô hình cơ bản, xử lý các vấn đề và hiệu chỉnh thông số, và kiểm tra khả năng dự báo của mô hình. Thông qua từng giai đoạn, từng lớp được xếp vào cây tuyến tính (linear tree) để đạt được mô hình tối ưu nhất về độ chính xác.

Hàm kích hoạt được chọn là hàm “tanh” do đặc trưng của dữ liệu đầu vào trải đều trên miền [-1,1]. Để xử lý overfit và underfit, nhóm tác giả sử dụng phương pháp thiết lập hàm gọi ngược dừng sớm (callback function) và loại bỏ một số nút trọng số sau mỗi vòng đào tạo.

Tổng quan mô hình LSTM được thể hiện trong Bảng 3.

Bộ dữ liệu kiểm tra được trích xuất thành các bộ dữ liệu với độ dài 48 - 96 giờ để kiểm định và hiệu chỉnh mô hình. Việc lựa chọn cấu trúc xây dựng mô hình và các thông số mô hình dựa trên các đánh giá về kích cỡ dữ liệu, mục tiêu dự báo và quá trình thử và hiệu chỉnh để lựa chọn các thông số phù hợp nhất. Các thông số mô hình sau quá trình đánh giá và kiểm định được thống kê tóm tắt trong Bảng 4.

Mô hình được huấn luyện với bộ dữ liệu đào tạo phê chuẩn, hàm mất mát (loss function) của mô hình đạt đủ điều kiện của module ngắt sớm sẽ kích hoạt kết thúc quá trình đào tạo và thu được mô hình sẵn sàng để dự báo.

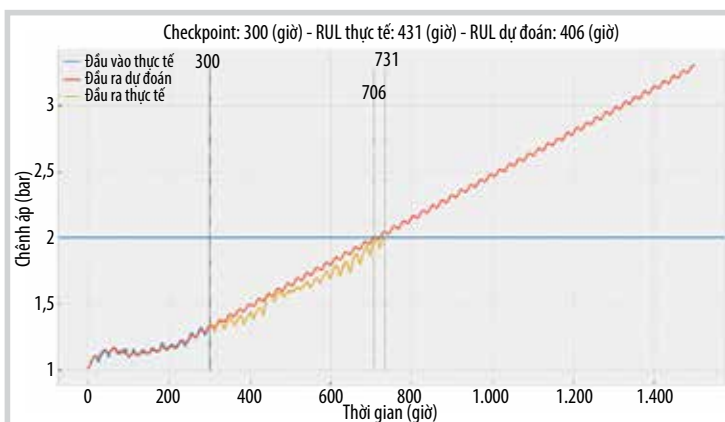
Bảng 3. Cấu trúc mô hình LSTM để xuất xây dựng cho bộ dữ liệu

Lớp	Cấu hình đầu ra (Batch size, time steps, units)	Số tham số
LSTM 1	(0, 48, 128)	66.560
Dropout 1	(0, 48, 128)	0
LSTM 2	(0, ×, 64)	49.408
Dropout 2	(0, 64)	0
Dense	(0, ×, 1)	65

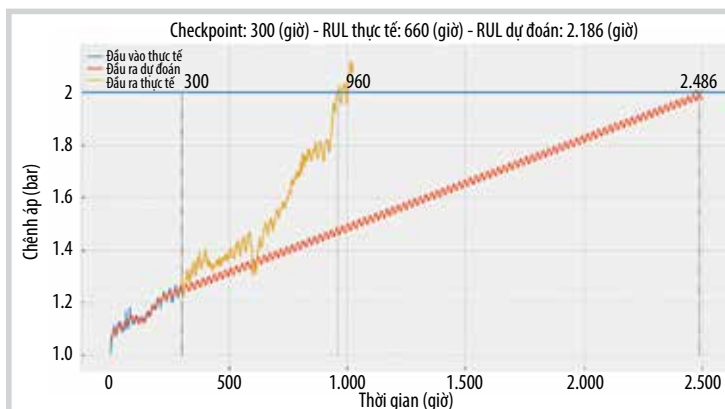
Tổng tham số: 116.033
 Tổng tham số huấn luyện: 116.033
 Tổng tham số không huấn luyện: 0

Bảng 4. Tham số mô hình LSTM được xây dựng

Đặc trưng	Chi tiết
Mục tiêu	Dự báo trước 24 giờ giá trị chênh áp dòng nước biển làm mát bộ trao đổi nhiệt dạng tấm.
Dữ liệu đầu vào	48 tensor dữ liệu cảm biến lưu lượng cửa vào dòng nước biển, cảm biến chênh áp cửa vào/ra dòng nước biển.
Cấu trúc mô hình	TensorFlow Core v2.8.0
Thông số mô hình	- Số lớp ẩn: 128, 64 - Dropout: 0,2; 0,1 - Tham số ngắt sớm (early stopping): monitor = val_loss, patience = 5, mode = min - EPOCH: 50 - Kích cỡ tập (batch size): 16.



Hình 3. Kết quả dự báo RUL thời điểm 300 giờ vận hành chu kỳ I.



Hình 4. Kết quả dự báo RUL thời điểm 300 giờ vận hành chu kỳ II.


4.2. Dự báo dài hạn bằng mô hình hồi quy phi tuyến

Mô hình hồi quy phi tuyến sử dụng hàm RMSE dựa trên dữ liệu 300 giờ vận hành đầu tiên, giúp dự báo thời gian sử dụng còn lại của bộ trao đổi nhiệt. Mô hình dự báo dựa trên giả thiết không có hiện tượng bất thường xảy ra trong quá trình vận hành còn lại của thiết bị kể từ thời điểm 300 giờ vận hành. Mô hình được xây dựng bao gồm 4 giai đoạn chính: xây dựng mô hình phi tuyến tổng hợp, hiệu chỉnh thông số, kiểm tra độ chính xác của mô hình và xây dựng hàm RUL từ kết quả dự báo.

Đối với dữ liệu hoạt động các chu kỳ của bộ trao đổi nhiệt dạng tấm, có thể dễ dàng quan sát thấy sự tồn tại của hàm tuần hoàn trong suất chu kỳ. Ngoài ra tại một số thời điểm, xuất hiện các đoạn tăng giảm đột ngột, có tính chất giống hàm bước. Bên cạnh đó, nguyên nhân chính gây sự tăng chênh áp dòng nước biển do sự hình thành các mảng bám bởi vi sinh vật biển, đa số là hà u biển. Quá trình phát triển này hình thành khi các ấu trùng hà u trong nước biển đi vào cửa làm mát và bám lên thành bộ tản nhiệt dạng tấm, theo thời gian phát triển theo dạng hàm tuyến tính và mũ [10] và ngăn cản dòng chảy làm tăng áp suất chênh lệch.

Mô hình hồi quy phi tuyến được xây dựng dựa trên sự kết hợp giữa các mô hình con. Dựa trên sai số của hàm con với dữ liệu đào tạo, các mô hình con được lựa chọn, hiệu chỉnh. Ngoài ra, dựa trên kết quả dự báo trên tập dữ liệu kiểm tra, các mô hình con cũng được hiệu chỉnh tương tự nhằm tối ưu hóa độ chính xác của mô hình. Xây dựng dữ liệu đầu vào dự báo bằng mảng một chiều đầu vào kéo dài 1.500 giờ nhằm đảm bảo vượt ngưỡng chênh áp trung bình của chu kỳ vận hành thiết bị. Nếu sau 1.500 giờ chưa đạt ngưỡng chênh áp trung bình, ta lần lượt chạy thêm các mốc 500 giờ cho tới khi đạt giá trị RUL. Điểm đạt ngưỡng RUL tương đồng với thời điểm giá trị dự báo đạt mức ngưỡng chênh áp dòng nước biển làm mát để xuất. Các giá trị dự báo thu được khi áp dụng hàm model.eval() với dữ liệu đầu vào dự báo.

Kết quả dự báo và dữ liệu đầu ra thực tế được lưu trữ thành khung dữ liệu mới và kết hợp với khung dữ liệu gốc nhằm trực quan hóa và đánh




Hình 5. RUL cập nhật tại một số giai đoạn vận hành trong chu kỳ I.

giá độ chính xác của mô hình. Các hiệu chỉnh được thực hiện dựa trên độ chính xác trung bình của mô hình đối với các bộ dữ liệu vận hành nhằm tìm ra mô hình đạt độ chính xác nhất.


5. Kết quả và thảo luận

5.1. Kết quả dự báo RUL bằng mô hình hồi quy phi tuyến

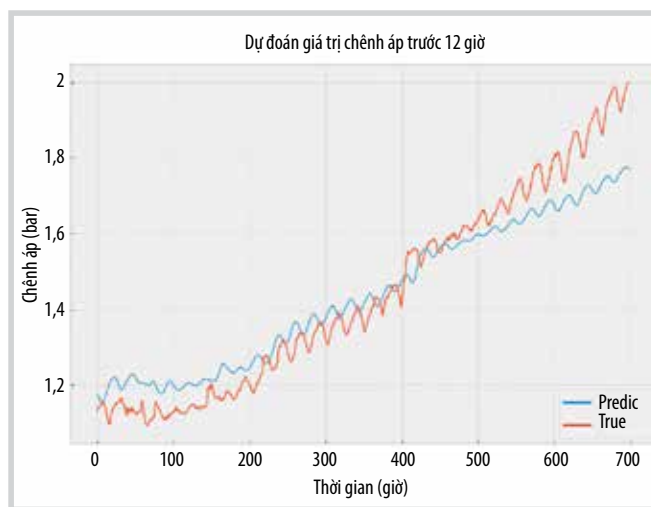
Tại thời điểm bộ trao đổi nhiệt sử dụng được 300 giờ, người vận hành có thể dự báo trước thời điểm đạt ngưỡng chênh áp 2 bar cần rửa ngược và sử dụng kết quả dự báo này cho nhiệm vụ lập lịch bảo trì thiết bị. Trong Hình 3, tại thời điểm 300 giờ, người vận hành có thể ghi nhận thời điểm cần bảo trì tại mốc 706 giờ so với thời điểm thực tế là 733 giờ, đảm bảo được việc bảo trì kịp thời. Tuy nhiên trong Hình 4, tại thời điểm 300 giờ vận hành, với mức vận hành trong 300 giờ trước đó, mô hình dự báo với mức vận hành tương lai tương tự ghi nhận RUL đạt mức 2.486 giờ. Trong khi đó, RUL thực tế của thiết bị là 727 giờ do có sự xuất hiện của bất thường và thay đổi mức độ hoạt động của bộ trao đổi nhiệt trong tương lai. Chính vì vậy, cần có sự cập nhật giá trị RUL theo thời gian nhằm đảm bảo mô hình bám sát nhất sự thay đổi của thiết bị. Các điểm lưu (checkpoint) được thành lập theo 2 phương thức: định kỳ hoặc khi kết quả dự báo ngắn hạn cảnh báo có sự thay đổi đáng kể của giá trị chênh áp. Có thể thấy trong Hình 5, với chu kỳ vận hành số I, khi áp dụng các điểm lưu lần lượt tại 348, 420, 565 và 636 giờ thì các giá trị dự báo RUL là sát hơn. Tương tự trong Hình 6 với chu kỳ vận hành số II. Nguyên nhân là do các vi sinh vật trong nước biển phát triển với tốc độ thay đổi, hình thành nên giá trị chênh áp tại bộ trao đổi nhiệt với độ biến thiên khác nhau. Việc kiểm soát sự phát triển và xâm nhập của vi sinh vật trong nước biển là rất khó khăn vì phải phụ thuộc vào nồng độ hóa chất được sử dụng cũng như sự biến đổi của dòng hải lưu. Nhóm tác giả đã đề xuất sử dụng phương pháp dự báo ngắn hạn giá trị chênh áp sử dụng mạng LSTM để phát hiện các điểm bất thường hay còn gọi là điểm lưu.



Hình 6. RUL cập nhật tại một số giai đoạn vận hành thiết bị chu kỳ II.



Hình 7. Dự báo ngắn hạn giá trị chênh áp (PDI-4400A) bằng mô hình LSTM.



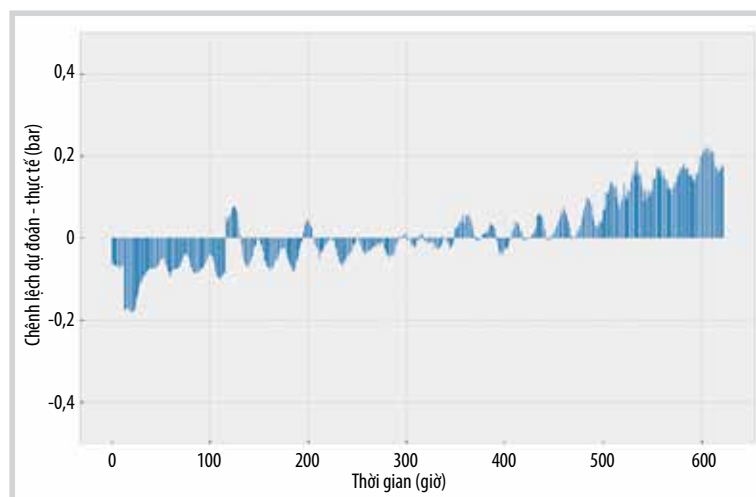
Hình 8. Dự báo ngắn hạn giá trị chênh áp (PDI-4400B) bằng mô hình LSTM.

5.2. Kết quả dự báo ngắn hạn và đánh giá tình trạng bằng mô hình LSTM

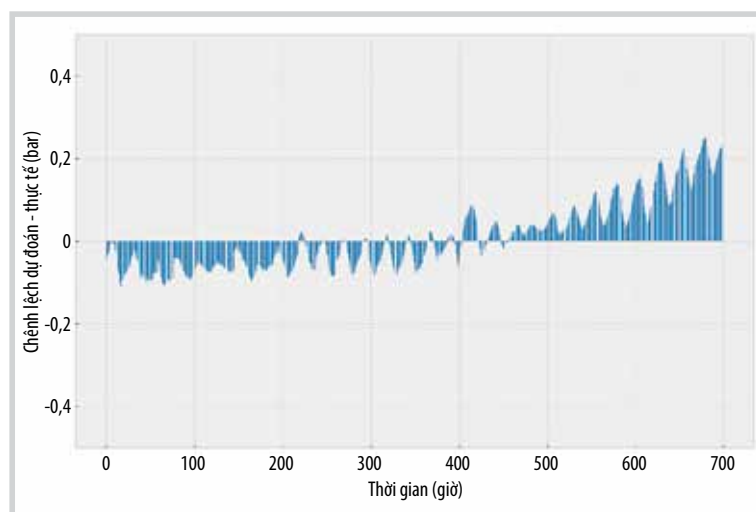
Mô hình LSTM cho thấy xu hướng thay đổi của các giá trị chênh áp của bộ trao đổi nhiệt dạng tấm ổn định hoặc bất thường, và xác định các vị trí xuất hiện thay đổi lớn làm cơ sở để cập nhật mô hình hồi quy phi tuyến tương

ứng. Các giá trị dự báo ngắn hạn của các chu kỳ dữ liệu cho thấy sự bám sát của kết quả dự báo mô hình với thực tế như trong Hình 7 và 8.

Giá trị sai số giữa mô hình dự báo và thực tế giúp phát hiện các bất thường trong quá trình hoạt động và qua đó cập nhật giá trị tuổi thọ hữu ích còn lại ngay khi có các



Hình 9. Sai lệch giữa kết quả dự báo và thực tế giá trị chênh áp (PDI-4400A).



Hình 10. Sai lệch giữa kết quả dự báo và thực tế giá trị chênh áp (PDI-4400B).

biến động không lường trước được trong quá trình vận hành thiết bị. Các cảnh báo được đưa ra nhằm cập nhật giá trị RUL mới qua mô hình hồi quy phi tuyến tính. Kết quả phát hiện sai số của mô hình LSTM dự báo ngắn hạn giá trị chênh áp đối với chu kỳ I thể hiện trong Hình 9 và 10 dẫn đến việc xác định giá trị điểm lưu tại các điểm 420, 565 và 636 giờ vận hành thiết bị.

6. Kết luận

Nghiên cứu đề xuất phương pháp dự báo được tuổi thọ hữu ích còn lại (RUL) của bộ trao đổi nhiệt dạng tấm với dạng dữ liệu có xu hướng thay đổi theo thời gian thông qua việc kết hợp mô hình hồi quy phi tuyến và mô hình mạng bộ nhớ dài - ngắn hạn LSTM. Quy trình thực hiện có thể được áp dụng với các thiết bị mà thông số vận hành có xu hướng tăng hoặc giảm theo thời gian trước khi chạm ngưỡng nhất định.

Mô hình hồi quy phi tuyến giúp tính toán thời gian sử dụng hữu ích còn lại đạt độ chính xác cao dựa trên việc xác định các điểm lưu và dự báo dài hạn giá trị chênh áp tại bộ trao đổi nhiệt dạng tấm. Mô

hình LSTM dự báo ngắn hạn giá trị chênh áp và cho kết quả dự báo liên tục mỗi 24 giờ. Giá trị sai số giữa mô hình dự báo và thực tế giúp phát hiện các bất thường trong quá trình hoạt động và qua đó cập nhật giá trị tuổi thọ hữu ích còn lại ngay khi có các biến động không lường trước được trong quá trình vận hành thiết bị. Sự kết hợp của 2 mô hình giúp các kỹ sư vận hành có thể chủ động trong việc lên kế hoạch và phân bổ nhân lực phục vụ công tác bảo trì bảo dưỡng thiết bị.

Tài liệu tham khảo

[1] Zhenghua Chen, Min Wu, Rui Zhao, Feri Guretno, Ruqiang Yan, and Xiaoli Li, "Machine remaining useful life prediction via an attention-based deep learning approach", *IEEE Transactions on Industrial Electronics*, Volume 68, Issue 3, pp. 2521 - 2531, 2021. DOI: 10.1109/TIE.2020.2972443.

[2] Zuozhou Pan, Zong Meng, Zijun Chen, Wenqing Gao, and Ying Shi, "A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings", *Mechanical Systems and Signal Processing*, Volume 144, 2020. DOI: 10.1016/j.ymssp.2020.106899.

[3] Jason Deutsch and David He, "Using deep learning-based approach to predict remaining useful life of rotating components", *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, Volume 48, Issue 1, pp. 11 - 20, 2018. DOI: 10.1109/TSMC.2017.2697842.

[4] James Carroll, Sofia Koukoura, Alasdair McDonald, Anastasis Charalambous, Stephan Weiss, and Stephen McArthur, "Wind turbine gearbox failure and remaining useful life prediction using machine learning techniques", *Wind Energy*, Volume 22, Issue 3, pp. 360 - 375, 2019.

[5] Yongmeng Zhu, Jiechang Wu, Xing Liu, Jun Wu, Kai Chai, Gang Hao, and Shuyong Liu, "Hybrid scheme through read-first-LSTM encoder-decoder and broad learning system for bearings degradation monitoring and remaining useful life estimation", *Advanced Engineering Informatics*, Volume 56, 2023. DOI: 10.1016/j.aei.2023.102014.

[6] Xiaoyu Li, Changgui Yuan, and Zhenpo Wang, "Multi-time-scale framework for prognostic health condition of lithium battery using modified Gaussian process regression and nonlinear regression", *Journal of Power Sources*, Volume 467, 2020. DOI: 10.1016/j.jpowsour.2020.228358.

[7] Venkat P. Nemani, Hao Lu, Adam Thelen, Chao Hu, and Andrew T. Zimmerman, "Ensembles of probabilistic LSTM predictors and correctors for bearing prognostics using industrial standards", *Neurocomputing*, Volume 491, pp. 575 - 596, 2022. DOI: 10.1016/j.neucom.2021.12.035.

[8] Colah's blog, "Understanding LSTM networks", 7/22/2022. [Online]. Available: <https://colah.github.io/posts/2015-08-understanding-LSTMs/>.

[9] Sepp Hochreiter and Jürgen Schmidhuber, "Long short-term memory", *Neural Computation*, Volume 9, Issue 8, pp. 1735 - 1780, 1997. DOI: 10.1162/neco.1997.9.8.1735.

[10] N.A. Sitnik, "Growth and the energy budget of flat oyster (*Ostrea edulis*) in early ontogenesis", *Biosystems Diversity*, Volume 18, Issue 1, pp. 110 - 116, 2010. DOI: 10.15421/011016.

PREDICTION OF THE REMAINING USEFUL LIFE FOR PLATE HEAT EXCHANGER AT HAI THACH - MOC TINH FIELDS

Tran Ngoc Trung, Nguyen Thanh Trung, Nguyen Duy Minh, Dao Quang Khoa, Tran Vu Tung, Tran Duc Thang

Bien Dong Petroleum Operating Company (Bien Dong POC)

Email: trungtn@biendongpoc.vn

Summary

Predictive maintenance is an advanced and widely adopted approach in the industry that helps maximize the equipment uptime by estimating its remaining useful life (RUL) and predicting any potential failure point. The authors have made a short-term prediction of the seawater flow pressure difference at a plate heat exchanger using a long short-term memory (LSTM) network, and thereby predicted the RUL using a nonlinear regression model. The proposed model achieved high accuracy by continuously detecting checkpoints and predicting RUL values every 24 hours. Checkpoints are identified through detecting differential pressure anomalies at the plate heat exchanger during operation. Thereby, it helps update the RUL value promptly upon any unforeseen deviation during equipment operation.

Key words: Remaining useful life, plate heat exchanger, Hai Thach - Moc Tinh fields.