

Giải pháp áp dụng các thuật toán Machine learning nhằm phát hiện các bất thường cho máy điện quay

SOLUTION FOR ANOMALY DETECTION IN ROTATING ELECTRICAL MACHINES USING MACHINE LEARNING ALGORITHMS

Nguyễn Duy Khánh¹, Nguyễn Văn Đạt², Trần Như Trí Tuệ³

¹Phòng Kiểm tra-Đánh giá, Công ty EPS, 0342073979, khanhd@eps.genco3.vn

²Phòng Kiểm tra-Đánh giá, Công ty EPS, 0915444642, datnv@eps.genco3.vn

³Phòng Kiểm tra-Đánh giá, Công ty EPS, 0934641007, tuetnt@eps.genco3.vn

TÓM TẮT

Các thiết bị quay công suất lớn như máy phát điện, bơm và quạt đóng vai trò quan trọng trong vận hành nhà máy điện. Việc phát hiện sớm dấu hiệu bất thường trong quá trình vận hành của các thiết bị này là yếu tố then chốt nhằm giảm thiểu sự cố đột xuất, tối ưu hóa công tác bảo trì và duy trì độ tin cậy. Tuy nhiên, các phương pháp giám sát truyền thống hiện nay chủ yếu dựa trên cảnh báo ngưỡng cố định (Alarm/Trip) được cài đặt trong hệ thống điều khiển DCS, kết hợp với kinh nghiệm theo dõi thủ công của nhân sự vận hành. Cách tiếp cận này còn nhiều hạn chế, đặc biệt trong việc phát hiện sớm các bất thường có diễn tiến chậm hoặc chưa đủ lớn để vượt ngưỡng cảnh báo, dẫn đến phản ứng chậm trễ và nguy cơ ngừng máy ngoài kế hoạch.

Nhằm khắc phục những hạn chế đó, nghiên cứu này đề xuất áp dụng thuật toán học máy (Machine Learning) để phát hiện sớm các bất thường thiết bị. Mô hình được lựa chọn là hồi quy tuyến tính đa biến kết hợp điều chuẩn Elastic Net, do có khả năng xử lý hiệu quả hiện tượng đa cộng tuyến giữa các biến đầu vào, đồng thời cân bằng giữa độ chính xác và khả năng giải thích mô hình. Mô hình này sử dụng mối tương quan giữa các tín hiệu vận hành trong điều kiện thiết bị hoạt động bình thường để dự đoán chính xác giá trị mục tiêu. Khi xảy ra sai lệch đáng kể giữa giá trị dự đoán và giá trị đo, hệ thống sẽ nhận diện và phát cảnh báo bất thường. Mô hình được huấn luyện và kiểm thử trên tập dữ liệu lịch sử được thu thập từ PI System của NMNĐ Vĩnh Tân 2, với thiết bị nghiên cứu là Quạt khói – một máy điện quay công suất lớn hoạt động trong môi trường khắc nghiệt.

Trong giai đoạn vận hành thử nghiệm từ đầu năm 2024, mô hình đã phát hiện sớm sự bất thường của nhiệt độ gối đỡ quạt khói trước khi vượt ngưỡng Alarm, giúp đơn vị vận hành chủ động xử lý bằng các biện pháp phù hợp như chạy thêm quạt làm mát gối đỡ, bơm bổ sung mỡ và theo dõi liên tục. Nhờ đó, thiết bị duy trì vận hành ổn định cho đến kỳ bảo dưỡng kế tiếp mà không phát sinh sự cố.

Nghiên cứu khẳng định hiệu quả của mô hình ML trong giám sát thiết bị quay, mở ra hướng tiếp cận mới cho công tác bảo trì dự đoán trong ngành điện, góp phần nâng cao độ tin cậy, tối ưu hóa chi phí và giảm thiểu thời gian dừng máy không mong muốn.

Từ khóa: Bảo trì dự đoán; Học máy; Hệ thống cảnh báo sớm; Hồi quy tuyến tính; Máy điện quay

CHỮ VIẾT TẮT

AI	Artificial Intelligence (Trí tuệ nhân tạo)
DCS	Distributed Control System (Hệ thống điều khiển phân tán)
ĐVPĐ	Đơn vị phát điện
IIoT	Industrial Internet of Things
IT	Information Technology (Công nghệ thông tin)
ML	Machine Learning (Học máy)

MSE	Mean Squared Error (Sai số bình phương trung bình)
NMNĐ	Nhà máy nhiệt điện
O&M	Operation and Maintenance (Vận hành và Sửa chữa)
OT	Operational Technology (Công nghệ vận hành)
PdM	Predictive Maintenance (Bảo trì dự đoán)
PI System	Hệ thống quản lý dữ liệu thời gian thực
R ²	Coefficient of Determination (Hệ số xác định)
RMS	Remote Monitoring System – Hệ thống giám sát từ xa

GIỚI THIỆU (INTRODUCTION)

Giám sát tình trạng vận hành là công tác liên tục và quan trọng để đảm bảo Nhà máy điện hoạt động an toàn, liên tục và kinh tế, đặc biệt là đối với các thiết bị quay có công suất lớn như máy phát điện, bơm và quạt. Tuy nhiên, các phương pháp giám sát truyền thống hiện nay chủ yếu dựa trên cảnh báo ngưỡng cố định (Alarm/Trip) được cài đặt trong hệ thống điều khiển DCS, kết hợp với kinh nghiệm theo dõi thủ công của nhân sự vận hành. Cách tiếp cận này còn nhiều hạn chế trong việc phát hiện sớm các bất thường có diễn tiến chậm hoặc chưa đủ lớn để vượt ngưỡng cảnh báo, dẫn đến phản ứng chậm trễ và nguy cơ ngừng máy ngoài kế hoạch.

Trong bối cảnh phát triển mạnh mẽ của IIoT, Tổng Công ty Phát điện 3 đã triển khai hệ thống giám sát từ xa (Remote Monitoring System – RMS) sử dụng nền tảng PI System (của hãng OSIsoft, nay là AVEVA) tại các NMNĐ Vĩnh Tân 2 và Mông Dương 1. Hệ thống RMS thu thập dữ liệu thời gian thực truyền từ môi trường OT (môi trường liên quan vận hành nhà máy) sang IT (môi trường liên quan đến cơ sở dữ liệu), tạo nguồn dữ liệu lớn về thông số vận hành thiết bị để phân tích và khai thác. Trong những năm gần đây, với sự phát triển của AI, các đơn vị quản lý O&M ngày càng chú trọng ứng dụng ML vào giám sát tình trạng các thiết bị trong nhà máy. ML có khả năng học được hành vi đặc trưng của thiết bị, qua đó nhận biết những sai lệch nhỏ của giá trị đo thực tế so với trạng thái hoạt động bình thường, ngay cả khi các giá trị này vẫn nằm dưới ngưỡng cảnh báo cố định (Alarm/Trip). Điều này giúp phát hiện sớm bất thường tiềm ẩn trước khi chúng tiến triển thành sự cố nghiêm trọng. Nhiều nghiên cứu đã đề xuất các hệ thống phát hiện bất thường dựa trên ML cho máy móc công nghiệp. Chẳng hạn, Kanawaday & Sane (2017) áp dụng mô hình ARIMA [1] trên chuỗi dữ liệu cảm biến IoT để dự báo hỏng hóc trong dây chuyền sản xuất, qua đó tối ưu chi phí bảo trì và nâng cao hiệu quả vận hành. Trong lĩnh vực máy điện quay, Sofiany (2024) [2] cũng chứng minh lợi ích của mô hình ML trong việc theo dõi độ rung của tuabin: mô hình dự đoán giúp phát hiện gia tăng bất thường rất nhỏ của rung động nằm dưới ngưỡng báo động, nhờ đó lên kế hoạch bảo trì có điều kiện một cách chủ động. Những kết quả này cho thấy ứng dụng Machine Learning vào công tác bảo trì dự đoán (predictive maintenance) là hướng đi đầy triển vọng.

Từ thực tế đó, nhóm tác giả thực hiện nghiên cứu áp dụng thuật toán ML để phát hiện bất thường trên thiết bị quay, cụ thể là quạt khói tại NMNĐ Vĩnh Tân 2, một máy điện quay công suất lớn hoạt động trong môi trường khắc nghiệt. Bài báo này trình bày phương pháp xây dựng mô hình, thử nghiệm trên dữ liệu thực tế để đánh giá mức độ hiệu quả của mô hình này.

CƠ SỞ LÝ THUYẾT/PHƯƠNG PHÁP NGHIÊN CỨU (THEORETICAL FRAMEWORK/METHODS)

Phương pháp giám sát dựa trên mô hình dự đoán

Để có thể phát hiện bất thường trong quá trình hoạt động của thiết bị từ dữ liệu thu thập trong quá khứ, nghiên cứu này sử dụng phương pháp hồi quy tuyến tính đa biến để xây dựng mô hình dự đoán giá trị của một tín hiệu dựa trên các tín hiệu khác có liên quan đến thiết bị. Trong điều kiện hoạt động bình thường, các tín hiệu như dòng điện, độ rung gối trục, nhiệt độ gối trục... thường thay đổi theo một quy luật nhất định và có mối liên hệ chặt chẽ với nhau. Nhờ đó, ta có thể sử dụng nhiều tín hiệu đầu vào (gọi là các biến độc lập) để dự đoán tín hiệu

đầu ra (gọi là biến phụ thuộc). Khi thiết bị vận hành ổn định, giá trị thực tế và giá trị dự đoán của tín hiệu sẽ gần giống nhau. Nếu có sự chênh lệch lớn giữa hai giá trị này, vượt quá ngưỡng cho phép, điều đó có thể là dấu hiệu của sự bất thường. Cách tiếp cận này tận dụng mối liên hệ giữa nhiều tín hiệu cùng lúc để phát hiện ra những thay đổi bất thường trong trạng thái hoạt động của thiết bị

Mô hình hồi quy tuyến tính đa biến có ưu điểm đơn giản và kết quả đầu ra sau khi được huấn luyện là một phương trình dễ dàng triển khai tính toán thời gian thực trong PI System đã được đầu tư. Phương trình này có dạng như sau:

$$y = a_1x_1 + a_2x_2 + a_3x_3 + \dots + a_nx_n + b \quad (1)$$

Trong đó: y là biến phụ thuộc (biến cần dự đoán); $x_1, x_2, x_3, \dots, x_n$ là các biến độc lập; $a_1, a_2, a_3, \dots, a_n$ là các hệ số ứng với từng biến độc lập; b là hệ số chặn

Thêm vào đó, mô hình Hồi quy tuyến tính đa biến cho phép giải thích rõ ràng mức độ ảnh hưởng của từng biến đầu vào (tương ứng là các tín hiệu đầu vào của mô hình) đến biến đầu ra (tín hiệu cần dự đoán), thuận tiện cho việc phân tích và chẩn đoán. Tuy nhiên, một nhược điểm tiềm ẩn của mô hình hồi quy tuyến tính đa biến là có thể gặp phải đa cộng tuyến (multicollinearity), khi các biến đầu vào có mối tương quan cao với nhau. Điều này khiến mô hình khó đánh giá chính xác vai trò riêng của từng tín hiệu trong việc dự đoán đầu ra. Nói cách khác, nếu một tín hiệu đầu vào bị lỗi hoặc sai lệch, mô hình có thể bị nhiễu và cho ra kết quả dự đoán không chính xác. Một vấn đề khác là quá khớp (overfitting) tức là khi mô hình rất chính xác trên tập dữ liệu huấn luyện nhưng lại kém hiệu quả khi áp dụng trên dữ liệu thực tế. Để giải quyết các vấn đề này, nhóm nghiên cứu áp dụng kỹ thuật điều chuẩn Elastic Net – một phương pháp hồi quy được thiết kế nhằm tăng độ ổn định và độ chính xác cho mô hình trong các trường hợp dữ liệu có mối tương quan mạnh giữa các biến đầu vào. Phương pháp này giúp mô hình:

Giảm hoặc loại bỏ ảnh hưởng của những tín hiệu ít quan trọng (giúp cho phương trình nhận được đơn giản hơn nhưng giá trị dự đoán vẫn có độ chính xác cao) bằng chuẩn L1.

Hạn chế tác động tiêu cực của các tín hiệu có quan hệ chặt chẽ với nhau (để loại bỏ hiện tượng đa cộng tuyến và overfitting) bằng chuẩn L2.

Cụ thể, hàm mất mát của Elastic Net được biểu diễn như sau [3]:

$$L(\beta) = RSS + \lambda (\alpha \|\beta\|_1 + (1 - \alpha) \|\beta\|_2^2) \quad (2)$$

Trong đó: RSS (*Residual Sum of Squares*) là tổng bình phương sai số giữa giá trị thực tế và giá trị dự đoán; β là vector các hệ số hồi quy; $\|\beta\|_1$ là chuẩn L1, có tác dụng khuyến khích triệt tiêu các hệ số nhỏ, từ đó hỗ trợ lựa chọn biến hiệu quả (Lasso); $\|\beta\|_2^2$ là chuẩn L2 – giúp giảm ảnh hưởng của đa cộng tuyến (Ridge); λ là điều chỉnh tổng mức phạt; α điều khiển tỷ lệ giữa hai loại điều chỉnh ($\alpha=1$ thì mô hình trở thành Lasso; $\alpha=0$ là Ridge).

Trong nghiên cứu, nhóm đã sử dụng thuật toán Grid Search để lựa chọn bộ tham số (λ, α) tối ưu cho kỹ thuật Elastic Net. Mô hình sau khi được huấn luyện được đánh giá mức độ chính xác bằng hai chỉ số phổ biến sau:

MSE (Mean Squared Error): Độ sai lệch trung bình bình phương giữa giá trị dự đoán và thực tế.


$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

R^2 (R-squared): Cho biết mô hình giải thích được bao nhiêu phần trăm biến động của tín hiệu cần dự đoán – càng gần 1, mô hình càng chính xác.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Trong đó: y_i giá trị thực tế; $\hat{y}_i$ là giá dự đoán, $\bar{y}$ giá trị trung bình của tập dữ liệu

Quy trình thực hiện:



Hình 1. Tổng quan quy trình thực hiện

Quy trình thực hiện được thể hiện trên hình 1, bao gồm thu thập dữ liệu từ PI System ra môi trường Visual studio code hoặc Jupyter notebook, sử dụng ngôn ngữ phổ biến và dễ sử dụng là Python để xử lý dữ liệu và xây dựng mô hình. Mô hình sau khi được đánh giá và tối ưu sẽ được triển khai vào PI System để chẩn đoán theo thời gian thực, phục vụ công tác giám sát tình trạng thiết bị.

Thu thập dữ liệu:

Các dữ liệu vận hành của quạt khói được trích xuất từ PI System trong khoảng thời gian thiết bị vận hành bình thường (01/09/2022 đến 19/12/2023) để làm dữ liệu chuẩn bị cho việc huấn luyện và đánh giá mô hình. Dữ liệu gồm các tín hiệu đo lường khác nhau liên quan đến tình trạng quạt, bao gồm: Công suất tổ máy, dòng điện động cơ, nhiệt độ gói động cơ, nhiệt độ cuộn dây động cơ, độ rung/ nhiệt độ gói trục quạt, nhiệt độ khói vào/ra, độ mở cánh quạt, áp suất/ nhiệt độ khói vào/ ra quạt, nhiệt độ nước làm mát/ dầu bôi trơn/ môi trường (*Danh mục tín hiệu đầu vào được liệt kê chi tiết trong Bảng 1*).

Bảng 1. Danh sách các tín hiệu liên quan đến Quạt khói thu thập ở PI System

Stt	Tên tín hiệu	Mô tả	Đơn vị
1	MWB	Công suất tổ máy	MW
2	CR	Dòng điện động cơ	A
3	FRONT BRG T-1, T-2, T-3	Nhiệt độ gói trục FRONT của quạt	°C
4	MIDDLE BRG T-1, T-2, T-3	Nhiệt độ gói trục MIDDLE của quạt	°C
5	REAR BRG T-1, T-2, T-3	Nhiệt độ gói trục REAR của quạt	°C
6	MTR WDG T-1, T-2, T-3, T-4, T-5, T-6	Nhiệt độ cuộn dây Stator của động cơ	°C
7	BRG X/Y VIB	Độ rung phương X/Y của gói quạt	mm/s
8	MTR FRONT BRG T	Nhiệt độ gói FRONT động cơ	°C
9	MTR REAR BRG T	Nhiệt độ gói REAR động cơ	°C
10	OUT FLUE GAS T	Nhiệt độ khói thoát đầu vào	°C
11	IN FLUE GAS T	Nhiệt độ khói thoát đầu ra	°C
12	STATOR BLADE MCA FEEDBACK	Độ mở cánh quạt khói	%
13	INLET FLUE GAS PRESS	Áp suất khói đầu vào	kPa
14	IN OUT FLUE GAS DP	Chênh áp đầu vào ra của khói	kPa
15	OUT FLUE GAS T	Nhiệt độ khói thoát đầu ra	°C
16	MTR OIL STA OUT T	Nhiệt độ của dầu bôi cấp cho gói động cơ	°C
17	CCCW HEAT PUMP BK HDR T	Nhiệt độ nước làm mát đầu ra của nước làm mát kín	°C
18	OUT T	Nhiệt độ môi trường	°C

Áp dụng thuật toán Hồi quy tuyến tính đa biến

Sau khi thu thập dữ liệu thô từ PI System, quá trình lọc và làm sạch dữ liệu được thực hiện trước khi đưa vào mô hình huấn luyện, bao gồm các bước sau:

Chọn lọc dữ liệu trong các khoảng thời gian thiết bị vận hành ổn định; loại bỏ các thời điểm thiết bị hoặc tổ máy ngừng hoạt động, hoặc xuất hiện dấu hiệu bất thường;

Loại bỏ các điểm đo bất thường (outlier) gây nhiễu kết quả phân tích;


Xử lý các giá trị bị thiếu trong bảng dữ liệu bằng cách điền hoặc loại bỏ tùy theo mức độ và ngữ cảnh dữ liệu.

Dữ liệu sau khi làm sạch được phân chia thành hai phần theo thứ tự thời gian: 80% đầu của tập dữ liệu dùng cho việc huấn luyện và 20% còn lại dùng cho việc kiểm tra. Việc tách dữ liệu như vậy đảm bảo rằng tập dữ liệu kiểm tra hoàn toàn độc lập với tập dữ liệu huấn luyện, giúp đánh giá độ chính xác của mô hình một cách khách quan.

Xây dựng mô hình Hồi quy tuyến tính đa biến trên tập dữ liệu huấn luyện

Phân tích mối tương quan giữa các tín hiệu để lựa chọn các thông số đầu vào và đầu ra của mô hình.

Ví dụ: Với mục tiêu dự đoán nhiệt độ gói trục FRONT, mô hình sử dụng các tín hiệu đầu vào gồm: nhiệt độ gói trục MIDDLE và REAR, nhiệt độ cuộn dây động cơ, và nhiệt độ môi trường. Các tín hiệu này được lựa chọn dựa trên phân tích mối tương quan, cho thấy chúng có mối liên hệ chặt chẽ với nhiệt độ gói trục FRONT, với hệ số tương quan lớn hơn 0.6 (tham khảo hình 2).



Hình 2. Bảng thông số mối tương quan (r) giữa từng cặp tín hiệu

Sử dụng thuật toán hồi quy tuyến tính đa biến kết hợp điều chuẩn Elastic Net để huấn luyện mô hình trên tập huấn luyện. Kết hợp quá trình huấn luyện với tối ưu các tham số điều chuẩn (α, λ) nhờ thuật toán GridSearchCV giúp cho mô hình đạt độ chính xác cao nhất.

Đánh giá mô hình trên tập kiểm tra: Các chỉ số MSE và R^2 dùng để đánh giá độ chính xác của mô hình đã huấn luyện trên tập kiểm tra. Hai chỉ số này được lựa chọn vì chúng là những thước đo phổ biến, dễ diễn giải và đặc biệt phù hợp với bài toán hồi quy. Nếu mô

hình đạt MSE thấp và R^2 cao gần tương đương giữa hai tập dữ liệu huấn luyện và kiểm tra, nghĩa là mô hình tổng quát hóa tốt, không bị overfitting.

Bảng 2. Kết quả đánh giá mô hình hồi quy tuyến tính đa biến trên tập huấn luyện (Train) và kiểm tra (Test)

Tên tín hiệu	MSE (Train)	MSE (Test)	R^2 (Train)	R^2 (Test)
FRONT BRG T	0.4346	0.4276	0.8953	0.8953
MIDDLE BRG T	0.0458	0.0486	0.9885	0.9886
REAR BRG T	0.0546	0.0511	0.9832	0.9842
MTR FRONT BRG T	0.1323	0.1276	0.9338	0.9338
MTR REAR BRG T	0.2007	0.1967	0.8747	0.8740
MTR WDG T	0.6265	0.6368	0.9009	0.8963
STATOR BLADE MCA FEEDBACK	2.1881	2.2332	0.9849	0.9845


Bảng 3. Kết quả đánh giá mô hình hồi quy tuyến tính đa biến kết hợp điều chuẩn Elastic Net trên tập huấn luyện (Train) và kiểm tra (Test)

Tên tín hiệu	MSE (Train)	MSE (Test)	R^2 (Train)	R^2 (Test)
FRONT BRG T	0.0240	0.0238	0.9958	0.9957
MIDDLE BRG T	0.0112	0.0111	0.9971	0.9972
REAR BRG T	0.0132	0.0126	0.9959	0.9959
MTR FRONT BRG T	0.0952	0.0900	0.9528	0.9518
MTR REAR BRG T	0.2735	0.2715	0.8046	0.8078
MTR WDG T	0.0004	0.0005	0.9999	0.9999
STATOR BLADE MCA FEEDBACK	1.0326	1.0605	0.9922	0.9920

Kết quả trình bày trong bảng 2 và bảng 3 cho thấy mô hình hồi quy tuyến tính có áp dụng điều chuẩn Elastic Net đạt hiệu suất dự đoán cao hơn. Cụ thể, các tín hiệu đầu ra đều có giá trị MSE rất nhỏ và hệ số xác định R^2 gần bằng 1 trên cả hai tập dữ liệu huấn luyện và kiểm tra. Sự chênh lệch nhỏ giữa các chỉ số trên hai tập này cho thấy mô hình không bị overfitting và vẫn duy trì được độ chính xác khi áp dụng với dữ liệu mới chưa từng thấy. Điều này chứng tỏ mô hình đã học hiệu quả mối quan hệ tuyến tính giữa các tín hiệu đặc trưng trong điều kiện vận hành bình thường của quạt, tạo nền tảng đáng tin cậy để phát hiện các dấu hiệu bất thường.

Triển khai mô hình vào thực tế

Sau khi mô hình được xây dựng, bước tiếp theo là triển khai vào PI System. Phương trình hồi quy thu được sẽ được đưa vào PI System như hình 3 để tính toán giá trị dự đoán theo thời gian thực.



Hình 3. Các phương trình dự đoán được đưa vào PI System

Đồng thời, xây dựng giao diện giám sát trên ứng dụng có sẵn của PI System để hiển thị trực quan cả giá trị thực tế và giá trị dự đoán của các thông số theo thời gian như hình 4. Giao diện này giúp kỹ sư theo dõi liên tục độ chính xác của mô hình và phát hiện nhanh khi mô hình đưa ra cảnh báo.

REMOTE MONITORING & DIAGNOSTICS CENTER									
PREDICTIVE MAINTENANCE									
S1 - BOILER INDUCED DRAFT FAN (IDF-A)									
MODEL WORKING									
MOTOR		MOTOR BEARING TEMP		MOTOR WINDING TEMP		FAN BEARING VIB		FAN BEARING TEMP, FRONT	
CB	0.28 A	16.43 A	-16.1	MTR FRONT BRG T-1	28.63 °C	68.90 °C	-38.28	MTR WDG T-1	26.50 °C
									17.17 °C
									9.53
									0.13 mm/s
									26.85 °C
									21.00 °C
									4.96
									26.16 °C
									26.65 °C
									-2.49
									26.32 °C
									26.11 °C
									1.21
									26.50 °C
									24.02 °C
									1.69
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05
									26.50 °C
									24.19 °C
									2.05

KẾT QUẢ NGHIÊN CỨU/TÍNH TOÁN/MÔ PHỎNG VÀ THẢO LUẬN (RESULTS AND DISCUSSION)

Kết quả nghiên cứu

Kiểm chứng mô hình với một sự cố trong quá khứ:

Vào tháng 12/2021, xảy ra sự cố dừng quạt khói NMNĐ Vĩnh Tân 2, khi mà công tác giám sát thiết bị chỉ dựa vào con người, chưa được áp dụng ML. Mô hình được chạy dự đoán với bộ dữ liệu trước thời điểm sự cố 02 tháng để đánh giá hiệu quả, kết quả như sau:

Từ ngày 02/11/2021 đến 01/12/2021, mô hình đưa ra 12 cảnh báo nhiệt độ gói FRONT có bất thường, giá trị thực tế vượt khỏi ngưỡng trên của khoảng tin cậy, mặc dù giá trị ghi nhận thực tế khoảng 69°C, vẫn thấp hơn ngưỡng Alarm (90°C)

Từ 02/12 đến 06/12/2021, tổ máy dừng dự phòng. Tuy nhiên, do không nhận diện được sự bất thường trước đó nên chưa có kế hoạch kiểm tra và bảo dưỡng quạt khói trong thời gian này.

Ngày 06/12/2021, tổ máy khởi động trở lại, mô hình tiếp tục đưa ra 03 cảnh báo nhiệt độ gói FRONT có bất thường. Đến ngày 12/12/2021, nhiệt độ gói FRONT tăng vọt từ 69°C lên 77°C và tiếp tục tăng lên sau đó, ĐVPPĐ phát hiện bất thường và thực hiện biện pháp châm mỡ bôi trơn bổ sung. Tuy nhiên nhiệt độ gói quạt vẫn không ngừng tăng và Trip quạt khói khi nhiệt độ đạt ngưỡng bảo vệ (Trip 100°C) vào ngày 14/12/2021.

Hình ảnh minh họa trend và phân tích dữ liệu từ hệ thống RMS tham khảo hình 6.




Hình 6. Trend dữ liệu lịch sử của sự cố năm 2021 khi áp dụng mô hình ML

Sau khi thiết bị dừng, kết quả kiểm tra tình trạng bạc đạn (tham khảo hình 7) như sau:

Ổ bi NU252 MA/C3 bị kẹt bi, vòng cách bị mòn và xuất hiện các mảnh kim loại tại vòng cách.

Bề mặt tiếp xúc của viên bi với ca trong bạc đạn NU252 MA/C3 xuất hiện các vết rỗ nhẹ, bề mặt ca trong ca ngoài bạc đạn bị nám đen do nhiệt độ cao.



Hình 7. Hình ảnh kiểm tra ca trong và ca ngoài của bạc đạn quạt khói

Nhận xét:

Mô hình ML đã cảnh báo sớm hơn 6 tuần trước khi sự cố xảy ra (từ ngày 02/11/2021). Nếu mô hình được áp dụng thì:

Kế hoạch kiểm tra và bảo dưỡng gói quạt có thể đã được thực hiện trong thời gian dừng dự phòng từ 02/12/2021 đến 06/12/2021.

Sự cố trip quạt khói vào ngày 14/12/2021 hoàn toàn có thể được ngăn chặn.

Giảm thiểu tổn thất sản lượng và rủi ro cho tổ máy.

Thử nghiệm mô hình theo thời gian thực:

Mô hình được triển khai để liên tục tính toán và so sánh giá trị dự đoán với giá trị đo thực tế theo thời gian thực cho quạt khói NMNĐ Vĩnh Tân 2. Kết quả như sau:

Từ ngày 09/01/2024 đến 16/01/2024, mô hình đưa ra 04 cảnh báo nhiệt độ gói FRONT có bất thường, giá trị thực tế vượt khỏi ngưỡng trên của khoảng tin cậy, mặc dù giá trị ghi nhận thực tế khoảng 73°C, vẫn thấp hơn ngưỡng Alarm (90°C) (như hình 8 và 9). ĐVPH thực hiện chạy 02 quạt làm mát gói quạt (ở điều kiện vận hành bình thường chỉ chạy 01 quạt làm mát gói). Nhiệt độ gói quạt được kiểm soát tốt sau đó.

Trong các đợt ngừng tổ máy dự phòng ngày 15/03/2024 và 03/07/2024, thực hiện tháo nắp gói quạt để lấy mỡ cũ và bơm mỡ bôi trơn mới. Đồng thời bảo dưỡng quạt làm mát gói quạt để đạt hiệu suất làm mát tốt nhất.



Hình 8. Nhiệt độ gói FRONT T-1 vượt ra khỏi khoảng tin cậy của mô hình

REMOTE MONITORING & DIAGNOSTICS CENTER									
PREDICTIVE MAINTENANCE									
S1 - BOILER INDUCED DRAFT FAN (IDF-B)									
MODEL WORKING									
MOTOR		MOTOR BEARING TEMP		MOTOR WINDING TEMP		FAN BEARING VIB		FAN BEARING TEMP_FRONT	
QIB	350.95 A	357.44 A	-6.49	MTR FRONT BRG T	54.96 °C	57.03 °C	-2.07	MTR WDG T-1	55.52 °C
STATOR BLADE MCA FB	84.38 %	83.16 %	1.22	MTR REAR BRG T	58.47 °C	57.85 °C	1.67	MTR WDG T-2	55.75 °C
Kính chú: Tag Name Actual value									
FURTHER PARAMETER									
MWB		610.55 MW		MTR OIL STA OUT T		44.80 °C		OLG FAN-1 RUNNING	
FURNACE PRESS		-45.46 Pa		AIR OUT T		33.45 °C		IN OUT FG DP	
								34.15 %	
								OUT FG PRESS	
								-54.12 Pa	
								INL FG PRESS	
								-3.65 Pa	
								OUT FG TEMP	
								151.58 °C	

Hình 9. Giao diện giám sát mô hình quạt khói khi có bất thường gói FRONT

Quạt khói NMNĐ Vĩnh Tân 2 tiếp tục vận hành an toàn và tin cậy nhờ các hành động phòng ngừa kịp thời này.

Nhận xét:

Mô hình ML đã dự đoán sớm bất thường, nhờ vậy mà bộ phận O&M kịp thời kiểm tra, giám sát chặt chẽ, thực hiện các biện pháp chăm sóc kịp thời để đảm bảo thiết bị vận hành an toàn và liên tục.

Kế hoạch BDSC thiết bị được chuẩn bị chủ động và tốt hơn.

So sánh với các nghiên cứu trước

Kết quả trên minh chứng giá trị thực tiễn của mô hình ML trong phát hiện sớm hư hỏng thiết bị. Mô hình ML nhận ra độ lệch nhỏ so với trạng thái bình thường tích lũy qua thời gian. Điều này phù hợp với báo cáo của Sofiany (2024) [2]: “Ứng dụng ML có thể phát hiện những biến đổi dù nhỏ, giúp ngăn ngừa sự cố trước khi chạm ngưỡng nguy hiểm”. Nếu không có cảnh báo sớm, nhiệt độ gói trục FRONT có thể tiếp tục tăng âm thầm và đột ngột vượt ngưỡng Alarm, gây sự cố ngừng máy khẩn cấp. Rõ ràng, việc kết hợp mô hình dự đoán ML với giám sát vận hành đã mở rộng “khoảng an toàn” cho thiết bị – phát hiện sớm thêm một bước so với giám sát bằng DCS.

Ngoài ra, quá trình thử nghiệm cũng khẳng định mô hình ML vận hành ổn định khi tích hợp vào PI System. Việc tính toán giá trị dự đoán với phương trình tuyến tính tiêu tốn rất ít tài nguyên, gần như thời gian thực. Giao diện giám sát trực quan giúp kỹ sư dễ dàng theo dõi và phân tích mô hình. Có thể khẳng định mô hình đáp ứng yêu cầu để triển khai liên tục 24/7 tại nhà máy.

KẾT LUẬN VÀ KHUYẾN NGHỊ (CONCLUSIONS)

Nghiên cứu đã cho thấy hiệu quả của việc áp dụng thuật toán ML trong giám sát tình trạng máy điện quay. Mô hình dự đoán đã thành công trong việc phát hiện sớm bất thường thiết bị, có thể phát hiện cả những bất thường diễn tiến chậm hoặc nhỏ, điều mà giám sát truyền thống khó có thể nhận ra sớm được. Kết quả cảnh báo của mô hình đã được kiểm chứng bằng thực tế vận hành, cho thấy tính chính xác và tin cậy cao. Việc cảnh báo sớm giúp đơn vị O&M có thêm thời gian và thông tin để chủ động ứng phó, lên kế hoạch bảo trì hợp lý, tránh được sự cố gián đoạn vận hành, góp phần giảm thiểu hỏng hóc đột xuất, nâng cao độ sẵn sàng và tuổi thọ cho thiết bị quay.

Từ thành công bước đầu, nhóm tác giả đưa ra một số khuyến nghị:

Với khả năng xử lý của hệ thống PI System, nên mở rộng triển khai mô hình ML tương tự cho các máy điện quay quan trọng khác trong nhà máy, như bơm cấp, quạt gió, hoặc thậm chí máy phát điện. Đối với mỗi loại thiết bị, cần thu thập đủ dữ liệu lịch sử và hiệu chỉnh mô hình phù hợp, nhưng về nguyên lý, đều có thể sử dụng hồi quy tuyến tính đa biến để dự đoán và giám sát.

Trong tương lai gần, có thể nghiên cứu áp dụng các thuật toán học máy tiên tiến như mạng nơ-ron nhân tạo, Isolation Forest, Auto-Associative Kernel Regression hoặc Extreme Gradient Boosting nhằm xử lý các đặc trưng phi tuyến và sự phức tạp trong dữ liệu, từ đó nâng cao hiệu quả phát hiện bất thường. Các mô hình này có thể được xây dựng và triển khai trực tiếp trong môi trường lập trình Python (Visual Studio Code hoặc Jupyter Notebook), giúp tránh được những giới hạn về tính toán và khả năng mô hình hóa của PI System. Song song đó, có thể tìm hiểu thêm các nền tảng APM/PdM sẵn có như GE Predix, IBM Maximo, Seeq...

Cuối cùng, việc đào tạo nhân sự kỹ thuật nắm vững kỹ năng phân tích dữ liệu và hiểu biết mô hình ML là cần thiết, đảm bảo làm chủ công nghệ và triển khai bền vững.

LỜI CẢM ƠN (ACKNOWLEDGMENT)

Nhóm tác giả xin chân thành cảm ơn sự quan tâm, chỉ đạo và tạo điều kiện của Ban Lãnh đạo Tổng Công ty Phát điện 3 và Công ty EPS, cũng như sự hỗ trợ, phối hợp của các đồng nghiệp trong quá trình nghiên cứu và thực hiện bài báo tham luận này.

Bài viết này là kết quả của quá trình làm việc thực tiễn, đồng thời cũng là sự kế thừa những kinh nghiệm quý báu trong công tác kỹ thuật tại đơn vị. Rất mong nhận được sự đóng góp

ý kiến từ các chuyên gia và đồng nghiệp để nội dung bài viết ngày càng được hoàn thiện và có giá trị ứng dụng cao hơn trong thực tế.

TÀI LIỆU THAM KHẢO (REFERENCES)

- [1] A. Kanawaday, A. Sane, 2017. Machine Learning for Predictive Maintenance of Industrial Machines Using IoT Sensor Data. Proceedings of the 8th IEEE International Conference on Software Engineering and Service Science (ICSESS 2017), Beijing, China.
- A. Sofiany, 2024. Leveraging Machine Learning to Enhance Anomaly Detection in Rotating Machinery. *Turbomachinery Magazine*, 65(5) (Sep/Oct 2024).
- Zou, H., & Hastie, T. (2005). Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 67(2), 301–320.