

# MỘT PHƯƠNG PHÁP DỰ ĐOÁN THỜI GIAN SỬ DỤNG HỮU ÍCH CÒN LẠI CỦA MÁY ĐIỆN QUAY DỰA TRÊN HỌC SÂU ĐỂ HỖ TRỢ RA QUYẾT ĐỊNH BẢO TRÌ

A REMAINING USEFUL LIFE PREDICTION METHOD OF ROTATING ELECTRICAL MACHINES  
BASED DEEP LEARNING TO SUPPORT MAINTENANCE DECISION MAKING

Nguyễn Hồ Sĩ Hùng<sup>1,\*</sup>, Nguyễn Thị Kim Trúc<sup>1</sup>,  
Nguyễn Kim Ánh<sup>1</sup>, Lưu Mạnh Tiến<sup>1</sup>, Trần Thị Hoàng Giang<sup>2</sup>

DOI: <http://doi.org/10.57001/huiv5804.2024.243>

## TÓM TẮT

Dự đoán thời gian sử dụng hữu ích còn lại (RUL) của thiết bị giữ một vai trò quan trọng trong việc phát triển các phương pháp bảo trì dựa trên tình trạng thiết bị, giảm thời gian dừng hệ thống, nâng cao độ tin cậy và an toàn. Nghiên cứu này đề xuất một mô hình dự đoán thời gian sử dụng còn lại của máy điện quay theo tiếp cận học sâu. Đầu tiên, dữ liệu chuỗi thời gian được lấy từ cảm biến gắn vào máy điện đo các biến đổi rung động. Bộ dữ liệu này được sử dụng để huấn luyện mạng nơ-ron tích chập lai với kiến trúc bộ nhớ ngắn - dài hạn (CNN-LSTM). Việc áp dụng mô hình dựa trên sự lai ghép giữa CNN và LSTM đã mang lại kết quả vượt trội so với các mô hình truyền thống. Những kết quả này có thể mang lại lợi ích để tối ưu hóa lịch trình bảo trì và cải thiện hiệu quả tổng thể của các hệ thống gồm nhiều máy điện quay.

**Từ khóa:** RUL; học sâu; CNN; LSTM; rung động.

## ABSTRACT

Predicting the remaining useful life (RUL) of equipment plays an important role in developing maintenance methods based on equipment condition, reducing system downtime, improving reliability and safety. This study proposes a model to predict the remaining lifetime of rotating electrical machines using a deep learning approach. First, time series data are obtained from sensors attached to the electrical machine that measure variation of the vibration. This dataset is used to train a convolutional neural network hybridized with long short-term memory (CNN-LSTM) architecture. Applying a model based on a hybrid of CNN and LSTM has yielded superior results compared to traditional models. These results can be beneficial for optimizing maintenance schedules and improving the overall efficiency of systems consisting of multiple rotating electrical machines.

**Keywords:** RUL; deep learning; CNN; LSTM; vibration.

<sup>1</sup>Khoa Điện, Trường Đại học Bách Khoa, Đại học Đà Nẵng

<sup>2</sup>Khoa Quản lý Dự án, Trường Đại học Bách khoa, Đại học Đà Nẵng

\*Email: nhshung@dut.udn.vn

Ngày nhận bài: 17/4/2024

Ngày nhận bài sửa sau phản biện: 18/5/2024

Ngày chấp nhận đăng: 25/7/2024

## KÝ HIỆU

Ký hiệu

N

Ý nghĩa

Số lượng mẫu trong tập dữ liệu

$y_j$

Giá trị thực tế của mẫu thứ j

$\hat{y}_j$

Giá trị dự đoán của mô hình cho mẫu thứ j

**CHỮ VIẾT TẮT**

RUL	Thời gian sử dụng hữu ích còn lại (Remaining useful life)
RMSE	Sai số trung bình bình phương (Root mean squared error)
MAPE	Sai số phần trăm tuyệt đối trung bình (Mean absolute percentage error)
CNN	Mạng thần kinh tích chập (Convolutional Neural Network)
LSTM	Bộ nhớ dài - ngắn hạn (Long Short-Term Memory)

**1. GIỚI THIỆU**

Việc xác định lỗi và ước tính chính xác thời gian sử dụng hữu ích còn lại (RUL) của máy điện quay có vai trò then chốt trong việc bảo trì dự đoán. Nhiều nhà nghiên cứu đưa ra các giải pháp xác định lỗi và dự đoán RUL của máy điện quay để giúp nâng cao hiệu quả trong việc bảo trì dự đoán, tăng độ tin cậy và giảm tỷ lệ hỏng hóc cũng như chi phí sửa chữa liên quan. Các mô hình xác định lỗi và dự đoán RUL hiện tại thường được xây dựng dựa trên hai cách tiếp cận: dựa trên mô hình và dựa trên dữ liệu [1, 2]. Theo tiếp cận đầu tiên, các phương pháp chủ yếu dựa vào một mức độ hiểu biết vật lý nhất định về sự suy thoái thiết bị để xác định lỗi và dự đoán RUL, chẳng hạn như sử dụng các lý thuyết về định luật Paris để xác định phương hướng tăng trưởng trong quá trình suy thoái của thiết bị [3] và các quy luật về độ tin cậy [4, 5, 6]. Tuy nhiên, việc sử dụng các kiến thức vật lý vào các mô hình có thể gặp phải nhiều thách thức, đặc biệt đối với các máy móc có kết cấu phức tạp, khi mà việc mô tả mô hình suy thoái phụ thuộc nhiều yếu tố ngẫu nhiên.

Sự ra đời của công nghệ Internet vạn vật (IoT) đã nâng cao khả năng giám sát và thu thập dữ liệu sử dụng cho việc xác định lỗi và RUL của thiết bị. Nguồn dữ liệu này đã hỗ trợ đáng kể việc áp dụng phương pháp dựa trên dữ liệu để phát hiện lỗi và RUL. Không giống phương pháp mô hình hóa, phương pháp dựa trên dữ liệu chủ yếu dựa vào dữ liệu được thu thập, cho phép ứng dụng nó vào các máy/hệ thống phức tạp mà không cần điều kiện tiên quyết là phải có kiến thức vật lý sâu rộng. Machine Learning (ML) là một phương pháp dựa trên nguồn dữ liệu phổ biến đã được sử dụng phổ biến trong việc xác định lỗi và dự đoán thời gian sử dụng hữu ích còn lại (RUL) của máy điện quay. Các nghiên cứu [7, 8, 9], đã sử dụng các mô hình ML nổi tiếng như Máy vectơ hỗ trợ (SVM), Hồi quy tuyến tính (LR) và Rừng ngẫu nhiên (RF) để

xác định lỗi và dự báo RUL. Tuy nhiên, các phương pháp này mắc phải một số nhược điểm đáng kể, chẳng hạn như hiệu suất dưới mức tối ưu do các công thức toán học không linh hoạt và các phép tính tốn thời gian cho dữ liệu đầu vào lớn. Do đó, đang có một xu hướng thay đổi đáng kể theo hướng kỹ thuật học sâu (DL) để thay thế các kỹ thuật học máy truyền thống.

Một số mô hình học sâu với các lớp mạng nơ-ron đơn giản đã được đề xuất để xác định lỗi và dự đoán thời gian sử dụng hữu ích còn lại (RUL) của máy. Liên quan đến việc chẩn đoán lỗi, sử dụng biến đổi wavelet để tạo ảnh phổ 2 chiều, sau đó sử dụng học sâu để chẩn đoán lỗi động cơ đã được nghiên cứu rộng rãi [10, 11, 12]. Nghiên cứu [13] đã ứng dụng mạng CNN để thực hiện chẩn đoán lỗi cho động cơ, tuy nhiên việc khởi tạo các tham số đầu vào của quá trình huấn luyện vẫn chưa được tác giả giải thích rõ ràng. Trong khi đó, một bộ nhớ dài - ngắn hạn hai chiều (Bi-LSTM), được giới thiệu bởi Huang vào năm 2019 [14] để thực hiện việc dự đoán RUL. Mô hình Bi-LSTM gồm 2 khối với các lớp được kết nối đầy đủ và lớp hồi quy tuyến tính. Tính năng độc đáo của các thành phần Bi-LSTM là có thể nắm bắt đồng thời cả thông tin quá khứ và tương lai, giúp cải thiện độ chính xác của RUL ước lượng. Một nghiên cứu mới gần đây trong lĩnh vực này là Mạng đơn vị tái phát có cổng kết nối tăng cường tự chú ý (SACGNet) được giới thiệu bởi Xu vào năm 2022 [15]. Nghiên cứu chỉ ra việc kết hợp các cơ chế tự chú ý giúp mô hình tập trung vào thông tin quan trọng, từ đó góp phần nâng cao hiệu quả trong việc dự đoán RUL.

Trong nghiên cứu này, chúng tôi đã đồng thời thực hiện việc chẩn đoán lỗi động cơ và dự đoán trạng thái vận hành của động cơ để phục vụ dự đoán RUL. Phương pháp chẩn đoán và dự đoán trạng thái vận hành của động cơ dựa trên phân tích tín hiệu rung động kết hợp với mạng học sâu (CNN) và mạng nơ-ron tích chập lai với kiến trúc bộ nhớ dài - ngắn hạn (CNN-LSTM). Để đạt được mục tiêu này, nghiên cứu đã xây dựng một mô hình thực nghiệm để thu thập tín hiệu rung động của động cơ, tập trung vào lỗi lệch trục. Dữ liệu rung động sau đó được tiền xử lý thông qua việc lọc nhiễu. Sau khi xử lý, dữ liệu tiếp tục được chuyển qua mô hình mạng CNN và CNN-LSTM để thực hiện việc chẩn đoán lỗi và dự đoán trạng thái vận hành của động cơ.

Các phần nội dung còn lại của bài báo được kiến trúc như sau: Phần 2 trình bày mô hình sử dụng trong các thí nghiệm, quá trình xây dựng phương pháp để phát hiện lỗi lệch trục và phương pháp để theo dõi trạng thái của động cơ. Phần 3 mô tả các bước thu thập dữ liệu và chuẩn

hóa dữ liệu phục vụ quá trình đào tạo. Ngoài ra, các kết quả trong việc sử dụng mạng CNN để chẩn đoán lỗi và sử dụng mạng lai CNN-LSTM để dự đoán trạng thái của động cơ cũng được trình bày trong phần này. Cuối cùng, các kết luận của nghiên cứu được trình bày trong phần 4.

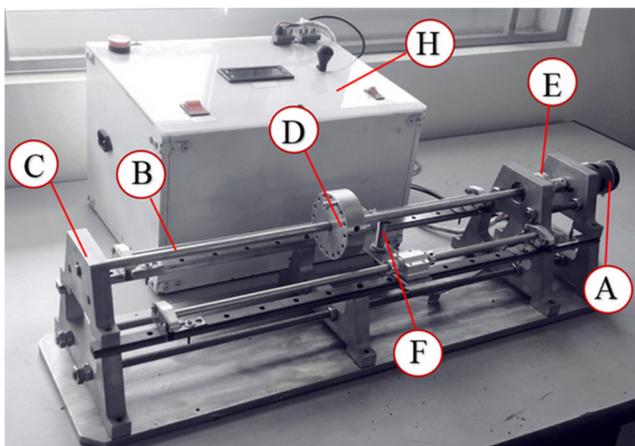
## 2. PHƯƠNG PHÁP NGHIÊN CỨU

### 2.1. Mô hình thực nghiệm

Hình 1 mô tả mô hình thực nghiệm được sử dụng phục vụ nghiên cứu. Mô hình thử nghiệm tương đối đơn giản gồm: 1 động cơ DC, 1 trục quay, 2 vòng bi, 1 khớp nối, 1 đĩa nặng được gắn trên trục động cơ, các cảm biến đo dao động và một bộ điều khiển.

Trong mô hình thử nghiệm này, tốc độ quay tối đa của động cơ có thể đạt 12.000 vòng/phút. Trục quay có đường kính 10mm được đỡ bởi hai vòng bi và nối với động cơ thông qua khớp nối. Để đo dao động của trục, một cảm biến tiệm cận cảm ứng được lắp đặt theo chiều dọc. Trong thiết lập kịch bản thí nghiệm, chúng tôi sử dụng cảm biến tiệm cận điện cảm để thu thập dữ liệu dao động của trục.

Để tạo ra sự mất cân bằng của trục truyền động gắn với động cơ, một đĩa nặng được gắn trực tiếp trên trục truyền động. Bề mặt của đĩa nặng hình tròn có đường kính 75mm và độ dày 25mm.



Hình 1. Mô hình sử dụng trong các thí nghiệm

(A) Động cơ; (B) Trục; (C) Vòng bi; (D) Đĩa nặng; (E) Bàn phím; (F) Cảm biến tiệm cận điện cảm; (H) tủ điện.

### 2.2. Mạch thu thập dữ liệu

#### 2.2.1. Sơ đồ khối hệ thống

Hệ thống được cấu thành bởi bộ phận sau:

- Arduino Nano: Nhận tín hiệu từ bảng điều khiển và từ Arduino Mega để điều khiển tốc độ động cơ.

- Cảm biến tiệm cận Analog: Cảm biến này được sử dụng để đo sự dao động của trục. Nó đánh giá một tín hiệu tương tự, thường là dải điện áp, để biểu thị giá trị đo

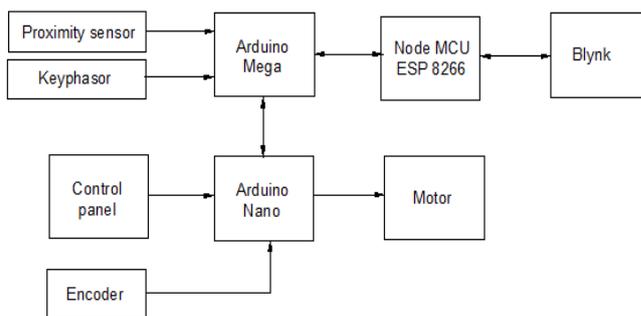
được. Tín hiệu này được gửi đến Arduino để xử lý thông qua bộ chuyển đổi.

- Keyphasor: Đây là một loại cảm biến thu tín hiệu số để xác định góc pha quay của thiết bị, chúng thường được sử dụng làm tín hiệu tham chiếu hoặc tín hiệu cơ sở có góc pha 0° cho hệ thống.

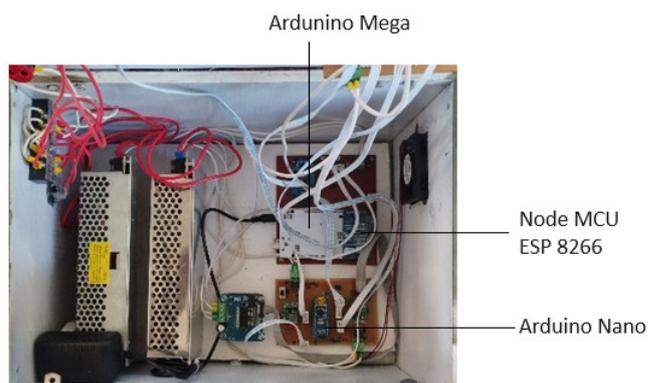
- Arduino Mega: Đây là bảng điều khiển nhận tín hiệu từ Arduino Nano, cảm biến tiệm cận analog và bộ pha phím. Sau đó, nó xử lý các tín hiệu này để gửi đến Blynk.

- NodeMCU: NodeMCU cho phép kết nối và liên lạc Wi-Fi thông qua giao thức TCP/IP. Thiết bị này sử dụng để thực hiện giám sát và điều khiển hệ thống từ xa.

- Blynk là ứng dụng thông minh giúp người sử dụng dễ dàng tương tác với các bộ điều khiển vi mô thông qua Internet. Ứng dụng Blynk tạo giao diện để điều khiển và giám sát hệ thống từ xa trên nhiều thiết bị. Ngoài ra, nó thực hiện lưu trữ dữ liệu để sử dụng cho mục đích phân tích tín hiệu.



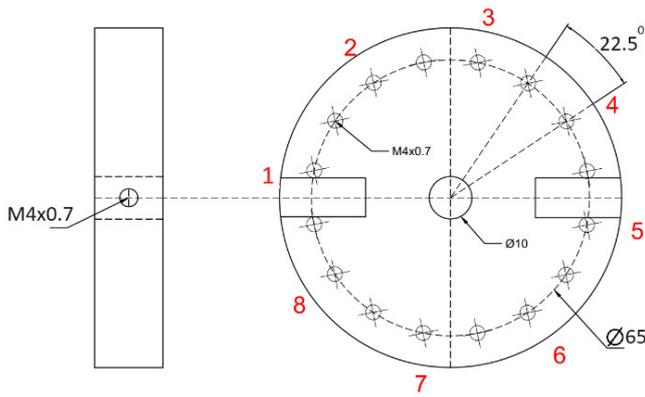
Hình 2. Sơ đồ khối hệ thống



Hình 3. Sơ đồ mạch thực tế

#### 2.2.2. Thu thập tín hiệu từ mô hình thu thập dữ liệu

Cảm biến tiệm cận được đặt cách ổ bi 20cm, còn Keyphasor được đặt gần rãnh nhỏ trên đĩa, sát với vị trí của động cơ. Ở trạng thái vận hành bình thường, không có vật nặng nào được đặt lên đĩa nặng. Tuy nhiên, để gây ra hiện tượng lệch trục trong thí nghiệm, một vật nặng sẽ được đặt từ vị trí 1 đến 8 như trên hình 4.



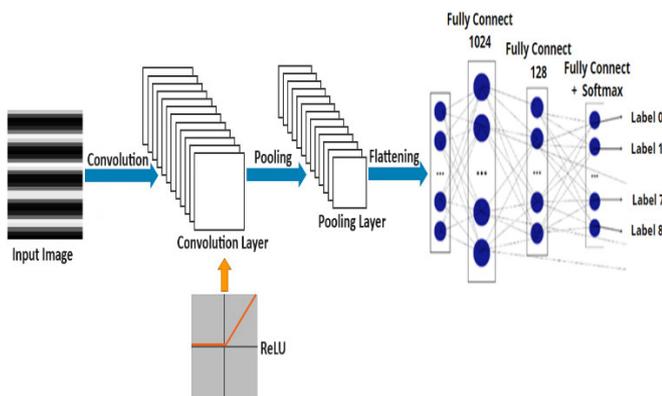
Hình 4. Vị trí của các khối lệch trục trên đĩa quay

Vị trí 1 song song với cảm biến, góc lệch tương đối giữa vị trí 1 và cảm biến là 0°, các vị trí tiếp theo lệch nhau 45°, vật nặng được đặt trên đĩa sẽ được thay đổi khối lượng trong từng thí nghiệm cụ thể:

- Thí nghiệm 1: Không có vật nặng đặt trên đĩa nặng ứng với trường hợp động cơ hoạt động bình thường.
- Thí nghiệm 2: Vật nặng  $m = 14g$  đặt trên đĩa nặng di chuyển các vị trí từ 1 đến 8.
- Thí nghiệm 3: Vật nặng  $m = 18g$  đặt trên đĩa nặng di chuyển các vị trí từ 1 đến 8.
- Thí nghiệm 4: Vật nặng  $m = 22g$  đặt trên đĩa nặng di chuyển các vị trí từ 1 đến 8.

### 2.3. Mạng lưới thần kinh chuyển đổi được đề xuất để chẩn đoán vị trí điểm lệch

Trong nghiên cứu này, mạng nơ-ron chuyển đổi với nhiều lớp tích chập (CNN) được đề xuất để tối ưu hóa nhiệm vụ phân loại lỗi như minh họa hình 5.



Hình 5. Mô hình mạng CNN thực hiện phân loại lỗi

Mô hình CNN bao gồm: các lớp tích chập, các lớp gộp và các lớp được kết nối đầy đủ. Để giảm kích thước của bản đồ đặc trưng, sau mỗi lớp tích chập chúng tôi sử dụng lớp tổng hợp. Sau lớp tích chập và lớp gộp, chúng tôi sử dụng lớp được kết nối đầy đủ để thực hiện nhiệm vụ phân loại.

- Flatten Layer: Lớp này được sử dụng để làm phẳng đầu vào của mô hình. Đây là một bước thiết yếu để chuyển đổi dữ liệu đa chiều (ví dụ: hình ảnh) thành vectơ một chiều để cung cấp cho các lớp dày đặc tiếp theo.

- Dense Layer 1: Đây là lớp được kết nối đầy đủ với 1024 đơn vị (nơ-ron) và chức năng kích hoạt ReLU. Lớp này thực hiện tính toán tuyến tính trên đầu vào và áp dụng hàm ReLU để tạo đầu ra phi tuyến tính.

- Dense Layer 2: Lớp này cũng là lớp được kết nối đầy đủ với 128 đơn vị và chức năng kích hoạt ReLU. Nó tiếp tục tính toán tuyến tính trên đầu vào từ lớp trước và áp dụng hàm ReLU.

- Dense Layer 3: Lớp này là lớp cuối cùng của mô hình, bao gồm 9 đơn vị và chức năng kích hoạt softmax. Lớp này thực hiện phân loại đầu ra thành chín lớp khác nhau, hàm softmax được sử dụng để tính xác suất phân loại cho mỗi lớp.

Mô hình được xây dựng dựa trên kiến trúc mạng nơ-ron truyền thẳng, trong đó các đơn vị nơ-ron trong các lớp Mật độ cao được kết nối hoàn toàn với nhau. Các hàm kích hoạt ReLU và softmax được sử dụng để tạo ra đầu ra phi tuyến tính và phân loại xác suất cho các lớp đầu ra tương ứng.

### 2.4. Mạng lưới thần kinh đề xuất dự đoán tình trạng sức khỏe của động cơ phục vụ dự đoán RUL

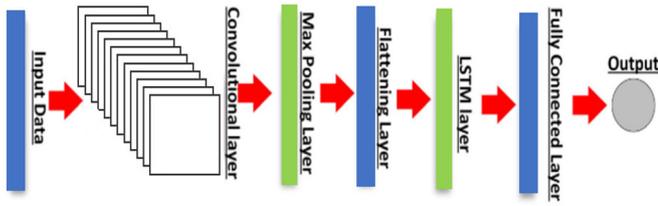
#### 2.4.1. Dữ liệu

Dữ liệu dùng để huấn luyện mô hình là tập dữ liệu thu thập được trong thí nghiệm 2 ( $m = 14g$ ). Dữ liệu sau khi thu thập sẽ được chuẩn hóa bằng phương pháp min-max và được chuyển đổi từ kiểu dữ liệu time-series sang kiểu dữ liệu phù hợp với mô hình đề xuất. Các hình ảnh và các chỉ số đánh giá mô hình sẽ được lấy từ tập dữ liệu điểm lệch 5,  $m = 14g$ .

#### 2.4.2. Mô hình mạng lưới thần kinh CNN-LSTM đề xuất

Mạng kết hợp CNN-LSTM (CNN-LSTM) là một kiến trúc mạnh mẽ kết hợp sức mạnh của mạng CNN 1D và mạng hồi quy LSTM. Sự kết hợp này làm mô hình phù hợp cho các nhiệm vụ dự đoán chuỗi thời gian, cho thấy kết quả hứa hẹn trong các ứng dụng khác nhau.

Trong mạng này, các lớp CNN 1D chịu trách nhiệm chụp các đặc tính thời gian của dữ liệu đầu vào. Đầu ra của các lớp CNN sau đó được đưa vào mạng LSTM, cho phép nó học các mối quan hệ thời gian và không gian trong dữ liệu trong khi bảo tồn thông tin quan trọng về chuỗi thời gian. Mô hình CNN-LSTM được minh họa cụ thể trong hình 6. Ba mô hình được thử nghiệm trên tập dữ liệu phía trên được trình bày trong bảng 1.



Hình 6. Mô hình kết hợp mạng CNN-LSTM

Bảng 1. Kiến trúc mô hình

Uni-LSTM100-Dense50-Dense1
Uni-Conv1D64-Dense50-Dense1
Uni-Conv1D64-LSTM4-LSTM4-Dense50-Dense1

Hai thước đo dùng để đánh giá mô hình là:

RMSE (sai số trung bình bình phương):

$$RMSE = \sqrt{\frac{\sum_{j=1}^N (y_j - \hat{y}_j)^2}{N}} \quad (1)$$

MAPE (sai số phần trăm tuyệt đối trung bình):

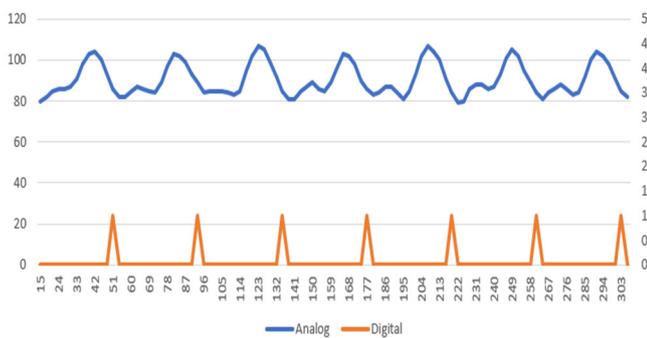
$$MAPE = \frac{100}{N} \sum_{j=1}^N \left| \frac{y_j - \hat{y}_j}{y_j} \right| \quad (2)$$

### 3. KẾT QUẢ NGHIÊN CỨU VÀ THẢO LUẬN

#### 3.1. Kết quả thu thập dữ liệu rung

##### 3.1.1. Trường hợp không có bất kỳ trọng lượng bổ sung nào được đặt trên đĩa nặng

Trường hợp không đặt thêm vật nặng lên đĩa nặng có thể coi là tương đương với hoạt động bình thường của động cơ.

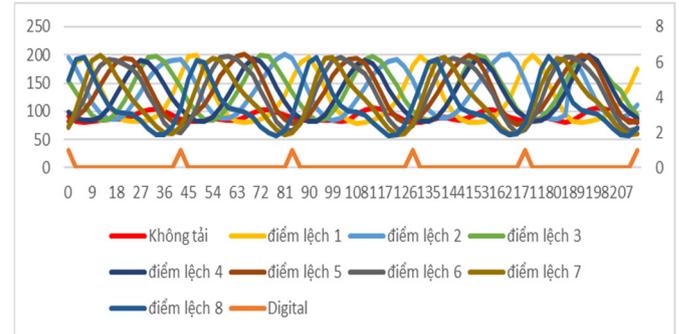


Hình 7. Đồ thị dao động của trục động cơ khi không đặt thêm vật nặng lên đĩa nặng sau khi lọc nhiễu tín hiệu

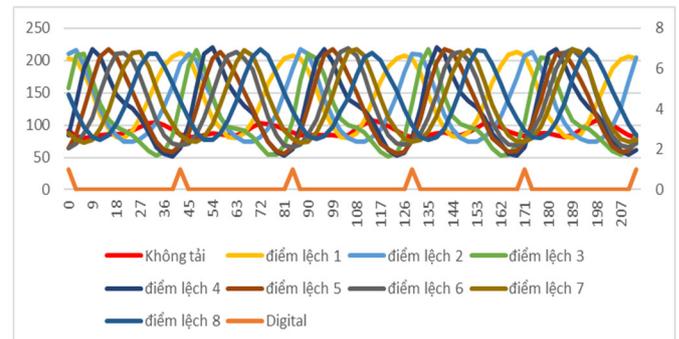
Rõ ràng, ngay cả khi động cơ hoạt động ở trạng thái bình thường vẫn xuất hiện một dao động mất cân bằng nhỏ trên trục động cơ. Có một số lý do dẫn đến sự mất cân bằng này, chẳng hạn như thiết kế trục động cơ không đồng đều hoặc ổ trục động cơ không chắc chắn trong quá trình quay, dẫn đến dao động mất cân bằng tăng lên.

##### 3.1.2. Trường hợp có khối lượng nặng đặt trên đĩa nặng tại các vị trí từ 1 đến 8

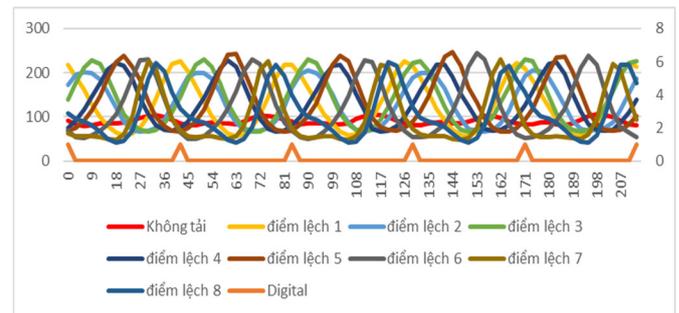
Trong trường hợp  $m = 14g$ ,  $m = 18g$  và  $m = 22g$ , các vật nặng sẽ được đặt ở các vị trí từ 1 đến 8. Tổng số mẫu mỗi trường hợp là 350.000 mẫu và kết quả đồ thị thu được sẽ được so sánh với trường hợp không đặt đĩa nặng. Kết quả tín hiệu dao động được thể hiện trong hình 8, 9 và 10. Rõ ràng, khi đặt thêm trọng lượng vào thì biên độ dao động tăng lên đáng kể, tần số dao động cũng cao hơn so với trạng thái bình thường.



Hình 8. Dữ liệu dao động của trục động cơ khi vật nặng khối lượng  $m = 14g$  thay đổi từ vị trí 1 đến 8



Hình 9. Dữ liệu dao động của trục động cơ khi vật nặng khối lượng  $m = 18g$  thay đổi từ vị trí 1 đến 8



Hình 10. Dữ liệu dao động của trục động cơ khi vật nặng khối lượng  $m = 22g$  thay đổi từ vị trí 1 đến 8

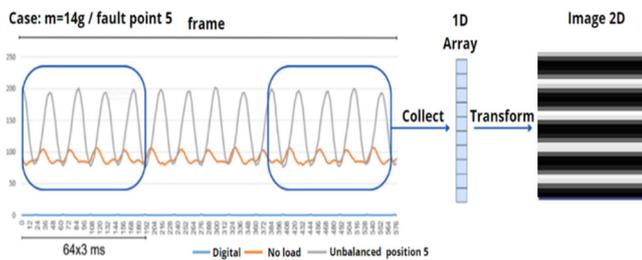
##### 3.1.3. Phân tích tiền xử lý dữ liệu đầu vào mô hình phân loại

Dữ liệu sau khi thu thập được sẽ qua các bước tiền xử lý để chuẩn hóa dữ liệu làm đầu vào. Dữ liệu mạng CNN

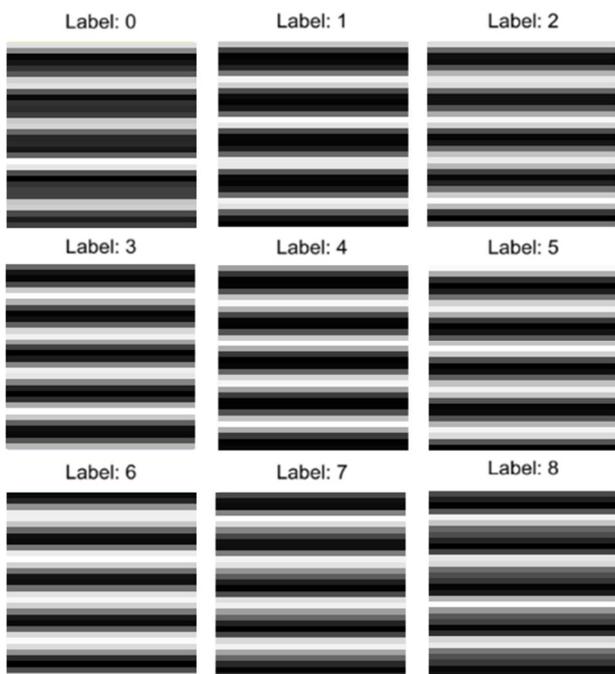
sẽ được chuyển sang mảng 2D trong khi đó dữ liệu vào mạng CNN-LSTM vẫn được dữ nguyên ở dạng 1D.

**3.1.4. Chuyển dữ liệu từ mảng 1D sang mảng 2D.**

Trong mô hình chẩn đoán lỗi, tập dữ liệu rung sau khi lọc nhiễu sẽ được chuyển về dạng ảnh 2D. Quá trình thực hiện chuyển đổi như sau, từ tín hiệu dao động, chúng tôi phân thành các phần có phạm vi tương ứng là 192ms để thực hiện chuyển ảnh 2D. Hình 11 hiển thị các hình ảnh 2D mẫu trong bộ dữ liệu được xây dựng cho từng loại lỗi tại các vị trí khác nhau của vật nặng với khối lượng khác nhau. Kết quả thu được gồm 600 hình ảnh đặc trưng cho trạng thái hoạt động bình thường và 24.000 hình ảnh đặc trưng cho trạng thái hoạt động tại các vị trí lỗi (3.000 hình ảnh cho mỗi vị trí bị lỗi, với 1.000 hình ảnh lỗi tương ứng với mỗi vật nặng có khối lượng m), tổng số cộng có 24.600 hình ảnh.



Hình 11. Quá trình thực hiện chuyển đổi dữ liệu analog sang định dạng hình ảnh 2D



Hình 12. Các nhãn điểm lỗi

Quá trình thực hiện chuyển đổi tín hiệu rung thành hình ảnh 2D được áp dụng cho tất cả các mẫu trong tập

dữ liệu. Sau đây, các nhãn lỗi được đánh số từ 0 đến 8 như trong hình 12.

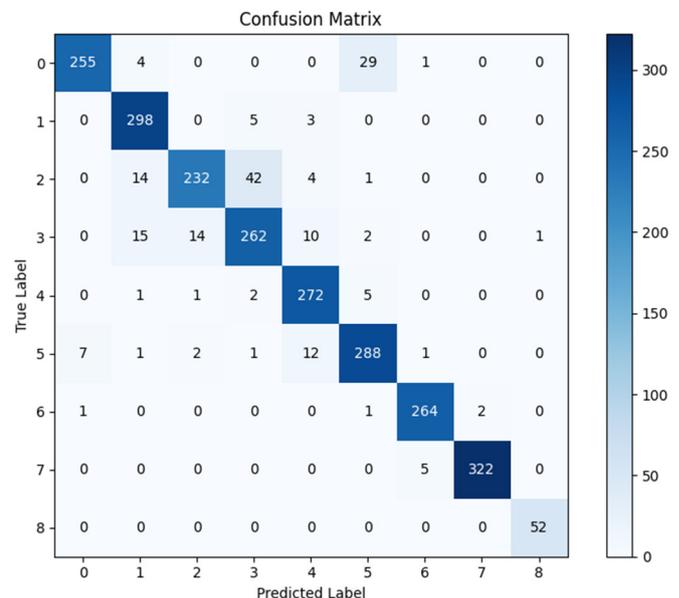
**3.2. Kết quả và bàn luận mạng CNN được đề xuất để chẩn đoán vị trí điểm lệch**

Để đánh giá độ chính xác, mô hình đã được chạy trên tập test. Kết quả thu được ma trận sai số ở hình 13 với các kết quả như sau:

- Accuracy (độ chính xác tổng quát): 92%;
- Precision (độ chính xác với các lớp dương): 98%;
- Recall (độ bao phủ đối với các dự đoán về lớp dương): 98%;
- F1-score (trung bình điều hòa giữa precision và recall): 99%;

Ma trận sai số biểu thị số lượng nhãn dự đoán của mô hình so với nhãn đúng. Chúng tôi nhận thấy tỉ lệ phân loại chính xác của mô hình ở mức tốt 92% trên tập test. Trường hợp phân loại sai nhiều nhất xuất hiện khi mô hình phân loại là nhãn 3 với 42 lần phân loại sai nhãn 3 nhầm thành nhãn 2.

Từ kết quả thu được ta thấy mô hình đề xuất có thể học được các đặc trưng khá tốt với độ chính xác của mô hình huấn luyện trên 90%. Quá trình khử nhiễu và chuẩn hóa dữ liệu ở giai đoạn tiền xử lý có vai trò quan trọng trong huấn luyện mô hình khi có thể giúp tăng độ chính xác.



Hình 13. Ma trận sai số trên tập test của mô hình

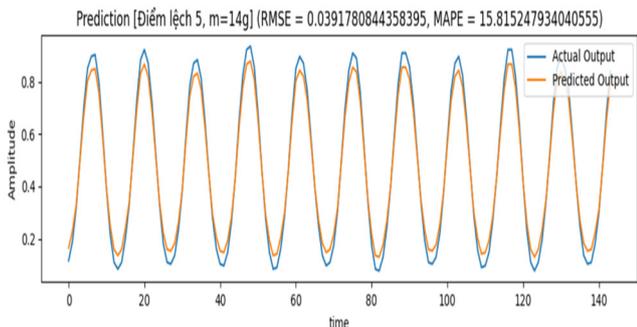
**3.3. Kết quả và bàn luận mạng nơ-ron lai CNN-LSTM để xuất dự đoán tín hiệu**

Bảng 2 là kết quả của ba mô hình được đề cập với tập dữ liệu điểm lệch 5, m = 14g với hai phương pháp đánh giá RMSE và MAPE.

Bảng 2. Bảng kết quả RMSE và MAPE ứng với các mô hình

Mô hình	RMSE	MAPE
Uni-LSTM100-Dense50-Dense1	0,553	98,848
Uni-Conv1D64-Dense50-Dense1	0,0429	16,307
Uni-Conv1D64-LSTM4-LSTM4-Dense50-Dense1	0,0392	15,815

Biểu đồ hình 14 thể hiện dự đoán trong 140 đơn vị thời gian tiếp theo (mỗi đơn vị thời gian tương ứng với 3ms) của mô hình có giá trị RMSE và MAPE thấp nhất.



Hình 14. Biểu đồ giá trị thực tế và giá trị dự đoán với mô hình Uni-Conv1D64-LSTM4-LSTM4-Dense50-Dense1

Các kết quả đánh giá của ba mô hình (mô hình truyền thống LSTM và CNN so với mô hình đề xuất CNN-LTSM) trên với tập dữ liệu thu thập được lần lượt như sau: Mô hình LSTM (Uni-LSTM100-Dense50-Dense1) có kết quả không tốt và thấp hơn nhiều so với mô hình CNN (Uni-Conv1D64-Dense50-Dense1) với giá trị MAPE là 98,848 của LSTM và 16,307 của CNN. Và sự kết hợp giữa CNN và LSTM (Uni-Conv1D64-LSTM4-LSTM4-Dense50-Dense1) đã cho kết quả tốt nhất với giá trị RMSE và MAPE lần lượt là 0,0392 và 15,815.

Từ kết quả trên, có thể thấy một cách tiếp cận mới trong quá trình dự đoán tín hiệu của động cơ thông qua các mô hình lai CNN-LSTM. Các kết quả dự đoán tín hiệu động cơ đều có các giá trị RMSE và MAPE khá tốt trên các tập dữ liệu đo khác nhau khi sử dụng kiến trúc mô hình CNN-LSTM (Uni-Conv1D64-LSTM4-LSTM4-Dense50-Dense1). Việc sử dụng dự đoán được trạng thái hoạt động của động cơ điện là cơ sở để thực hiện dự báo RUL.

#### 4. KẾT LUẬN

Việc chẩn đoán lỗi và theo dõi tình trạng hoạt động của máy điện quay theo tiếp cận học sâu vẫn còn khá mới mẻ ở Việt Nam. Bài báo này đã thực hiện việc chẩn đoán lỗi lệch trục của động cơ bằng việc sử dụng mạng CNN đồng thời theo dõi trạng thái hoạt động của động cơ dựa trên mạng lai CNN-LSTM. Kết quả chẩn đoán lỗi cho độ chính xác 92% trong khi việc dự đoán trạng thái của máy điện cũng tương đối chính xác với mức độ sai số RMSE là

0,0392. Kết quả thu được cho thấy các mô hình của chúng tôi hoạt động tốt và có thể là lựa chọn đầy hứa hẹn cho các ứng dụng bảo trì dự đoán. Trong tương lai, chúng tôi mong muốn kiểm tra tính mạnh mẽ và hiệu suất của các mô hình đề xuất trên các ứng dụng thực tế. Chúng tôi có kế hoạch mở rộng mô hình để kết hợp các nguồn dữ liệu bổ sung, chẳng hạn như nguồn dữ liệu dữ liệu âm thanh của máy hay tham khảo ý kiến chuyên gia.

#### LỜI CẢM ƠN

Nghiên cứu này được tài trợ bởi Bộ Giáo dục và Đào tạo trong đề tài có mã số: B2024.DNA.18.

#### TÀI LIỆU THAM KHẢO

- [1]. Ferreira C., Gonçalves G., "Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods," *Journal of Manufacturing Systems*, 63, 550-562, 2022.
- [2]. Chen J., Lin C., Peng D., Ge H., "Fault diagnosis of rotating machinery: A review and bibliometric analysis," *IEEE Access*, 8, 224985-225003, 2020.
- [3]. Li Y., Kurfess T. R., Liang S. Y., "Stochastic prognostics for rolling element bearings," *Mechanical Systems and Signal Processing*, 14(5), 747-762, 2000.
- [4]. Behzad M., Arghan H. A., Bastami A. R., Zuo M. J., "Prognostics of rolling element bearings with the combination of paris law and reliability method," In *2017 Prognostics and System Health Management Conference (PHM-Harbin)*, 1-6, IEEE, 2017.
- [5]. Zhang J. X., Du D. B., Si X. S., Liu Y., Hu C. H., "Prognostics based on stochastic degradation process: The last exit time perspective," *IEEE Transactions on Reliability*, 70(3), 1158-1176, 2021.
- [6]. Zhang S., Zhai Q., Shi X., Liu X., "A Wiener process model with dynamic covariate for degradation modeling and remaining useful life prediction," *IEEE Transactions on Reliability*, 72(1), 214-223, 2022.
- [7]. Singh J., Azamfar M., Li F., Lee J., "A systematic review of machine learning algorithms for prognostics and health management of rolling element bearings: fundamentals, concepts and applications," *Measurement Science and Technology*, 32(1), 012001, 2020.
- [8]. Wu D., Jennings C., Terpenney J., Gao R. X., Kumara S., "A comparative study on machine learning algorithms for smart manufacturing: tool wear prediction using random forests," *Journal of Manufacturing Science and Engineering*, 139(7), 071018, 2017.
- [9]. Sharp M., Ak R., Hedberg Jr T., "A survey of the advancing use and development of machine learning in smart manufacturing," *Journal of manufacturing systems*, 48, 170-179, 2018.
- [10]. Sangeetha P., Hemamalini S., "Dyadic wavelet transform-based acoustic signal analysis for torque prediction of a three-phase induction motor," *IET Signal Processing*, 11(5), 604-612, 2017.

[11]. Xia M., Li T., Xu L., Liu L., De Silva C. W., "Fault diagnosis for rotating machinery using multiple sensors and convolutional neural networks," *IEEE/ASME transactions on mechatronics*, 23(1), 101-110, 2017.

[12]. Wen L., Gao L., Li X., "A new deep transfer learning based on sparse auto-encoder for fault diagnosis," *IEEE Transactions on systems, man, and cybernetics: systems*, 49(1), 136-144, 2017.

[13]. Kumar A., Gandhi C. P., Zhou Y., Kumar R., Xiang J., "Improved deep convolution neural network (CNN) for the identification of defects in the centrifugal pump using acoustic images," *Applied Acoustics*, 167, 107399, 2020.

[14]. Huang C. G., Huang H. Z., Li Y. F., Peng W., "A novel deep convolutional neural network-bootstrap integrated method for RUL prediction of rolling bearing," *Journal of Manufacturing Systems*, 61, 757-772, 2021.

[15]. Xu J., Duan S., Chen W., Wang D., Fan Y., "A remaining useful life prediction of bearing with self-attention augmented convolution GRU network," *Lubricants*, 10(2), 21, 2022.

---

#### AUTHORS INFORMATION

**Nguyen Ho Si Hung<sup>1</sup>, Nguyen Thi Kim Truc<sup>1</sup>, Nguyen Kim Anh<sup>1</sup>,  
Luu Manh Tien<sup>1</sup>, Tran Thi Hoang Giang<sup>2</sup>**

<sup>1</sup>Faculty of Electrical Engineering, University of Science and Technology - University of Da Nang, Vietnam

<sup>2</sup>Faculty of Project Management, University of Science and Technology - University of Da Nang, Vietnam