

## Ứng dụng mạng nơ-ron trong chẩn đoán lỗi động cơ dựa trên tín hiệu độ rung

Nguyễn Đức Thành<sup>1</sup>, Trần Hoài Linh<sup>1</sup>, Nguyễn Công Phương<sup>1</sup>, Phạm Văn Nam<sup>2\*</sup>

<sup>1</sup>Trường Điện - Điện tử, Đại học Bách khoa Hà Nội, Số 1 Đại Cồ Việt, Hai Bà Trưng, Hà Nội, Việt Nam;

<sup>2</sup>Đại học Công nghiệp Hà Nội, Bắc Từ Liêm, Hà Nội, Việt Nam.

\*Email: nampv@hau.edu.vn

Nhận bài: 16/02/2024; Hoàn thiện: 02/4/2024; Chấp nhận đăng: 02/4/2024; Xuất bản: 22/04/2024.

DOI: <https://doi.org/10.54939/1859-1043.j.mst.94.2024.22-30>

### TÓM TẮT

Bài báo này nghiên cứu và áp dụng trí tuệ nhân tạo nơ-ron (AI) để cải thiện quá trình giám sát và chẩn đoán lỗi động cơ điện dựa trên tín hiệu độ rung. Mục tiêu của nghiên cứu là tự xây dựng một mô hình để thu thập dữ liệu mẫu từ động cơ và sử dụng 3 mạng AI khác nhau trong nghiên cứu này bao gồm YOLO (You Only Look Once), Resnet (Residual neural network) và SVM (Support Vector Machine). Ứng dụng để xây dựng các mô hình nhận dạng độc lập có cùng chung tín hiệu đầu vào là độ rung để xác định các lỗi trong hệ thống có sử dụng động cơ, bài báo tập trung khảo sát các lỗi liên quan đến vòng bi. Kết quả thử nghiệm được trình bày trong bài báo cho thấy tính chính xác của việc sử dụng các mạng này trong việc chẩn đoán lỗi động cơ và đưa ra các nhận xét quan trọng về độ chính xác của các mạng AI và khả năng áp dụng thực tế trong lĩnh vực bảo trì và quản lý thiết bị công nghiệp.

**Từ khóa:** Lỗi động cơ; YOLO; Resnet; SVM; Biến đổi Fourier STFT.

### 1. MỞ ĐẦU

Hiện tại, hầu hết các thiết bị giám sát và cảnh báo cho động cơ trong các nhà máy đều được lắp đặt một cách rời rạc, chỉ giám sát một vài thông số điện, hầu như không có thu thập dữ liệu để theo dõi phân tích. Việc kiểm tra và theo dõi, giám sát phân tích các thông số động cơ online chưa được thực hiện một cách thường xuyên là liên tục, không có khả năng đưa ra kế hoạch bảo trì động cơ tự động, dẫn đến việc không phát hiện ra các hỏng hóc không mong muốn, các hỏng hóc của động cơ nếu không được theo dõi đúng mức sẽ dẫn đến phá hủy máy nghiêm trọng, đòi hỏi chi phí cao trong sửa chữa hoặc thậm chí thay thế động cơ mới. Tuy nhiên, nếu tình trạng được theo dõi thường xuyên, các hư hỏng tiềm tàng có thể được theo dõi và khắc phục sớm, khi đó, việc sửa chữa sẽ đơn giản hơn, nhanh hơn và rẻ hơn. Do vậy, nghiên cứu, thiết kế chế tạo và thử nghiệm hệ thống kiểm tra, giám sát, dự đoán lỗi cho động cơ điện sử dụng công nghệ thông minh IOT (Internet of Things technology) trong các nhà máy là cần thiết và thiết thực. Bên cạnh đó, việc thu thập dữ liệu (các thông số điện năng, độ rung, âm thanh, hình ảnh,...) sẽ được lưu trữ để bổ sung dữ liệu kết hợp với phần mềm thông minh nhằm phục vụ việc chẩn đoán, ứng dụng các mô hình trí tuệ nhân tạo và là xu hướng của cuộc cách mạng công nghiệp lần thứ 4.

Bài toán nhận dạng sự cố động cơ có nhu cầu thực tiễn cao, hiện này đã có nhiều công trình nghiên cứu. Các nghiên cứu gần đây [1- 3] đã chỉ ra những thách thức và cơ hội liên quan đến việc phát triển các kỹ thuật bảo trì dựa trên máy học mạnh mẽ, đặc biệt là đối với hệ thống truyền động lực từ điện năng thành cơ năng, momen quay như ô bi, động cơ, hộp số, gô đỡ, các thiết bị này hay bị hỏng hóc, nếu không được phát hiện sớm sẽ gây các sự cố cho các động cơ điện. Ứng dụng những công nghệ mới hiện này để nâng cao độ chính xác của các mô hình máy học và tăng cường khả năng dự đoán sớm để có kế hoạch bảo trì là hướng nghiên cứu có tính thực tiễn hiện nay. Trong các nghiên cứu [5-10] đề xuất một phương pháp phát hiện bất thường cho động cơ điện dựa trên tín hiệu độ rung kết hợp với mạng nơ-ron. Họ phát triển một mô hình giám sát cho hai loại động cơ khác nhau: Động cơ công nghiệp mới và động cơ công nghiệp cũ. Họ nghiên cứu kỹ lưỡng về hiệu suất của mô hình trong việc phát hiện bất thường cho cả hai loại động cơ đã chỉ ra rằng nó

có khả năng phát hiện bất thường cao nhất đối với các điều kiện tiêu chuẩn hóa của động cơ sử dụng các đặc trưng được ánh xạ. Tuy nhiên, họ hiện đang chỉ có dữ liệu từ điều kiện bình thường của động cơ và thiếu thông tin về dữ liệu trong các điều kiện lỗi.

Trong nghiên cứu [16] trình bày một giải pháp sử dụng các đặc trưng của tín hiệu rung để làm đầu vào cho quá trình đào tạo mô hình nhận dạng. Tương tự như nhiều nghiên cứu khác, trong giai đoạn tiền xử lý dữ liệu, bài báo này giới thiệu một phương pháp gọi là Median-based Outlier Detection (MOD) để phát hiện ngoại lệ (các mẫu dữ liệu mà các đặc trưng bị ảnh hưởng bởi các yếu tố bên ngoài, không phải do lỗi và loại bỏ chúng khỏi quá trình đào tạo để cải thiện hiệu suất mô hình). Tuy nhiên, bài báo này không đề cập đến việc phân loại các loại lỗi tương tự với các kích thước lỗi khác nhau.

Trong những năm gần đây, với sự phát triển của học sâu Deep Learning (DL) ngày càng nhiều nhà nghiên cứu quan tâm đến việc sử dụng các phương pháp DL [5-12] để giải quyết các vấn đề nêu trên với nhiều phương pháp đã được áp dụng để chẩn đoán lỗi vòng bi. Mạng thần kinh tích chập (CNN) là cấu trúc mạng DL cổ điển, rất hữu ích cho việc phân loại hình ảnh [7, 8] và nhiều mô hình DL khác [10-15] đã được áp dụng rộng rãi cho các nhiệm vụ phát hiện lỗi vòng bi. Tuy nhiên, trong các mô hình DL có các lớp sâu hơn, vấn đề biến mất độ dốc sẽ xuất hiện; nghĩa là, các mô hình DL phải hy sinh hiệu năng khi chúng được huấn luyện với các lớp sâu hơn. Để giải quyết những vấn đề này, Mạng (SVM) đã được đề xuất [12] SVM sử dụng nguyên lý kết hợp tuyến tính thông qua các siêu phẳng, giúp nó hiệu quả trong việc đối mặt với dữ liệu phức tạp và không gian đa chiều; Do đó, một loạt mô hình dựa trên svm đã được đưa ra.

Phân tích tín hiệu rung là một phương pháp mới để phát hiện/chẩn đoán sớm các sự cố của động cơ. Bài báo này tập trung xây dựng một thiết bị thu thập các dữ liệu về độ rung động theo 3 chiều X, Y, Z, xây dựng một hệ thống giám sát và cảnh báo một số trường hợp sự cố của động cơ điện online từ xa, khảo sát các mạng AI khác nhau để khảo sát tính chính xác của việc chẩn đoán lỗi, nghiên cứu tiên hành phân tích lỗi dựa trên tín hiệu độ rung. Kết quả thử nghiệm được trình bày trong bài báo cho thấy tính chính xác của các mạng thành phần này trong để xây dựng các phần mềm chẩn đoán lỗi động cơ.

## **2. NỘI DUNG XÂY DỰNG HỆ THỐNG NHẬN DẠNG SỰ CỐ ĐỘNG CƠ**

### **2.1. Bộ cơ sở dữ liệu**


#### *2.1.1. Xây dựng mô hình thử nghiệm*

Xây dựng phần mềm chẩn đoán tự động trên các động cơ hoạt động trong điều kiện thực tế đặt ra các hạn chế do tính phức tạp. Phương pháp truyền thống là sử dụng tín hiệu điện năng như điện áp U và dòng điện I thường chỉ phản ánh các sự cố đã xảy ra, như quá tải và ngắn mạch, có thể sử dụng các thiết bị bảo vệ công nghiệp như relay nhiệt và aptomat. Tuy nhiên, một số sự cố có thể không thể hiện rõ qua các tín hiệu điện này mà thay vào đó lại phản ánh qua độ rung và tiếng ồn của động cơ, như:

- Sự mài mòn: Các bề mặt tiếp xúc trong động cơ có thể mòn do sử dụng lâu dài. Điều này có thể tạo ra động lực không đều, gây ra độ rung và tiếng ồn không bình thường.
- Hông hóc vòng bi: Nếu vòng bi trong động cơ bị lỏng lẻo hoặc hông hóc, nó có thể tạo ra các rung động không đều và tiếng ồn. Các biểu hiện này thường xuất hiện ở tốc độ cao và có thể được nghe rõ từ xa.
- Thiếu cân bằng: Sự thiếu cân bằng trong các bộ phận quay có thể gây ra động lực không đều khi động cơ hoạt động, dẫn đến độ rung và tiếng ồn.
- Lệnh trục: Nếu trục của động cơ không được lắp đặt đúng cách, nó có thể dẫn đến động lực không đều khi quay, tạo ra độ rung và tiếng ồn không mong muốn.

Những biểu hiện này thường là dấu hiệu của vấn đề cụ thể trong động cơ và cần được kiểm tra và sửa chữa kịp thời để tránh hỏng hóc nghiêm trọng và đảm bảo hoạt động ổn định của động cơ.

Bài báo này lựa chọn sử dụng tín hiệu độ rung để xử lý và chẩn đoán lỗi của động cơ, để thực hiện được nhóm nghiên cứu cần xây dựng một mô hình để lấy mẫu tín hiệu độ rung, xây dựng bộ cơ sở dữ liệu, phục vụ cho bài toán nhận dạng [16].



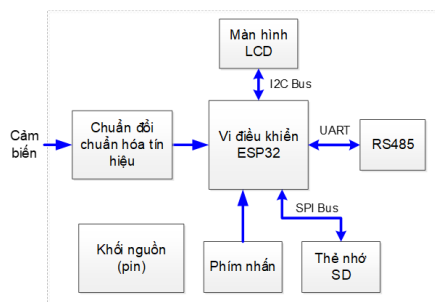
**Hình 1.** Hình ảnh mô hình thử nghiệm, vị trí đặt thiết bị đo.

Đối tượng nghiên cứu thử nghiệm có thông số như sau:

- Động cơ với 2 gối đỡ trục (như hình 1).
- Bộ phanh điện từ để tạo phụ tải cho động cơ, có thể mô-men hãm 0-100% tương ứng với tín hiệu điều chỉnh từ 0-20VDC.
- Thiết bị đo độ rung, lưu trữ trên thẻ SD và truyền tải thông qua các tiêu chuẩn giao tiếp WIFI để đào tạo mô hình trí tuệ nhân tạo, với tần số lấy mẫu là 2 kHz.

### 2.1.2. Xây dựng thiết bị thu thập dữ liệu


Dựa trên các yêu cầu công nghệ và chức năng của bộ thu thập dữ liệu, bài báo xây dựng thiết bị có sơ đồ khối như sau:



**Hình 2.** Sơ đồ khối của thiết bị.

Thiết bị bao gồm các khối chính sau:

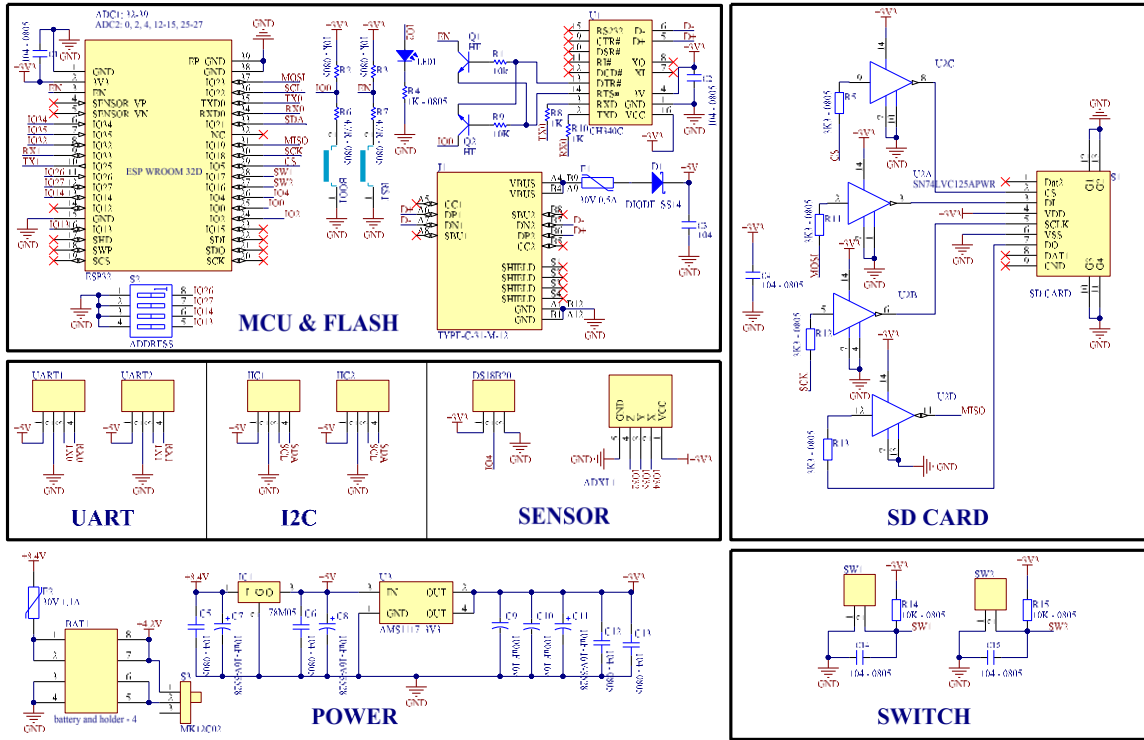
- o Cảm biến: Lựa chọn cảm biến đo độ rung ADXL335 GY-61.
- o Khối điều khiển trung tâm: Sử dụng ESP32 có chức năng tương tác với các nền tảng IoT và có tính bảo mật cao hơn ESP8266.
- o Thẻ nhớ SD: Thiết bị sẽ sử dụng các thẻ nhớ dung lượng cao 8 Gb.
- o Khối pin: Lựa chọn sử dụng 04 quả pin 18650 sạc lại được, loại 3.7 V 2000 mAh.



**Hình 3.** Cảm biến gia tốc ADXL335 GY-61 và sơ đồ khối chức năng.

**Nghiên cứu khoa học công nghệ**

ADX1335 có thể đo gia tốc trên 3 trục X, Y, Z tạo thành hệ trục tọa độ 3D. ADXL335 có khả năng đo gia tốc từ -3g đến +3g trên mỗi trục, các giá trị đo được sẽ được phản ánh ở dạng Analog. Với sai số thấp ADXL335 có độ chính xác cao trong đo gia tốc, độ rung. Chân X, Y, Z lần lượt là đầu vào analog của kích thước trục X, Y, Z. Chân này cấp tín hiệu đầu vào analog cho bộ điều khiển được đo bởi gia tốc kế ADLX 335.



**Hình 4.** Thiết kế sơ đồ nguyên lý của thiết bị đo.



**Sơ đồ thiết kế mạch in thiết bị**



**Thiết kế vị trí lắp đặt pin**

**Hình 5.** Thiết kế mạch in của thiết bị.

**2.1.3. Mô hình thực nghiệm và kết quả đo**



**Hình 6.** Hình ảnh mô hình thử nghiệm và vị trí đặt thiết bị đo.

Bài báo xây dựng tập mẫu tín hiệu độ rung, hoạt động bình thường (N) và 3 trường hợp lỗi như sau:

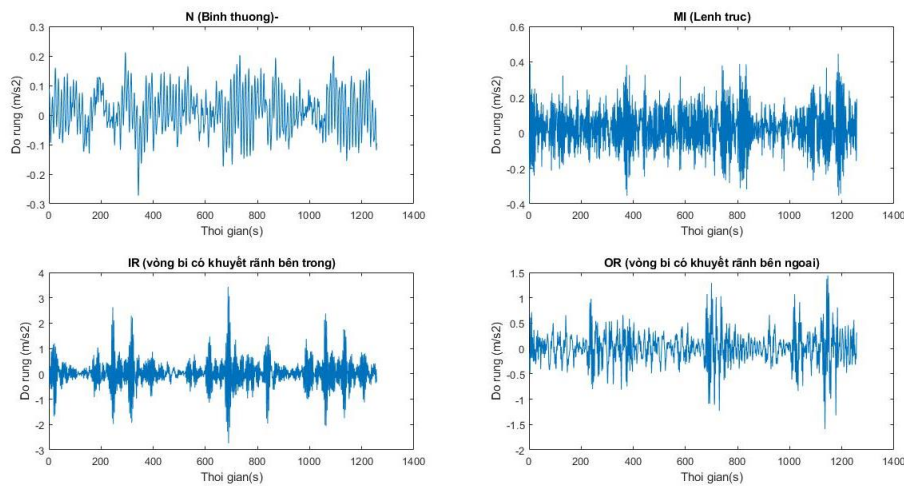
- MI: Lệch trục có thể tạo ra mô-men xoắn không đều và gây rung động.
- IR: Vòng bi có khuyết rãnh bên trong.
- OR: Vòng bi có khuyết rãnh bên ngoài.

Các ổ đỡ trục với bi và các rãnh bên trong và bên ngoài bị hư hại trên một điểm với đường kính 0.2 mm. Các tín hiệu rung động được ghi lại sử dụng cảm biến gia tốc lắp đặt tại vị trí như trên hình 6. Các tín hiệu được ghi lại trong thời gian khoảng 5 phút, tần số lấy mẫu 2 kHz, đặt cố định mô-men hãm là 50%. Dữ liệu thu thập được miêu tả cụ thể ở bảng 1 sau:

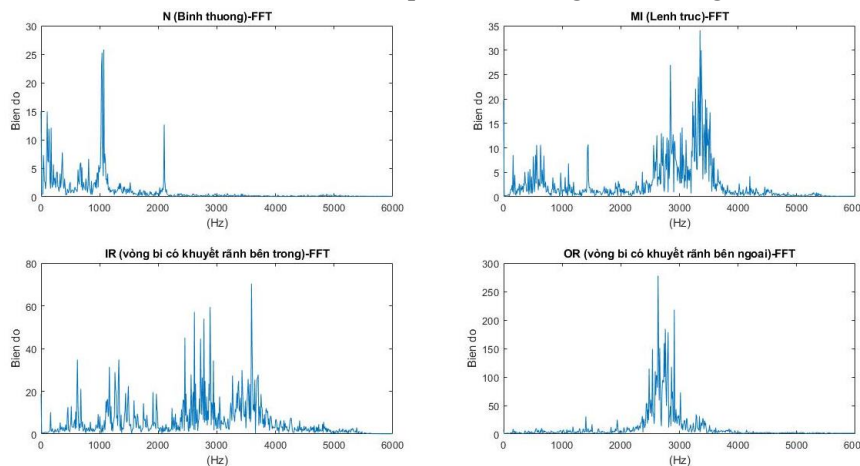
**Bảng 1.** Dữ liệu thu thập từ mô hình thực nghiệm.

Loại lỗi	Tần số trích mẫu (Hz)	Số lượng trích mẫu	Thời gian mỗi trích mẫu (phút)
N	2000	10	5
MI	2000	10	5
IR	2000	10	5
OR	2000	10	5

Dưới đây là một hình ảnh của bộ dữ liệu thu thập sau khi được biểu diễn tại miền thời gian:



**Hình 7.** Biểu đồ thể hiện tập dữ liệu trong miền thời gian.



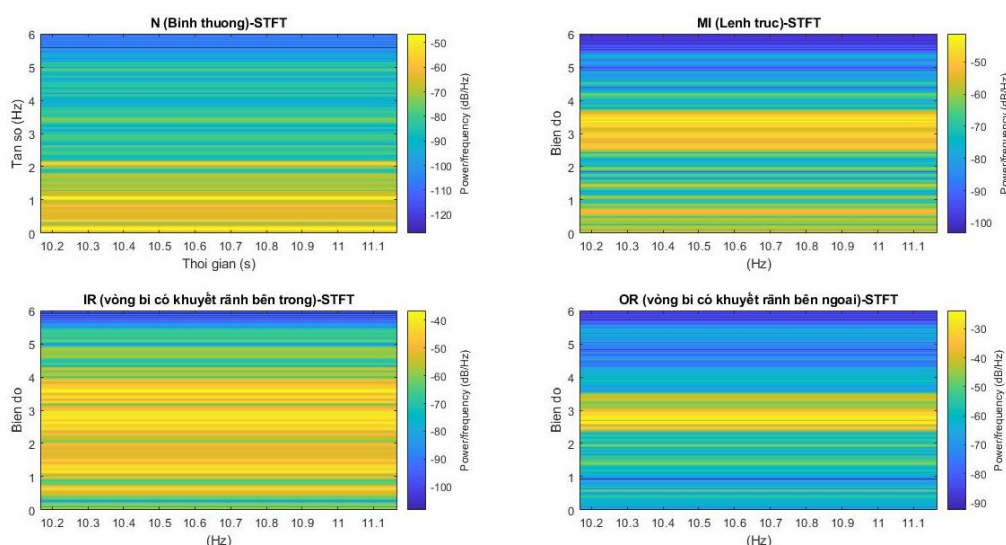
**Hình 8.** Biểu diễn trên miền tần số FFT ( $F_s = 2000$  Hz).

Ta có thể nhận thấy từ các hình ví dụ dưới sự khác biệt rõ ràng về biểu diễn của 4 đồ thị. Đồ thị ở trạng thái hoạt động bình thường và lỗi vòng bi có biên độ thấp và không có các điểm với biên độ tăng vọt lên giá trị cao nhưng biểu đồ lỗi vòng bi có biên độ trung bình cao hơn. Từ đây, ta thấy rõ ràng, dù là với mắt thường và bộ dữ liệu thô chưa được chạy qua bộ lọc hay phép biến đổi nào thì ta vẫn có thể phân biệt rõ ràng các trường hợp khác nhau.

Bài báo sử dụng biến đổi STFT (Short-Time Fourier Transform) để chuyển đổi tín hiệu từ miền thời gian sang miền phổ, quá trình này thường bao gồm các bước sau:

- *Chia tín hiệu thành các khung thời gian:* Tín hiệu được chia thành các phân đoạn nhỏ, gọi là khung thời gian, bằng cách sử dụng cửa sổ trượt trên toàn bộ tín hiệu. Mỗi khung thời gian thường có độ dài cố định.
- *Áp dụng cửa sổ:* Trong mỗi khung thời gian, tín hiệu được nhân với một hàm cửa sổ, chẳng hạn như cửa sổ Hanning hoặc cửa sổ Hamming, để giảm thiểu hiện tượng rò rỉ tần số và đảm bảo rằng tín hiệu được xử lý mượt mà.
- *Thực hiện biến đổi Fourier:* Sau khi áp dụng cửa sổ, biến đổi Fourier được thực hiện trên từng khung thời gian để chuyển đổi tín hiệu từ miền thời gian sang miền tần số. Kết quả là một phổ ảnh, trong đó, mỗi cột đại diện cho một khung thời gian và mỗi hàng đại diện cho một tần số.

Sử dụng biến đổi STFT, ta có thể thu được một biểu diễn phổ của tín hiệu, giúp hiểu rõ hơn về thành phần tần số và biến động của tín hiệu theo thời gian. Điều này rất hữu ích trong việc phân tích và xử lý tín hiệu trong nhiều ứng dụng khác nhau như xử lý âm thanh, xử lý hình ảnh và truyền thông. Dữ liệu từ miền thời gian (hình 7) sẽ được biến đổi STFT, được các tập mẫu tương đương dạng hình ảnh, được thể hiện trong các hình dưới đây:



**Hình 9.** Hình ảnh sau chuyển đổi STFT từ dữ liệu trên hình 8.

## 2.2. Sử dụng mạng nơ-ron để xây dựng phần mềm chẩn đoán lỗi động cơ

### 2.2.1. Mạng SVM

Máy hỗ trợ Vector (SVM) là một thuật toán học máy giám sát phổ biến được sử dụng rộng rãi cho cả nhiệm vụ phân loại và hồi quy. Trong ngữ cảnh của việc phân loại hình ảnh, SVM được biết đến và sử dụng rộng rãi vì hiệu suất của nó trong việc xử lý dữ liệu đa chiều, làm cho nó thích hợp cho phân tích dữ liệu hình ảnh. SVM nhằm tìm ra mặt phẳng phân chia tốt nhất giữa các lớp trong không gian đặc trưng đa chiều. SVM tìm kiếm mặt phẳng phân chia sao cho tối đa hóa ranh

giới, tức là khoảng cách giữa mặt phẳng phân chia và điểm gần nhất từ mỗi trong hai lớp. Một ranh giới lớn thường dẫn đến khả năng tổng quát và hiệu suất tốt hơn. Trong bối cảnh của vấn đề của chúng ta, là bài toán phân loại đa lớp, chúng ta sẽ sử dụng phương pháp One-Versus-Rest.

Mỗi hình ảnh được biểu diễn dưới dạng một vector đặc trưng dựa trên các đặc trưng đã trích xuất. Tập huấn luyện được sử dụng để huấn luyện SVM. Các vector đặc trưng đã trích xuất từ hình ảnh huấn luyện cùng với nhãn tương ứng của chúng được đưa vào SVM. SVM học cách tìm ra siêu phẳng tốt nhất phân tách các vector đặc trưng dựa trên nhãn của chúng.

### 2.2.2. Mạng YOLO

YOLO (You Only Look Once) được huấn luyện trên toàn bộ hình ảnh, tối ưu hóa trực tiếp khả năng phát hiện của nó. Mô hình thống nhất này cung cấp một số ưu điểm so với các phương pháp phát hiện đối tượng truyền thống. Đối với phân loại hình ảnh, kiến trúc có thể được điều chỉnh để phục vụ mục đích phân loại hình ảnh đầu vào vào các lớp được xác định trước. Trong YOLO truyền thống, hình ảnh được chia thành một lưới, và mỗi ô lưới dự đoán các bounding box và xác suất lớp. Tuy nhiên, điều này có thể được giảm xuống một ô lưới duy nhất chứa toàn bộ hình ảnh cho mục đích phân loại hình ảnh. Thay vì dự đoán bounding box và xác suất lớp cho mỗi ô lưới, chúng ta điều chỉnh lớp đầu ra để chỉ dự đoán xác suất lớp. Điều này có nghĩa là loại bỏ khía cạnh dự đoán bounding box từ lớp đầu ra cuối cùng. Mạng dự đoán xác suất lớp cho các lớp được xác định trước trực tiếp. Mỗi lớp có một xác suất liên quan cho biết khả năng hình ảnh đầu vào thuộc về lớp đó.

### 2.2.3. Mạng ResNet-50

ResNet-50 là một kiến trúc học sâu được công nhận và có ảnh hưởng rộng rãi, đặc biệt trong lĩnh vực thị giác máy tính. Nó thuộc vào họ mô hình ResNet (Residual Neural Network). ResNet-50 là một kiến trúc mạng nơ-ron sâu được sử dụng rộng rãi trong lĩnh vực thị giác máy tính. Nó là một phần của họ các mô hình ResNet (Residual Neural Network) được thiết kế để giải quyết vấn đề của việc huấn luyện các mạng nơ-ron sâu với số lớp ngày càng tăng. Kiến trúc ResNet-50 bao gồm một loạt các khối residual (khối còn gọi là identity blocks) mà trong đó các kết nối tắt (shortcut connections) được sử dụng để tránh hiện tượng vanishing gradient và giúp huấn luyện các mạng sâu trở nên dễ dàng hơn. Cụ thể, ResNet-50 có 50 lớp, trong đó bao gồm các lớp convolution, lớp pooling và các khối residual. ResNet-50 đã được chứng minh là hiệu quả trong nhiều nhiệm vụ thị giác máy tính như nhận dạng vật thể, phân loại hình ảnh.

## 3. KẾT QUẢ VÀ THẢO LUẬN

### 3.1. Xây dựng tập cơ sở dữ liệu

Chúng tôi đã tiến hành chuyển đổi dữ liệu miền thời gian từ bảng 1 sáng dữ liệu hình ảnh tương ứng, sẽ thu được một tập dữ liệu gồm 10000 hình ảnh cho mỗi danh mục, bao gồm N, MI, IR và OR. Các hình ảnh này được chia thành tỷ lệ 7-3, tương ứng với các tập huấn luyện, xác thực và kiểm tra cho mỗi lớp. Cụ thể, 70% cho việc huấn luyện mạng nơ-ron, 30% cho việc kiểm tra, bộ cơ sở dữ liệu được liệt kê chi tiết tại bảng 2 dưới đây:

**Bảng 2.** Bảng phân chia số lượng mẫu học và mẫu kiểm tra.

Loại lỗi	Tổng số mẫu	Số mẫu học	Số mẫu kiểm tra
N	10000	7000	3000
MI	10000	7000	3000
IR	10000	7000	3000
OR	10000	7000	3000

**3.2. Kết quả chẩn đoán lỗi và phân tích so sánh sau quá trình huấn luyện cho mỗi mô hình**

**Bảng 3.** Các thông số đánh giá chất lượng của 3 mô hình.

Loại mô hình	Độ chính xác huấn luyện (%)	Độ chính xác kiểm tra (%)
YOLOv8x	99.591	98.921
Resnet50	96.527	93.381
SVM	97.684	96.297

Bảng cung cấp một đánh giá toàn diện về các chỉ số hiệu suất kiểm tra và validation cho các mô hình thị giác máy tính khác nhau, gồm YOLOv8x, ResNet50 và SVM. Đáng chú ý, YOLOv8x nổi bật trong một số khía cạnh quan trọng. YOLOv8x đứng đầu giữa 3 mô hình với độ chính xác huấn luyện ấn tượng là 99.591% và độ chính xác kiểm tra là 98.921%. Độ chính xác đáng kể này cho thấy sự ưu việt của nó trong việc phát hiện và nhận dạng đối tượng so với ResNet50 và SVM. Trong khi ResNet50 và SVM cũng hoạt động tốt, với độ chính xác kiểm tra là 93.381%, và 96.297%. Độ chính xác kiểm tra của YOLOv8x cao hơn đáng kể, cho thấy khả năng hiệu quả của nó trong việc xác định đối tượng chính xác trong hình ảnh.

**4. KẾT LUẬN**

Thuật toán học sâu mang lại nhiều lợi ích cho việc chẩn đoán lỗi máy móc, bao gồm cả động cơ, biến áp,... Chúng tôi dự đoán về sự gia tăng nhanh chóng trong các nghiên cứu về chẩn đoán lỗi động cơ và vòng bi với đầu vào là tín hiệu độ rung bằng các mạng nơ-ron mới bây giờ. Đóng góp chính của bài báo này nằm ở việc tạo ra một bộ dữ liệu với 3 loại lỗi ổ trục và kiểm thử nó với nhiều mạng nơ-ron thông dụng hiện nay. Kết quả nghiên cứu đặc biệt nhấn mạnh ưu điểm của mạng YOLOv8x trong ngữ cảnh này, mở ra những khả năng mới cho các nhiệm vụ phân loại. Trong tương lai, chúng tôi có kế hoạch mở rộng và hoàn thiện hơn bộ cơ sở dữ liệu.

**TÀI LIỆU THAM KHẢO**

- [1]. Rai, A., & Upadhyay, S. H., “A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings”, *Tribology International*, 96, 289-306, (2016).
- [2]. Saufi, S. R., Ahmad, Z. A. B., Leong, M. S., & Lim, M. H., “Challenges and opportunities of deep learning models for machinery fault detection and diagnosis”, *A review. Ieee Access*, 7, 122644-122662, (2019).
- [3]. Zhao, Z., Wu, J., Li, T., Sun, C., Yan, R., & Chen, X., “Challenges and opportunities of AI-enabled monitoring, diagnosis & prognosis”, *A review. Chinese Journal of Mechanical Engineering*, 34(1), 1-29, (2021).
- [4]. Tahir, M. M., Khan, A. Q., Iqbal, N., Hussain, A., & Badshah, S., “Enhancing fault classification accuracy of ball bearing using central tendency based time domain features”, *IEEE Access*, 5, 72-83, (2016).
- [5]. Chen, Z.; Li, C.; Sanchez, R.V, “Gearbox fault identification and classification with convolutional neural networks”, *Shock. Vib.* 2015, 390134, (2015).
- [6]. Zhao, J.; Yang, S.; Li, Q.; Liu, Y.; Gu, X.; Liu, W, “A new bearing fault diagnosis method based on signal-to-image mapping and convolutional neural network”, *Measurement*, 176, 109088, (2021).
- [7]. Gao, Y.; Liu, X.; Huang, H.; Xiang, J, “A hybrid of FEM simulations and generative adversarial networks to classify faults in rotor-bearing systems”, *ISA Trans*, 108, 356–366, (2021).
- [8]. Liu, H.; Zhou, J.; Xu, Y.; Zheng, Y.; Peng, X.; Jiang, W, “Unsupervised fault diagnosis of rolling bearings using a deep neural network based on generative adversarial networks”, *Neurocomputing*, 315, 412–424, (2018).
- [9]. Wang, R.; Jiang, H.; Li, X.; Liu, S, “A reinforcement neural architecture search method for rolling bearing fault diagnosis”, *Measurement*, 154, 107417, (2020).
- [10]. Y. A. Almatheel and M. Osman, “Bearing Element Fault Diagnosis Using Support Vector Machine”, 2020 International Conference on Computer, Control, Electrical, and Electronics Engineering (ICCCEEE), Khartoum, Sudan, pp. 1-5, (2021).

- [11]. X. Zhang, Y. Liang, J. Zhou, and Y. zang, "A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM," *Measurement*, vol. 69, pp. 164–179, (2015).
- [12]. C. Zhang, J. Chen, and X. Guo, "A gear fault diagnosis method based on EMD energy entropy and SVM," *Journal of Vibration and Shock*, vol. 29, no. 10, pp. 216–220, (2010).
- [13]. S. Zgarni and A. Braham, "Classification of Bearing Fault Detection Using Multiclass SVM: A Comparative Study", 2018 15th International Multi-Conference on Systems, Signals & Devices (SSD), Yasmine Hammamet, Tunisia, pp. 888-892, (2018).
- [14]. J. Redmon and A. Farhadi, "YOLO9000: better, faster, stronger", in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 7263-7271, (2017).
- [15]. C.-Y. Wang, A. Bochkovskiy, and H.-Y. M. Liao, "YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors", *arXiv preprint arXiv:2207.02696*, (2022).
- [16]. Van-Nam Pham, Quang-Huy Do Ba, Duc-Anh Tran Le, "Using Artificial Intelligence (AI) for Monitoring and Diagnosing Electric Motor Faults Based on Vibration Signals", *International Conference on Information Networking (ICOIN)*, (2024).

### ABSTRACT

#### **Application of neural networks in diagnosing engine faults based on vibration signals**

*This paper investigates and applies artificial intelligence (AI) to improve the monitoring and diagnosis process of electrical engine faults based on vibration signals. The research aims to build a model to collect sample data from engines and utilize three different AI networks in this study, including YOLO (You Only Look Once), Resnet (Residual neural network), and SVM (Support Vector Machine). By applying these models to independently identify faults using the common input signal of vibration, particularly focusing on bearing-related faults in engine systems, the paper concentrates on exploring various faults. The experimental results presented in the paper demonstrate the accuracy of using these networks in diagnosing engine faults and provide important insights into the accuracy and practical applicability of AI networks in the field of industrial equipment maintenance and management.*

**Keywords:** Engine error; Yolo; Resnet; SVM; Short-Time Fourier Transform STFT.