

ĐỀ XUẤT GIẢI PHÁP CHẨN ĐOÁN HƯ HỒNG ĐỘNG CƠ ĐIỆN KHÔNG XÂM LẤN ỨNG DỤNG MẠNG GOOGLNET

PROPOSAL OF NONINVASIVE FAILURE DIAGNOSIS OF ELECTRICAL MOTOR USING GOOGLNET

Hoàng Văn Tùng¹, Nguyễn Văn Khanh², Nguyễn Chí Ngôn²
¹ Trường Đại học Sư phạm Kỹ thuật Vĩnh Long, Việt Nam
² Trường Đại học Cần Thơ, Việt Nam

Ngày toà soạn nhận bài 24/8/2021, ngày phân biên đánh giá 21/9/2021, ngày chấp nhận đăng 28/9/2021.

TÓM TẮT

Chẩn lỗi là một công cụ hữu ích trong vận hành giúp giảm rủi ro và chi phí bảo trì hệ thống. Tuy nhiên, dữ liệu về hành vi hoạt động danh nghĩa và lỗi của hệ thống thường không được thu thập và lưu trữ một cách đầy đủ, gây khó khăn cho việc chẩn đoán cũng như đề xuất các phương pháp xác định lỗi tự động. Nghiên cứu này đề xuất một giải pháp ứng mạng học sâu CNN (Convolutional neural network) để nhận dạng một số lỗi thông dụng trên động cơ cảm ứng dựa vào âm thanh vận hành. Dữ liệu âm thanh phát ra từ trên động cơ cảm ứng hai cực 0,37 kW được thu thập trong một số trường hợp như hoạt động bình thường, mất pha, lệch pha và vỡ bạc đạn. Ảnh phổ 2D của chúng được phân tích bằng chuyển đổi Wavelet liên tục được sử dụng để huấn luyện và kiểm tra mạng học sâu CNN (GoogLeNet) để nhận dạng các lỗi trên. Kết quả thực nghiệm cho thấy phương pháp này phát hiện được các lỗi trên động cơ cảm ứng với độ chính xác lên đến 98,8%.

Từ khóa: Chẩn lỗi; mạng nơ-ron tích chập; ảnh phổ 2D; wavelet; GoogLeNet.

ABSTRACT

Fault diagnosis is a useful tool that reduces system maintenance risks and costs. However, data related to the system's nominal and fault operating behavior is often not collected and stored adequately, it is difficult to identify and suggest automated fault detection methods. This study proposes a solution to apply deep learning technique on the convolutional neural network (CNN) to identify some common errors on induction motors based on operation sound. The operation sound signal emitted from on a 0.37 kW two-pole induction motor is collected in some cases such as normal operation, phase loss, phase difference and bearing breakage. Their 2-D scalogram images are analyzed by continuous Wavelet transformation which is used to train and evaluate the deep learning CNN (i.e. GoogLeNet) to identify the above faults. Experimental results show that this method can diagnose induction motor faults with accuracy up to 98.8%.

Keywords: Fault diagnosis; CNN; 2-D scalogram image; wavelet; GoogLeNet.

1. GIỚI THIỆU

Hư hỏng động cơ điện gây ra tình trạng gián đoạn hoạt động sản xuất công nghiệp, làm gia tăng chi phí cho doanh nghiệp. Theo kết quả khảo sát của viện nghiên cứu EPRI (Electric Power Research Institute) và IEEE, khả năng xảy ra các hư hỏng của động cơ là do lỗi của các thành phần cấu tạo nên nó. Kết quả khảo sát trong Bảng 1 cho thấy sự cố xảy ra trên động cơ cảm ứng phần lớn là do lỗi của các linh kiện

như vòng bi, Stato, và Rô-to chiếm 78% (theo IEEE), 88% (theo EPRI). Trong khi, sự cố xảy ra do các lỗi khác là rất thấp.

Bảng 1. Khả năng xảy ra sự cố trên động cơ cảm ứng [1]

	Lỗi vòng bi	Lỗi Stato	Lỗi Rô-to	Các lỗi khác
IEEE	42%	28%	8%	22%
EPRI	40%	38%	10%	12%

Chẩn đoán lỗi động cơ điện đã được thảo luận trong nhiều nghiên cứu liên quan [2]. Các sự cố trên động cơ được chia thành hai loại chính bao gồm: (i) lỗi cơ học xảy ra do mất cân bằng cơ học, hỏng ổ trục, lệch trục, biến dạng khe hở không khí và (ii) lỗi điện xảy ra trên rô-to và stato [3, 4]. Nhiều phương pháp đã được đề xuất để chẩn đoán các lỗi trên như phân tích rung động cơ học, phân tích tín hiệu điện, nhiệt độ và âm thanh phát ra từ động cơ lúc vận hành.

Trong đó, các phân tích rung động cơ học, điện và nhiệt đã được áp dụng để chẩn đoán lỗi của máy điện [5, 6]. Trong các phương pháp này, phân tích rung động cơ học và phân tích dòng điện là phổ biến nhất do khả năng đo lường dễ dàng, độ chính xác và độ tin cậy. Tuy nhiên, các cảm biến rung động, chẳng hạn như cảm biến gia tốc, thường chỉ được lắp đặt trên các máy có giá thành cao và độ chính xác của chúng chịu ảnh hưởng lớn bởi các yếu tố môi trường và chỉ chẩn đoán được các lỗi cơ học. Kỹ thuật chẩn đoán dựa trên phân tích dòng điện cho hiệu quả tốt nhất vì chi phí thực hiện thấp, hiệu suất nhận dạng cao, tín hiệu nhận dạng ít bị ảnh hưởng bởi các yếu tố môi trường. Tuy nhiên, nhược điểm chính của phương pháp này là phải can thiệp vào động cơ (kỹ thuật xâm lấn) và chỉ chẩn đoán được các lỗi về điện. Bên cạnh đó, ảnh nhiệt cũng đã được áp dụng để chẩn đoán lỗi động cơ cảm ứng [7, 8]. Ưu điểm của kỹ thuật này là không xâm lấn động cơ và phát hiện đúng vị trí lỗi. Tuy nhiên, chi phí triển khai cao, cần thời gian làm nóng động cơ, máy ảnh nhiệt phải được đặt một cách nhất quán và cần phải áp dụng các thuật toán xử lý ảnh thích hợp.

Chẩn đoán lỗi động cơ dựa trên phân tích tín hiệu âm thanh thu được trong quá trình vận hành cũng đã được áp dụng [9, 10]. Ưu điểm lớn nhất kỹ thuật này là không xâm lấn động cơ, chi phí áp dụng không cao; đặc biệt, nó có thể nhận dạng được cả hai lỗi cơ và điện. Nhược điểm của phương pháp này là không thể được xác định chính xác vị trí bị lỗi, micro thu âm phải được lắp đặt ở vị trí hợp lý để thu tốt âm thanh từ động cơ và ít bị

ảnh hưởng bởi âm thanh từ môi trường và âm thanh phản hồi. Như vậy vấn đề lọc nhiễu là rất quan trọng trong phương pháp này.


Những năm gần đây, mạng nơ-ron nhân tạo đã được áp dụng vào lĩnh vực bảo trì để tạo ra một phương pháp chẩn đoán thông minh. Theo nghiên cứu Gong và cộng sự [11] bài toán nhận dạng thông minh chủ yếu dựa trên sự phân loại và nhận dạng đặc trưng của các hư hỏng; sau đó sử dụng chúng để huấn luyện cho một mạng kết hợp giữa mạng nơ-ron tích chập và máy học véc-tơ CNN-SVM (Convolutional Neural Network – Support Vector Machine) để nhận dạng tự động các lỗi trên động cơ. Kết quả nhận dạng đã được so sánh với các mạng nơ-ron nhân tạo truyền thống như mạng lan truyền ngược BPNN (Back-Propagation Artificial Neural Network), máy học véc-tơ SVM và minh chứng được sự cải thiện rất tốt khả năng nhận dạng lỗi. Trong nghiên cứu [11] lỗi động cơ được nhận dạng chủ yếu dựa trên tín hiệu rung động thu thập từ động cơ. Mặc dù kết quả nhận dạng lỗi rất tốt, nhưng để thu thập tốt tín hiệu rung động, động cơ cần phải can thiệp để lắp đặt cảm biến thu thập dữ liệu dẫn đến kết quả của phương pháp phụ này thuộc rất lớn vào phương pháp thu thập dữ liệu.

Trong nghiên cứu này, nhóm tác giả đã đề xuất một phương pháp chẩn đoán lỗi cơ và điện của động cơ dựa trên phân tích tín hiệu âm thanh kết hợp với mạng học sâu. Một tập dữ liệu âm thanh phát ra từ động cơ trong lúc vận hành được thu thập trực tiếp bằng một điện thoại thông minh trong bốn trường hợp: động cơ bình thường, vỡ bạc đạn (vỡ ổ bi), bị mất pha và lệch pha. Các dữ liệu này sau đó được lọc nhiễu bằng biến đổi Wavelet, chuẩn hóa biên độ, cắt thành các đoạn âm thanh ngắn có cùng số mẫu âm thanh và được phân tích thành ảnh phổ tần số hai chiều (2D – Two dimension) trong miền thời gian – tần số dựa trên biến đổi Wavelet liên tục. Tập ảnh phổ được sử dụng để huấn luyện và kiểm tra mạng học sâu GoogLeNet [12], sau đó được kiểm nghiệm khả năng nhận dạng lỗi trên các tập tin âm thanh độc lập.

2. DỮ LIỆU VÀ PHƯƠNG PHÁP NHẬN DẠNG

2.1 Dữ liệu

Mô hình thí nghiệm thu thập tín hiệu âm thanh của động cơ được bố trí như Hình 1. Một động cơ không đồng bộ 3 pha có các thông số như trình bày trong Bảng 2 và một điện thoại thông minh đặt cạnh động để thu thập âm thanh phát ra từ động cơ khi vận hành.



Hình 1. Bố trí thí nghiệm

Bảng 2. Thông số động cơ được thí nghiệm

Thông số	Ký hiệu	Giá trị
Khối lượng (kg)	M_m	11
Điện áp định mức (V)	$V_{đm}$	220/380
Dòng điện định mức (A)	$I_{đm}$	1.6/0.8
Dòng điện không tải (A)	I_{kt}	0.9/0.5

Tốc độ rô-to (vòng/phút)	RSM	1450
Công suất định mức (kW)	$P_{đm}$	0.37
Tần số định mức (Hz)	$f_{đm}$	50

Dữ liệu âm thanh được thu lần lượt trong bốn trường hợp là động cơ hoạt động bình thường, động cơ gặp sự cố vỡ bạc đạn, mất pha và lệch pha. Mỗi trường hợp sẽ thu 500 đoạn âm thanh với thời lượng trung bình từ 20 đến 25 giây. Dữ liệu thu thập được tóm tắt trong Bảng 3.

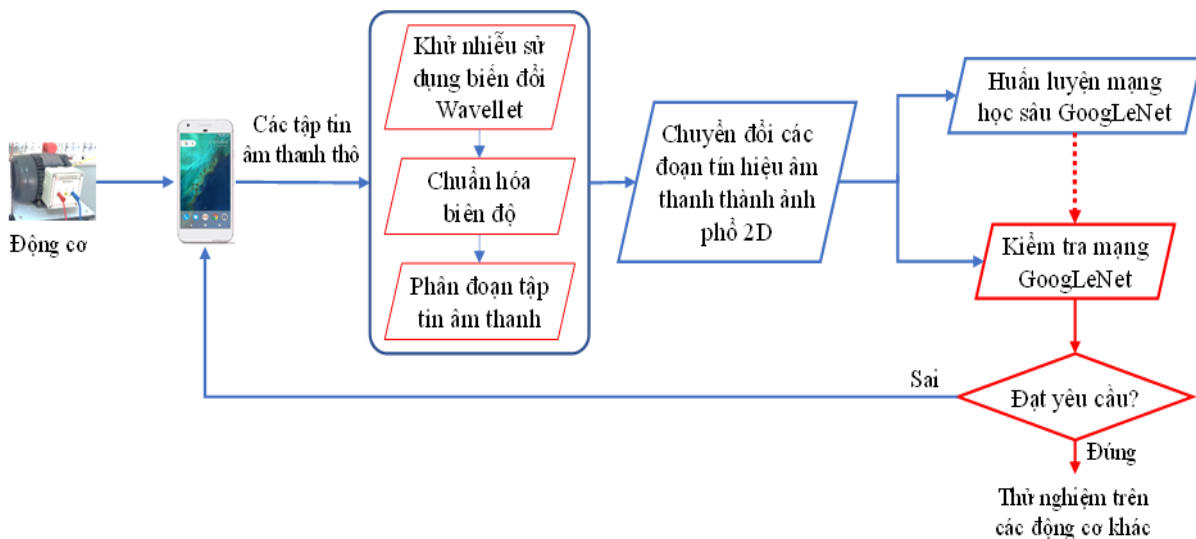
Bảng 3. Kết quả thu thập dữ liệu

Trường hợp	Số tập tin	Thời lượng
Bình thường	480	20-25 giây
Mất pha	500	20-25 giây
Lệch pha	500	20-25 giây
Vỡ bạc đạn	500	20-25 giây

2.2 Phương pháp

Tổng quan về phương pháp đề xuất được trình bày trong sơ đồ Hình 2.


Thành phần chính của phương pháp này là một mạng học sâu tích chập GoogLeNet [12] được sử dụng để nhận dạng các đặc trưng của âm thanh phát ra từ động cơ khi hoạt động bình thường và khi gặp vấn đề. Quá trình xử lý dữ liệu âm thanh được thực hiện thông qua ba bước chính. Thứ nhất, một điện thoại thông minh được sử dụng để thu thập âm thanh từ



Hình 2. Sơ đồ tổng quan về phương pháp nghiên cứu

một động cơ khi nó hoạt động bình thường và khi xảy ra sự cố (mất pha, lệch pha và vỡ bạc đạn) và lưu thành từng nhóm tập tin riêng biệt. Sau đó, các tập tin âm thanh trong từng nhóm sẽ được lọc nhiễu sử dụng biến đổi Wavellet [13], chuẩn hóa biên độ và cắt thành những đoạn đều nhau có kích thước 65535 mẫu tín hiệu. Cuối cùng, các mẫu đoạn âm thanh sau khi xử lý trong từng nhóm sẽ được chuyển đổi thành các ảnh phổ 2D có kích thước 224x224 pixel [12]. 80% các ảnh phổ 2D trong mỗi nhóm sẽ được sử dụng để huấn luyện mạng học sâu GoogLeNet, mỗi nhóm dữ liệu ảnh là một nhãn huấn luyện. 20% dữ liệu ảnh còn lại trong các nhóm sẽ được sử dụng để kiểm tra mạng học sâu sau khi huấn luyện. Nếu kết quả có độ chính xác đạt yêu cầu mạng sẽ được sử dụng để kiểm tra trên các động cơ khác để khẳng định hiệu quả huấn luyện. Nếu độ chính xác chưa đạt sẽ quay về bố trí thí nghiệm thu tập dữ liệu mới và lặp lại quá trình.

Mạng GoogLeNet đã được hiệu chỉnh để có thể chạy được trên các thiết bị có tài nguyên tính toán hạn chế, hay MobiNet [14]. Một số ứng dụng nhận dạng dựa trên mạng này cũng đã được phát triển và chứng minh được sự hiệu quả [15]. Do đó, thành công của việc thu thập dữ liệu sử dụng điện thoại thông minh và huấn luyện mạng GoogLeNet sẽ mang một ý nghĩa thực tiễn hết sức quan trọng. Một ứng dụng chẩn đoán thông minh có thể phát triển ngay trên các thiết bị di động để chẩn đoán các hư hỏng trực tiếp từ âm thanh thu được. Ứng dụng sẽ không bị giới ở chẩn đoán động cơ mà có thể áp dụng với nhiều đối tượng cũng như ứng dụng khác.



Hình 3. Tập âm khi thu tiếng ồn từ động cơ

2.2.1 Lọc nhiễu tín hiệu âm thanh

Tín hiệu âm thanh thu được từ điện thoại thông minh ngoài tiếng ồn phát ra từ động cơ thì còn nhiều tạp âm khác như minh họa trong Hình 3. Các tạp âm này có thể ảnh hưởng đến quá trình huấn luyện mạng GoogLeNet. Do đó, tín hiệu âm thanh cần phải được lọc nhiễu bằng thuật toán Wavellet [13] để loại bỏ tạp âm trước khi được phân đoạn tín hiệu và chuyển đổi thành ảnh phổ 2D làm dữ liệu huấn luyện và kiểm tra mạng học sâu.


Giả sử tín hiệu âm thanh thu được $y(t)$ là tổng hợp của tiếng ồn từ động cơ $x(t)$ và tạp âm $e(t)$, $y(t)$ sẽ được biểu diễn như sau:

$$y(t_i) = x(t_i) + e(t_i) \quad (1)$$

Theo [13] phương pháp khử nhiễu Wavelet được áp dụng để khử hay làm giảm ảnh hưởng của tạp âm $e(t)$ đến tín hiệu âm thanh thu được $y(t)$ được thực hiện qua ba bước chính. Trước tiên, tiến hành chọn wavelet cơ sở và cấp phân tích để thực hiện phân tích wavelet trên $y(t)$ và nhận được các thành phần tần số cao. Tiếp theo, đối với các hệ số của thành phần tần số cao nhận được từ bước một sẽ được tiến hành xác định các ngưỡng lượng tử hóa. Có hai phương pháp chính để xác định ngưỡng lượng tử ngưỡng cứng và ngưỡng mềm với nhiều tiêu chuẩn chọn ngưỡng như Stein agonic lifelihood, min-max, logarithmic length consistent threshold, heuristic agonic likelihood. Trong nghiên cứu này sẽ áp dụng tiêu chuẩn chọn ngưỡng mềm của Stein. Sau cùng, phục hồi tín hiệu $y(t)$ sau khi loại nhiễu sử dụng các hệ số của tín hiệu tần số thấp và các hệ số của tín hiệu tần số cao sau khi đã lượng tử hóa, và tính toán tỉ lệ nhiễu trên tín hiệu.

Trong bài báo này, hàm wdenoise trong Wavelet toolbox của Matlab được áp dụng để khử nhiễu tạp âm cho tín hiệu âm thanh thu được từ điện thoại thông minh, sử dụng phương pháp khử nhiễu Wavelet Block James-Stein với ngưỡng lượng tử hóa là 5 [16]. Ngưỡng này được chọn bằng phương pháp thực nghiệm. Hình 4 minh họa kết quả áp dụng phương pháp khử nhiễu Block

James-Stein trên một đoạn tín hiệu thu thập được.



Hình 4. Minh họa lọc nhiễu bằng phép biến đổi Wavelet

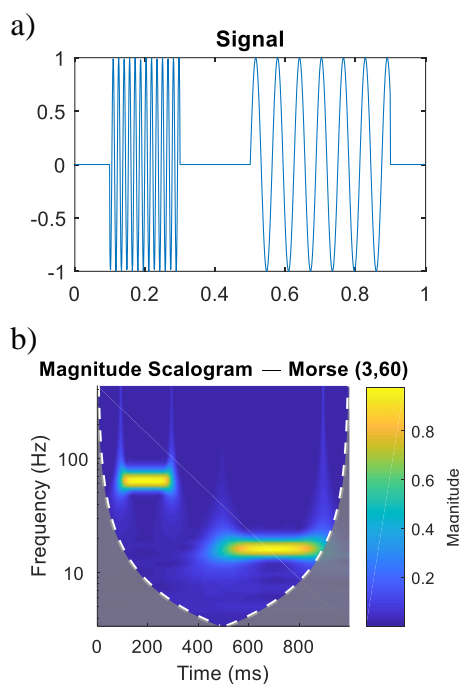
2.2.2 Tạo ảnh phổ 2D

Ý tưởng chính của bài báo này huấn luyện mạng học sâu GoogLeNet để nó có thể nhận dạng được các lỗi động cơ dựa trên âm thanh thu trực tiếp từ điện thoại thông minh. Do dữ liệu vào huấn luyện mạng này là các ảnh màu RGB có kích thước 224x224 pixel nên từng đoạn âm thanh (65535 mẫu tín hiệu) sau khi lọc sẽ được phân tích các thông phần tần số theo thời gian và biểu diễn chúng thành các ảnh phổ có kích thước như trên, hay còn được gọi là ảnh phổ 2D trong bài báo này. Các ảnh phổ này sẽ được sử dụng làm dữ liệu huấn luyện để mạng GoogLeNet có thể học được đặc trưng tần số của tín hiệu phát ra từ động cơ với từng trường hợp hay nhãn khác nhau.

Do tín hiệu âm thanh là tín hiệu có tần số biến động nên phép biến đổi Wavelet liên tục sẽ được chọn để phân tích vì nó có thể phân tích được thông tin tần số theo thời gian của tín hiệu. Để thực hiện được việc này một hàm cửa sổ Wavelet $\psi_{u,s}(t)$ với độ rộng trong miền thời gian có thể thay đổi được bởi tham số s và sẽ được dịch chuyển từng bước có độ rộng thời gian là u trên suốt miền thời gian của tín hiệu cần biến đổi để lấy mẫu tín hiệu và phân tích thông tin tần số bằng biến đổi Fourier. Hàm $\psi_{u,s}(t)$ có dạng tổng quát như công thức (2).

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) \quad (2)$$

Trong đó, s là tỉ lệ co giãn và u là tham số tịnh tiến của sổ Wavelet trong miền thời gian. Hàm Wavelet được chọn phải xác định hiệu quả các đặc tính tần số của tín hiệu cần biến đổi. Có nhiều loại phân tích Wavelet với nhiều dạng cửa sổ khác nhau như Morse wavelet, Morlet (Gabor) wavelet và bump wavelet. Trong bài báo này, Morse (3,60) wavelet được tích hợp trong hàm `cwtfilterbank` [17] sẽ được ứng dụng để tính toán các cửa sổ và biến đổi Wavelet. Phổ biên độ của biến đổi Wavelet sẽ được chuyển đổi thành ảnh phổ 2D để làm dữ liệu cho huấn luyện và kiểm tra mạng GoogLeNet. Hình 5 minh họa tín hiệu trong miền thời gian và ảnh phổ của nó trong miền thời gian – tần số.




Hình 5. Ảnh phổ phân tích bằng biến đổi Wavelet: a) tín hiệu trong miền thời gian, b) ảnh phổ biên độ phân tích được trong miền thời gian – tần số

2.2.3 Nhận dạng lỗi động cơ ứng dụng mạng GoogLeNet

GoogLeNet là tên của mạng học sâu tích chập dựa trên kiến trúc khởi động (Inception architecture) đã được Szegedy và các cộng sự sử dụng để tham gia cuộc thi ImageNet Large-Scale Visual Recognition vào năm

2014 [12]. Đây là mạng học sâu tích chập gồm 22 lớp có tham số, 5 lớp pooling không tham số. Các mô-đun khởi động sử dụng hai bộ lọc chập có kích thước 3×3 và 5×5 cùng với bộ lọc giảm chiều không gian 1×1 . Kiến trúc của mô-đun khởi động được minh họa trong Hình 6. Dữ liệu ngõ vào của mạng là các tập ảnh màu RGB có kích thước 224×224 pixel. Các bộ lọc có kích thước khác nhau giúp mạng có thể học được một khối lượng rất lớn đặc trưng ảnh giúp tăng hiệu quả trong việc nhận dạng các nhân ảnh khác nhau.



Hình 6. Kiến trúc một mô-đun khởi động của mạng GoogLeNet

Để huấn luyện mạng GoogLeNet nhận dạng được các lỗi động cơ đang quan tâm, tập ảnh phổ của dữ liệu âm thanh sau khi xử lý sẽ được dán nhãn giống với tên tập dữ liệu (cụ thể: trường hợp động cơ hoạt động bình thường có nhãn là Binh_thuong, vỡ bạc đạn có nhãn là Vo_bacdan, mất pha có nhãn là Mat_pha và lệch pha có nhãn là Lech_pha) và sau đó phân chia ngẫu nhiên thành hai nhóm. Nhóm 1 được sử dụng để huấn luyện mạng bao gồm 80% ảnh phổ của các trường hợp và nhóm 2 được sử dụng để kiểm tra tính hiệu quả của mạng sau khi đã huấn luyện bao gồm 20% số ảnh phổ còn lại. Bài báo này sử dụng mạng GoogLeNet được tích hợp trên Deep Learning Toolbox Model của Matlab [18], thông số mạng được cấu hình như Bảng 4. Các tham số này có thể được hiệu chỉnh để tăng tốc độ huấn luyện mạng.

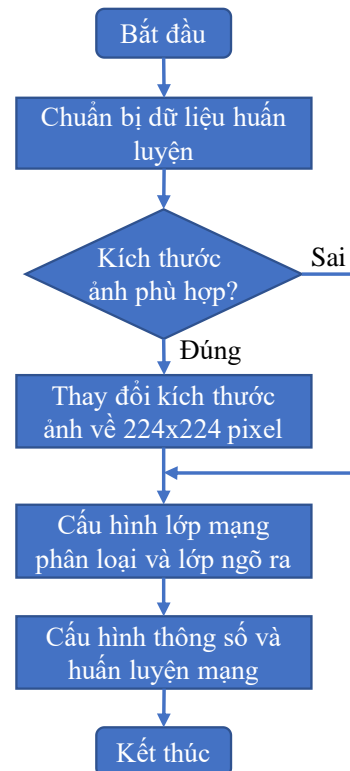
Bảng 4. Kết quả thu thập dữ liệu

Tên tham số	Giá trị
MiniBatchSize	10
MaxEpochs	6
InitialLearnRate	10^{-4}

3. KẾT QUẢ VÀ THẢO LUẬN

3.1 Huấn luyện mạng GoogLeNet

Quá trình huấn luyện mạng GoogLeNet được tóm tắt trong lưu đồ Hình 7 gồm 3 bước chính. Trước tiên, các tập dữ liệu ảnh sẽ được chuẩn bị cho quá trình. Mỗi tập dữ liệu tương ứng với một nhãn nhận dạng sẽ được lưu trữ trong các thư mục riêng biệt với tên thư mục được xem là nhãn nhận dạng. Đây cũng chính là 80% số lượng ảnh phổ 2D của đã được đề cập trong các phần trước. Tập ảnh này sẽ được phân chia một lần nữa để tách thành tập dữ liệu huấn luyện và tập dữ liệu kiểm tra trong quá trình huấn luyện. Trong nghiên cứu này, 80% ảnh phổ được sử dụng để huấn luyện và 20% được sử dụng để kiểm tra. Tỷ lệ này có thể thay đổi tùy vào trường hợp. Nếu các tập dữ liệu ảnh có kích thước khác 224×224 pixel thì chúng cần được thay đổi về kích thước này để phù hợp với yêu cầu của mạng.




Hình 7. Quá trình huấn luyện mạng GoogLeNet

Sau đó, mạng GoogLeNet mặc định sẽ được cấu hình lại cho phù hợp với mục đích nghiên cứu. Mặc định GoogLeNet có thể

nhận dạng được 1000 đối tượng khác nhau. Tuy nhiên, trong bài báo này chỉ cần nhận dạng 4 đối tượng tương ứng với 4 tập ảnh phổ khác nhau. Do đó, lớp thứ 142 (lớp kết nối đầy đủ hay fully connected layer) với 1000 nút mạng sẽ được thay đổi thành 4 nút mạng tương ứng với xác suất nhận dạng của 4 trường hợp đang được quan tâm. Tên của lớp mạng ngõ ra (lớp 144) cũng có thể được thay đổi cho phù hợp với ứng dụng.

Sau cùng, các thông số của mạng sẽ được cấu hình như mô tả trong Bảng 4 và bắt đầu quá trình huấn luyện mạng.

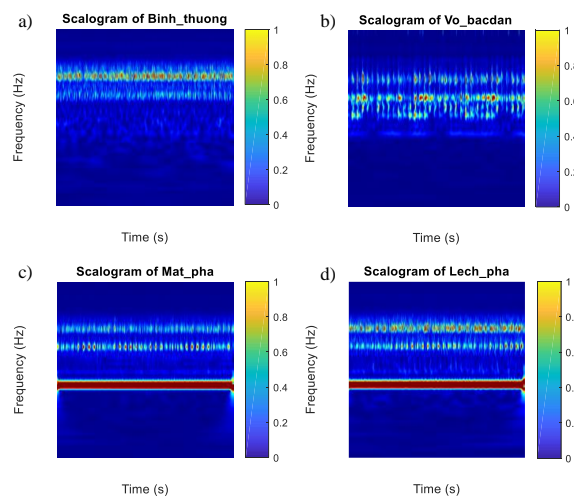


Hình 8. Lọc nhiễu bằng Wavelet

Để có được tập dữ liệu ảnh phổ 2D, các tín hiệu âm thanh sẽ được lọc nhiễu bằng biến đổi Wavelet, chuẩn hóa biên độ (đưa biên độ tín hiệu về [-1 1]), cắt thành những đoạn dữ liệu bằng nhau và phân tích thành ảnh phổ 2D trong miền thời gian – tần số. Các tín hiệu âm thanh thu thập bằng điện thoại thông minh tồn tại nhiều tạp âm như minh họa trong Hình 8, đặc biệt là trường hợp vỡ bạc đạn. Thông tin tần số của các tạp âm này sẽ xuất hiện trên ảnh phổ 2D và sẽ ảnh hưởng đến quá trình nhận dạng nên cần

phải được lọc bỏ. Bên cạnh đó, biên độ tín hiệu cũng khác nhau trong các trường hợp do cường độ âm thanh phát ra khác nhau, để loại bỏ ảnh hưởng của biên độ tất cả các tín hiệu âm thanh sẽ được chuẩn hóa về [-1 1]. Hình 8 trình bày kết quả lọc và chuẩn hóa của một đoạn tín hiệu âm thanh tiếng ồn phát ra từ động cơ trong các trường hợp khác nhau. Kết quả cho thấy tín hiệu đã được lọc nhiễu rất tốt bằng biến đổi Wavelet và sẵn sàng để phân tích ảnh phổ.

Hình 9 minh họa ảnh phổ biên độ 2D của một đoạn âm thanh ngẫu nhiên của 4 trường hợp trên trong miền thời gian – tần số. Trục y là thông tin về tần số, trục x là thời tín hiệu và bản đồ màu là thông tin biên độ của tín hiệu tại thời điểm cụ thể. Các ảnh phổ này chứa nhiều đặc trưng riêng biệt nên sẽ rất phù hợp cho việc huấn luyện mạng để nhận dạng chúng.



Hình 9. Ảnh phổ 4: a) bình thường, b) vỡ bạc đạn; c) mất pha; d) lệch pha

Bảng 5. Tóm tắt dữ liệu sau khi xử lý

Trường hợp	Số lượng ảnh	Huấn luyện	Kiểm tra
Bình thường	8592	8599	8599
Mất pha	6873	6879	6879
Lệch pha	1719	1720	1720
Vỡ bạc đạn	8592	8599	8599

Bảng 5 tóm tắt thông tin về tập ảnh phổ được sử dụng để huấn luyện mạng GoogLeNet. Các tập ảnh phổ này được lưu

trữ trong các thư mục khác nhau theo yêu cầu của quá trình huấn luyện. Kích thước lưu trữ của các ảnh phổ thông nhất là 224x224 pixel nên không cần phải thêm bước hiệu chỉnh kích thước ảnh trong quá trình huấn luyện.

Kết quả huấn luyện mạng GoogLeNet được thể hiện trong Hình 10. Quá trình huấn luyện được thực hiện trong 6 epoch, sau mỗi epoch mạng sẽ được kiểm tra một lần. Kết quả từ hình cho thấy chỉ sau epoch 1, độ chính xác huấn của mạng đã đạt trên 90% và độ chính xác được thiện dần trong các epoch còn lại. Cuối cùng, sau 6 epoch với 16488 lần lặp đã huấn luyện được mạng GoogLeNet với độ chính xác 98.8%.

Như vậy, việc huấn luyện mạng dựa trên ảnh phổ tần số 2D của tín hiệu âm đã tỏ ra rất hiệu quả. Tuy nhiên, mạng sau khi huấn luyện cần được kiểm tra với các tập tin âm thanh khác để kiểm chứng được hiệu quả, tránh trường hợp bị *over-fitting*. Để thực việc kiểm tra mạng, 20% dữ liệu ảnh phổ của các trường hợp sẽ được sử dụng điểm kiểm khả năng nhận dạng của mạng. Đồng thời, việc thu thập âm thanh tiếng ồn của các động cơ khác với cùng triệu chứng để kiểm tra cũng rất cần thiết để minh chứng tính hiệu quả của phương pháp.

3.2 Kiểm tra mạng GoogLeNet

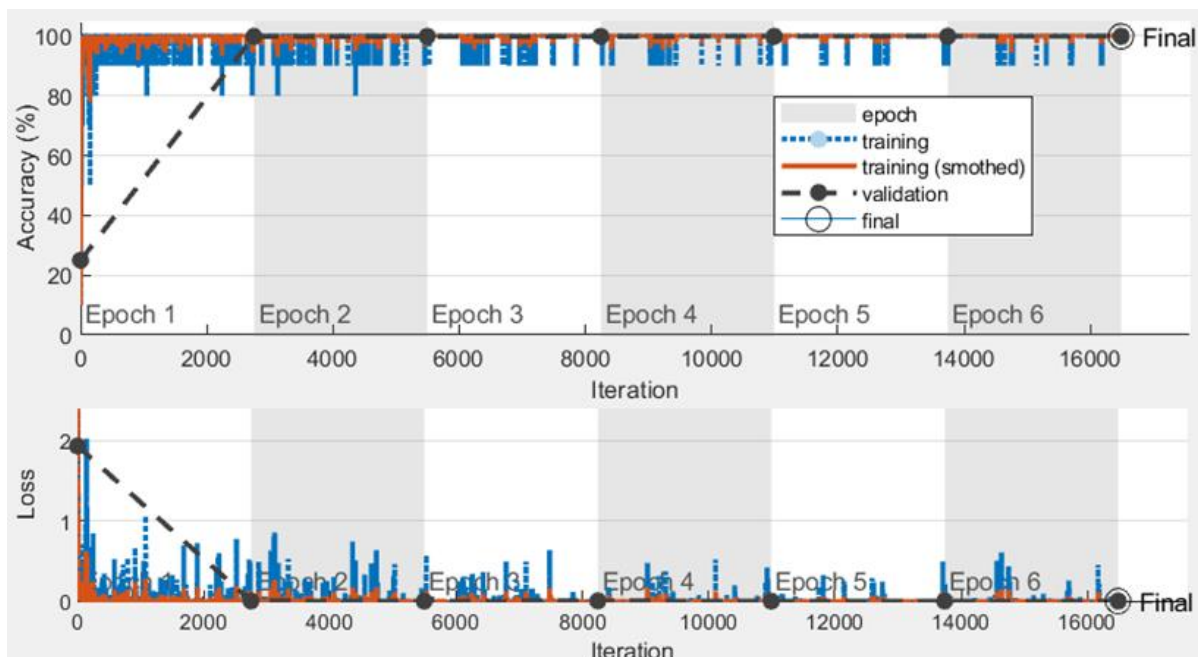
Mạng GoogLeNet sau khi huấn luyện đã được kiểm tra với các tập ảnh phổ từ các tập các tập tin âm thanh độc lập. Kết quả được minh họa trong Hình 11 và Bảng 6. Mạng sau khi huấn luyện đã nhận dạng được tất cả ảnh phổ của các trường hợp khác nhau.

Bảng 6. Kết quả kiểm tra khả năng nhận dạng lỗi động cơ trên các tập âm thanh độc lập

Trường hợp	Số lần kiểm tra	Số lần dự đoán đúng	Tỷ lệ đạt (%)
Bình thường	9	9	100
Mất pha	20	20	100
Lệch pha	20	20	100
Vỡ bạc đạn	20	20	100

3.3 Thảo luận

Bài báo đã đề xuất một phương pháp chẩn đoán lỗi động cơ điện thông minh và hoàn toàn không xâm lấn. Mạng đã được huấn luyện và kiểm tra đạt độ chính xác cao trên 98% tương đương với kết quả của phương pháp đo Gong và các công sự đã đề xuất, cũng như các phương pháp chẩn đoán



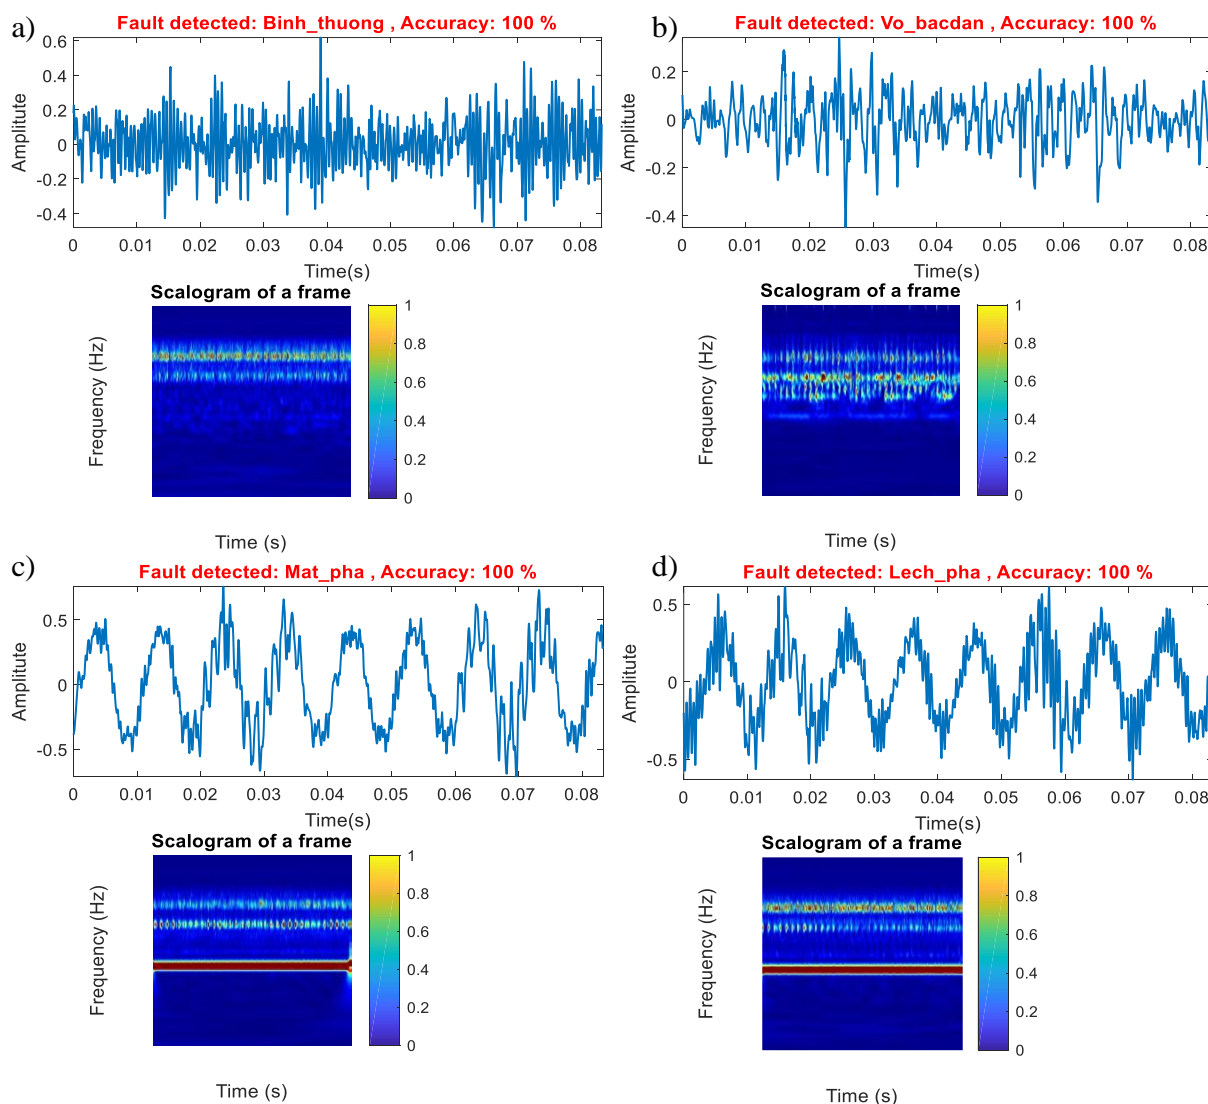
Hình 10. Kết quả huấn luyện

sử dụng mạng truyền thống. Tuy nhiên, ưu điểm của phương pháp đề xuất trong bài báo này là sử dụng trực tiếp âm thanh thu được từ điện thoại thông minh mà không cần bất kỳ một thao tác xâm lấn nào đến động cơ. Điều này giúp việc chẩn đoán lỗi hết đơn giản và linh hoạt. Phương pháp này hoàn toàn có thể được áp dụng để phát triển một ứng dụng chẩn đoán thông minh hoạt động trên nền tảng di động như Android hay iOS.

Tuy nhiên, trong nghiên cứu này, nhóm tác giả chỉ đặt điện thoại thông minh tại một vị trí, điều này không xác định được vị trí, khoảng cách cũng như góc đặt điện thoại tối ưu nhất để có được dữ liệu âm thanh hiệu quả nhất. Trong các nghiên cứu tiếp theo,

nhóm sẽ tiến hành thí nghiệm để thu bộ dữ liệu âm thanh tương ứng với nhiều cách bố trí điện thoại thông minh từ đó sẽ khuyến nghị được một phương pháp tối ưu nhất để thu tín hiệu âm thanh phục vụ cho chẩn đoán.

Nghiên cứu này sử dụng mạng GoogLeNet với các thông số gần như mặc định như trình bày trong Bảng 3. Mặc dù mạng sau khi huấn luyện có độ chính xác rất cao, tuy nhiên thời gian huấn luyện chưa tối ưu, hơn 10 giờ. Do đó, việc khảo sát ảnh hưởng của các thông số này đến thời gian và độ chính xác của mạng là rất cần thiết, đặc biệt là hai thông số *MiniBatchSize* và *MaxEpochs*. Thật vậy, từ kết quả huấn luyện cho thấy, với tập dữ liệu ảnh phổ thu được,



Hình 11. Kết quả kiểm tra mạng GoogLeNet: a) bình thường, b) vỡ bạc đạn, c) mất pha và d) lệch pha

chỉ sau một epoch mạng đã đạt được độ chính xác trên 90% và các epoch tiếp theo chỉ tối ưu độ chính xác. Như vậy, việc xác định số lượng epoch ít nhất để mạng đạt được độ chính xác mong muốn là rất cần thiết để giảm thời gian huấn luyện.

Phương pháp đề xuất trong nghiên cứu này nên được kiểm chứng trên một số lỗi khác của động cơ điện. Thật vậy, mặc dù kết quả rất khả quan, tuy nhiên phương pháp đề xuất chỉ mới được kiểm chứng trên 3 lỗi cơ bản của động cơ bao gồm vỡ bạc đạn, mất pha và lệch pha. Từ tín hiệu trong miền thời gian cũng như ảnh phổ 2D cho thấy sự khác biệt giữa các trường hợp này và khác biệt so với tín hiệu khi bình thường là khá rõ, nên kết quả nhận với độ chính xác cao là không quá bất ngờ. Để khẳng định thêm hiệu quả của phương pháp, trong tương lai, nhóm tác giả sẽ kiểm tra mạng với nhiều lỗi khác nữa

của động cơ, đặc biệt là các lỗi mà ít ảnh hưởng tới tiếng ồn của động cơ.

4. KẾT LUẬN

Nghiên cứu này đã đề xuất được một phương pháp chẩn đoán lỗi động cơ thông minh, không xâm lấn sử dụng mạng học sâu GoogLeNet, dựa trên âm thanh thu trực tiếp từ điện thoại thông minh. Kết quả thực nghiệm đã chứng minh được hiệu quả nhận dạng trên 3 lỗi cơ bản của động cơ bao gồm vỡ bạc đạn, mất pha và lệch pha với độ chính xác chẩn đoán lên đến 98.8%. Mặc dù còn nhiều vấn đề cần cải tiến như vị trí đặt điện thoại thông minh, thời gian huấn luyện mạng, nhận dạng thêm đa dạng lỗi,... Tuy nhiên kết quả ban đầu của nghiên cứu này hứa hẹn sẽ mở ra nhiều hướng nghiên cứu rất hữu ích trong tương lai.

TÀI LIỆU THAM KHẢO

- [1] Report of Large Motor Reliability Survey of Industrial and Commercial Installations: Part 3, *IEEE Transactions on Industry Applications*, vol. IA-23, no. 1, pp. 153-158, 1987.
- [2] H. Henao, GA. Capolino, M. Fernandez-Cabanas, F. Filippetti, C. Bruzzese, E. Strangas, R. Pusca, J. Estima, M. Riera-Guasp and S. Hedayati-Kia, Trends in Fault Diagnosis for Electrical Machines A Review of Diagnostic Techniques, *IEEE Industrial Electronics Magazine*, 8 (2), pp. 31-42, 2014.
- [3] A. Glowacz, W. Glowacz and Z. Glowacz, Recognition of armature current of DC generator depending on rotor speed using FFT, MSAF-1 and LDA, *Eksploatacja i Niezawodność – Maintenance and Reliability*, 17(1), pp. 64-69, 2015.
- [4] Y. Li, F. Chai, ZX. Song and ZY. Li, Analysis of vibrations in interior permanent magnet synchronous motors considering air-gap deformation, *Energies*, 10(9), 1259, 2017.
- [5] R. Yousefi, R. Yusof and R. Arfa, Fault diagnosis of three-phase induction motors based on vibration and electrical current signals, *Jurnal Teknologi*, 78, pp. 129-33, 2016.
- [6] J. Jozwik, Identification and monitoring of noise sources of cnc machine tools by acoustic holography methods, *Advances in Science and Technology Research Journal*, 10(30), pp. 127-137, 2016.
- [7] T. Ciszewski, L. Gelman and L. Swedrowski, Current-based higher-order spectral covariance as a bearing diagnostic feature for induction motors. *Insight - Non - Destructive Testing and Condition Monitoring*, 58(8), pp. 431-434, 2016.
- [8] C. Verucchi, J. Bossio, G. Bossio and G. Acosta, Misalignment detection in induction motors with flexible coupling by means of estimated torque analysis and MCSA. *Mechanical Systems and Signal Processing*, 80, pp. 570-581, 2016.
- [9] PA. Delgado-Arredondo, D. Morinigo-Sotelo, RA. Osornio-Rios, JG. Avina-Cervantes, H. Rostro-Gonzalez and RD. Romero-Troncoso, Methodology for fault detection in induction motors via sound and vibration signals. *Mechanical Systems and Signal Processing*, 83, pp. 568-589, 2017.

- [10] R. Lara, R. Jimenez-Romero, F. Perez-Hidalgo and MD. Redel-Macias, Influence of constructive parameters and power signals on sound quality and airborne noise radiated by inverter-fed induction motors, *Measurement*, 73, pp. 503-514, 2015.
- [11] W. Gong, H. Chen, Z. Zhang, M. Zhang, R. Wang, C. Guan and Q. Wang, A novel deep learning method for intelligent fault diagnosis of rotating machinery based on improved CNN-SVM and multichannel data fusion. *Sensors*, 19, 1693, 2019.
- [12] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke and A. Rabinovich, Going deeper with convolutions. *Computing Research Repository*, 2015.
- [13] Y. Yin, .Y Hu and P. Liu, The research on denoising using wavelet transform. *International Conference on Multimedia Technology*, 2011. <https://doi.org/10.1109/ICMT.2011.6002276>
- [14] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov and LC. Chen, MobileNetV2: Inverted Residuals and Linear Bottlenecks, *arXiv preprint*, arXiv:1801.04381, 2018.
- [15] N. Duong-Trung, LD. Quach and CN. Nguyen, Towards Classification of Shrimp Diseases Using Transferred Convolutional Neural Networks, *Advances in Science, Technology and Engineering Systems Journal*, 5(4), pp. 724-732, 2020.
- [16] Inc. The MathWorks, Wavelet Toolbox User's Guide, *Online*, Retrived on August, 2021, from https://www.mathworks.com/help/pdf_doc/wavelet/wavelet Ug.pdf
- [17] Inc. The MathWorks, Continuous wavelet transform filter bank, *Online*, Retrived on August, 2021, from <https://it.mathworks.com/help/wavelet/ref/cwtfilterbank.html>
- [18] Inc. The MathWorks, GoogLeNet convolutional neural network, *Online*, Retrived on August, 2021, from <https://www.mathworks.com/help/deeplearning/ref/googlenet.html>

Tác giả chịu trách nhiệm bài viết:

PGS.TS Nguyễn Chí Ngôn
Trường Đại học Cần Thơ
Email: ncngon@ctu.edu.vn