

ỨNG DỤNG CỦA PHƯƠNG PHÁP EEMD-SVD VÀ BSOA-SVM ĐỂ CHẨN ĐOÁN HƯ HỒNG Ổ LĂN

AO HÙNG LINH

*Khoa Công nghệ Cơ khí, Trường Đại học Công nghiệp Thành phố Hồ Chí Minh,
aohunglinh@iuh.edu.vn*

Tóm tắt. Nghiên cứu này đề xuất một phương pháp mới để chẩn đoán hư hỏng ổ lăn trong đó chúng tôi sử dụng phương pháp phân rã mô hình thực nghiệm hoàn toàn (EEMD) kết hợp với phương pháp phân tích giá trị riêng (SVD) và máy véc tơ hỗ trợ (SVM). Thêm vào đó, các tham số của SVM được lựa chọn thông qua thuật toán tối ưu hóa tìm kiếm ngược (BSOA) để tạo thành bộ phân lớp BSOA-SVM. Trước tiên, tín hiệu dao động gia tốc của ổ lăn được phân rã thành những IMF (Intrinsic Mode Function) bằng phương pháp EEMD. Những IMF này được phân tích giá trị riêng để tạo thành những véc tơ đầu vào cho bộ phân lớp SVM. Cuối cùng, những bộ phân lớp BSOA-SVM được dùng để phân loại các mẫu ổ lăn lỗi. Kết quả thực nghiệm cho thấy phương pháp đề xuất có thể phân loại tình trạng hoạt động của ổ lăn với độ chính xác cao và thời gian thấp khi so sánh với các phương pháp khác.

Từ khóa. Phương pháp phân tích giá trị riêng (SVD-Singular Value Decomposition), phương pháp phân rã mô hình thực nghiệm hoàn toàn (EEMD-Ensemble Empirical Mode Decomposition), thuật toán tối ưu hóa tìm kiếm ngược (BSOA-Backtracking Search Optimization Algorithm), máy véc tơ hỗ trợ (SVM-Support Vector Machine), bộ phân lớp máy véc tơ hỗ trợ dựa trên thuật BSOA (BSOA-SVM).

APPLICATION OF EEMD-SVD TECHNIQUE BSOA-SVM METHOD TO FAULT DIAGNOSIS FOR ROLLER BEARING

This study proposes a new method to diagnose roller bearing failure, in which we use EEMD (Ensemble Empirical Mode Decomposition) method combined with the singular value decomposition method (SVD) and support vector machine. (SVM). In addition, the parameters of SVM are selected through Backtracking Search Optimization Algorithm to make BSOA-SVM classifiers. First, the accelerator vibration signal is decomposed into IMF (Intrinsic Mode Function) by EEMD method. These IMFs are analyzed separately to create input vectors for SVM classifiers. Finally, BSOA-SVM classifiers are used to classify fault roller bearing patterns. Experimental results show that the proposed method can classify the conditions of roller bearings with higher accuracy and lower time when compared with other methods.

1 ĐẶT VẤN ĐỀ

Ổ lăn là chi tiết tương tác giữa bộ phận cố định và bộ phận quay của máy vì thế ổ lăn được sử dụng rộng rãi trong các ứng dụng công nghiệp và trong các phương tiện vận tải. Trong quá trình hoạt động những khuyết tật của ổ lăn sẽ dẫn đến phá hỏng của cả cụm máy hoặc dẫn đến những tai nạn nghiêm trọng. Theo thống kê, 30-40% hư hỏng của máy móc xuất phát từ ổ lăn bị khuyết tật vì thế chẩn đoán hư hỏng ổ lăn để kịp thời thay thế là rất quan trọng [1]. Các dạng khuyết tật chính của ổ lăn bao gồm hư vòng ngoài, hư vòng trong, hư bi. Nguyên nhân hư hỏng chính có thể do lỗi trong quá trình sản xuất, hao mòn tự nhiên, hao mòn do thay đổi tải đột ngột. Các phương pháp chẩn đoán khuyết tật ổ lăn bao gồm trực quan, sử dụng dụng cụ đo khoảng hở, kiểm tra bằng siêu âm, kiểm tra bằng tín hiệu âm thanh và chẩn đoán thông qua tín hiệu dao động từ ổ lăn. Hai phương pháp đầu tiên cho độ chính xác thấp và độ tin cậy không cao. Phương pháp kiểm tra bằng siêu âm đòi hỏi kinh nghiệm của kỹ thuật viên khi so sánh sóng siêu âm thu được từ ổ lăn với sóng mẫu. Bên cạnh đó, bề mặt chi tiết kiểm tra cần phải được lau chùi và cần các khớp nối để truyền năng lượng sóng siêu âm từ vật kiểm tra đến các đầu dò. Phương pháp kiểm tra bằng tín hiệu âm thanh đòi hỏi thiết bị kiểm tra phải được cách âm nghiêm ngặt để tránh nhiễu âm thanh, điều

này khó ứng dụng trong cơ khí. Phương pháp chẩn đoán thông qua tín hiệu dao động gia tốc thu thập từ các cảm biến gắn trên gối đỡ ổ lăn. Ý nghĩa của phương pháp thu thập tín hiệu này dựa trên sự thay đổi khối lượng của các chi tiết làm mô đun đàn hồi thay đổi dẫn đến gia tốc quay của các bộ phận ổ lăn cũng thay đổi.

Chẩn đoán hư hỏng ổ lăn thông qua tín hiệu dao động bao gồm ba giai đoạn: thu thập dữ liệu, trích xuất đặc tính và nhận dạng hư hỏng. Trong đó hai giai đoạn sau giữ vai trò then chốt. Trong quá trình ổ lăn hoạt động khi có hư hỏng xảy ra, các tín hiệu dao động của ổ lăn sẽ có các đặc tính không ổn định. Việc trích xuất thông tin đặc tính lỗi từ các tín hiệu dao động không ổn định là vấn đề thách thức trong chẩn đoán hư hỏng ổ lăn. Bên cạnh đó, giai đoạn nhận dạng hư hỏng cũng đòi hỏi độ chính xác và thời gian xử lý. Các nghiên cứu trước vẫn còn một số hạn chế về độ chính xác phân loại và thời gian xử lý. Vì vậy, chẩn đoán lỗi của ổ lăn đã được nghiên cứu trong bài báo này.

2 GIẢI QUYẾT VẤN ĐỀ

Phương pháp trích xuất đặc tính bao gồm phân rã tín hiệu thành các tín hiệu thành phần. Sau đó các tín hiệu này được trích xuất thành các ma trận véc tơ đặc tính. Các phương pháp phân rã tín hiệu thường dùng như biến đổi nhanh Fourier, phân rã mô hình thực nghiệm (Empirical Mode Decomposition - EMD), phân rã trung bình cục bộ (Local Mean Decomposition - LMD)[2], phân rã tỷ lệ đặc tính cục bộ (Local Characteristic-scale Decomposition)[3]. Phương pháp EMD và LCD có khuyết điểm là hiện tượng trộn lẫn mô hình (mode mixing), theo đó tín hiệu sau khi được phân rã thành các tín hiệu thành phần sẽ bao gồm cả phần nhiễu. Điều này làm giảm độ chính xác phân loại bước nhận dạng hư hỏng ở giai đoạn kế tiếp của chẩn đoán hư hỏng. Gần đây Huang và cộng sự đã đề xuất phương pháp phân rã mô hình thực nghiệm hoàn toàn (Ensemble Empirical Mode Decomposition -EEMD) nhằm khắc phục các khuyết điểm của phương pháp EMD [4].

Bước kế tiếp ma trận đặc tính được dùng làm ma trận đầu vào của bộ phân loại như mạng nơ ron nhân tạo [5] hoặc máy véc tơ hỗ trợ (SVM) [6] để nhận dạng các hư hỏng. Ưu điểm của máy véc tơ hỗ trợ so với mạng nơ ron nhân tạo là khả năng tổng quát cao với số lượng mẫu huấn luyện nhỏ. Tuy nhiên muốn bộ phân loại SVM hoạt động hiệu quả cần phải lựa chọn các thông số tối ưu C (tham số phạt) và σ (thông số kernel). Thông thường hai thông số này được lựa chọn dựa trên kinh nghiệm của người dùng. Trong các tài liệu [2, 7-9] các thông số của SVM được tối ưu bởi các thuật toán heuristic.

Trong bài báo này chúng tôi sử dụng hai bước cơ bản là trích xuất đặc tính và nhận dạng khuyết tật. Trước tiên, những tín hiệu dao động gia tốc của những ổ lăn được phân rã thành những IMF (Intrinsic Mode Function) bằng phương pháp EEMD. Bước thứ hai, phương pháp phân tích giá trị riêng (SVD) được dùng để trích chọn những IMF này thành các véc tơ đặc tính và dùng các véc tơ này làm véc tơ đầu vào cho bộ phân lớp SVM. Cuối cùng, những bộ phân lớp sử dụng thuật toán tối ưu hóa tìm kiếm ngược (Backtracking Search Optimization Algorithm- Support Vector Machine viết tắt là BSOA-SVM) được dùng để nhận dạng các mẫu ổ lăn có khuyết tật [10]. Kết quả thực nghiệm cho thấy phương pháp đề xuất có thể phân loại tình trạng hoạt động của ổ lăn với độ chính xác cao và thời gian thấp khi so sánh với các phương pháp khác.

2.1 Trích xuất đặc tính

Trích xuất đặc tính là lấy ra các thông số chính của tín hiệu dao động. Trong bài báo này chúng tôi sử dụng phương pháp EEMD kết hợp phân tích SVD dùng để trích xuất đặc tính.

2.1.1 Phương pháp EMD

Phương pháp EMD được phát triển từ giả thiết là bất kỳ một tín hiệu phức hợp đều bao gồm nhiều IMF [11]. Theo phương pháp này, mỗi tín hiệu đều có thể phân tích thành một số IMF và một phần dư r_n .

$$x(t) = \sum_{i=1}^p c_i + r_n \quad (1)$$

với p là số lượng IMF, r_n là phần dư.

2.1.2 Phương pháp EEMD

Phương pháp EMD có khuyết điểm là hiện tượng trộn lẫn mô hình (mode mixing). Hiện tượng này xảy ra khi phân rã tín hiệu $x(t)$ trong công thức (1) thành các thành phần IMF. Mỗi thành phần IMF này lại bao gồm tín hiệu thực và thành phần nhiễu. Chính thành phần nhiễu trong mỗi IMF làm giảm độ chính xác phân loại trong bước nhận dạng khuyết tật.

Để khắc phục điều này phương pháp EEMD đã được đề xuất trong nghiên cứu [12]. Ý tưởng cơ bản của phương pháp EEMD là cộng vào nhiễu trắng sẽ tạo ra toàn bộ không gian tần số-thời gian đồng nhất với các thành phần cấu thành của những tỷ lệ khác nhau. Số lượng nhiễu thêm vào và biên độ nhiễu dựa vào kinh nghiệm của người dùng. Chi tiết của phương pháp này được mô tả trong tài liệu [12]. Phương pháp EEMD bao gồm các bước sau:

(1) Khởi tạo số lượng M tín hiệu thêm vào và biên độ của nhiễu trắng thêm vào là m với $m=1$.

(2) Thực hiện m lần thử trên mỗi tín hiệu được thêm vào nhiễu trắng. Cụ thể:

(a) Thêm vào tín hiệu khảo sát một chuỗi nhiễu trắng với biên độ cho trước.

$$x_m(t) = x(t) + n_m(t) \quad (2)$$

Với $n_m(t)$ là chuỗi nhiễu trắng thêm vào thứ m , $x(t)$ là tín hiệu khảo sát, $x_m(t)$ là tín hiệu sau khi đã thêm vào nhiễu trắng của lần thử thứ m .

(b) Phân rã tín hiệu thành N các IMF bằng cách dùng phương pháp EMD đã được mô tả phía trên với $c_{i,m}$ là IMF thứ i của lần thử thứ m và N là số lượng của IMF.

(c) Nếu $m < M$ thì thực hiện lại bước (a) với $m=m+1$. Lặp lại bước (a) và (b) nhiều lần với những chuỗi nhiễu trắng khác nhau của mỗi lần thử.

(3) Tính toán giá trị tín hiệu trung bình \bar{c}_i thêm vào của M lần thử cho mỗi IMF

$$\bar{c}_i = \left(\frac{1}{M}\right) \sum_{m=1}^M c_{i,m}, i = 1, 2, \dots, N, \text{ với } m = 1, 2, \dots, M \quad (3)$$

(4) Mỗi giá trị \bar{c}_i với $i = 1, 2, \dots, N$ của mỗi IMF chính là các IMF thu được cuối cùng.

2.1.3. Phương pháp SVD

Phương pháp SVD là phương pháp phân rã một ma trận thành tích số của ba ma trận thành phần. Ý nghĩa của phương pháp này là nhằm đưa ma trận lớn, phức tạp về bài toán nhỏ hơn.

$$\Sigma = E\Delta V^T \quad (4)$$

với $E = [e_1, e_2, e_3, \dots, e_n] \in R^{N \times N}, E^T E = I, V = [v_1, v_2, v_3, \dots, v_n] \in R^{M \times M}, V^T V = I, \Delta R^{N \times M}$,

Trong đó:

E, V^T là các ma trận trực giao cấp $m \times r$

Δ là ma trận đường chéo có các giá trị suy biến $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$

Những giá trị λ_i là giá trị đơn của ma trận Σ .

Sau đó những tín hiệu dao động ồ lẩn được phân rã thành những IMF bởi thuật toán EEMD và được chia thành hai nhóm ma trận véc tơ đặc tính ban đầu X và Y .

$$X = \begin{bmatrix} imf_1 \\ imf_2 \\ \vdots \\ imf_J \end{bmatrix}; Y = \begin{bmatrix} imf_{J+1} \\ imf_{J+2} \\ \vdots \\ imf_{J+n} \end{bmatrix} \quad (5)$$

với $J = n/2$ (khi n là số lẻ), $J = (n + 1)/2$ (khi n là số chẵn). Những đặc tính của tín hiệu dao động ồ lẩn $x(t)$ có thể được trích xuất từ những ma trận véc tơ đặc tính ban đầu X và Y . Từ những ma trận này có thể thu được các giá trị đơn. Các giá trị đơn này được dùng làm các véc tơ đặc trưng cho hư hỏng ồ lẩn.

2.2 Nhận dạng khuyết tật

Các thông số chính của tín hiệu dao động thu được từ bước trích xuất đặc tính được đưa vào bộ phân loại máy véc tơ hỗ trợ (SVM). Tuy nhiên máy véc tơ hỗ trợ có khuyết điểm là việc lựa chọn hai tham số C và

σ đòi hỏi kinh nghiệm của người dùng. Trong bài báo này chúng tôi sử dụng thuật toán BSOA để tối ưu hai thông số trên.

2.2.1. Máy véc tơ hỗ trợ

SVM là kỹ thuật học máy mạnh dựa trên lý thuyết học thống kê. Đây là phương pháp học có giám sát. Ý tưởng cơ bản của SVM là ánh xạ những mẫu huấn luyện từ không gian đầu vào sang một không gian đặc tính có số chiều cao hơn bằng cách sử dụng một hàm ánh xạ φ [9]. Giả thiết rằng cho trước một tập mẫu huấn luyện $G = \{x_i, y_i\}$, $i = 1, 2, \dots, l$, với mỗi mẫu thuộc một lớp $y \in \{+1, -1\}$ và dữ liệu huấn luyện phi tuyến không thể phân chia trong không gian đặc tính, hàm mục tiêu có thể được biểu diễn như sau [13]:

$$\begin{cases} \text{minimize} & \varphi(\omega) = \frac{1}{2}(\omega \cdot \omega) + C \sum_{i=1}^l \xi_i \\ \text{s. t} & y_i((\omega \cdot \varphi(\omega)) + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = \{1, 2, \dots, l\} \end{cases} \quad (6)$$

với ω là véc tơ pháp tuyến của siêu mặt; C là tham số; b là độ lệch và là một vô hướng; ξ_i là những biến bù không âm; $\varphi(x)$ là hàm ánh xạ.

Đưa vào những nhân tử Lagrange $\alpha_i \geq 0$, bài toán tối ưu có thể được viết lại như sau:

$$\begin{aligned} \max & L(\omega, b, \alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \\ \text{s. t} & \sum_{i=1}^l \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, l \end{aligned} \quad (7)$$

với $K(x_i, x_j)$ là hàm kernel.

Hàm quyết định siêu phẳng tối ưu (hyperplan) có thể thu được theo [9]

$$f(x) = \text{sgn}[\sum_{i=1}^l \alpha_i y_i K(x, x_i) + b] \quad (8)$$

Hàm kernel thường dùng trong SVM là hàm RBF (radial basis function), được biểu diễn trong công thức sau [13, 14]

$$K(x, x_i) = \exp(-\|x - x_i\|^2 / 2\sigma^2) \quad (9)$$

với σ là thông số kernel.

Thông số C trong công thức (6) và σ trong công thức (9) được chọn lựa bằng thuật toán tối ưu hóa tìm kiếm ngược BSOA.

2.2.2. Thuật toán tối ưu hóa tìm kiếm ngược (BSOA)

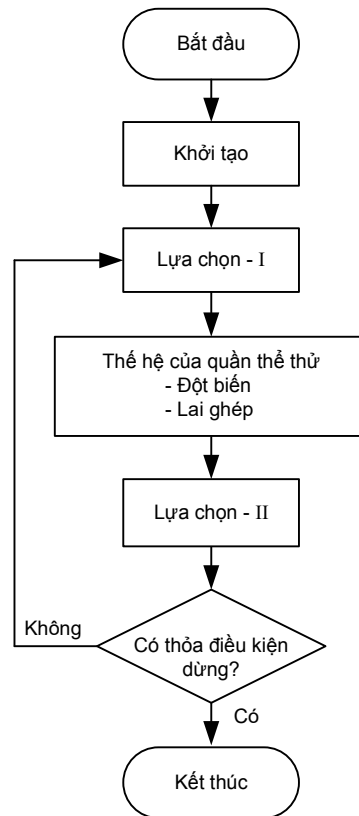
Thuật toán BSOA là một thuật toán tìm kiếm thích ứng bao gồm ba toán tử di truyền cơ bản bao gồm đột biến, lai ghép và lựa chọn để tạo ra những cá thể thử. Thuật toán BSOA bao gồm sáu bước như sau [10]: (i) Định nghĩa bài toán và những thông số của thuật toán; (ii) Khởi tạo; (iii) Lựa chọn-I; (iv) Lai ghép và đột biến; (v) Lựa chọn-II; (vi) Kết thúc. Tiến trình của thuật toán BSOA được biểu diễn như trong Hình 1.

Định nghĩa bài toán và các thông số của thuật toán

$$\text{Cực tiểu hàm } f(x) \quad (10)$$

sao cho $x_i \in D_i = [l_i, u_i]$, $i = 1, 2, \dots, M$

Trong công thức trên, $f(x)$ là một hàm mục tiêu (fitness function); $\mathbf{x} = (x_1, x_2, \dots, x_N)$ là véc tơ các biến độc lập; M là số lượng biến độc lập; D_i , l_i và u_i lần lượt là vùng chứa giá trị khả thi, biên dưới và biên trên của biến độc lập thứ i .



Hình 1. Sơ đồ khối của thuật toán BSOA.

2.2.2. Tối ưu hóa thông số SVM bằng thuật toán BSOA

Độ chính xác phân loại được quyết định bởi sự lựa chọn các thông số tối ưu của SVM. Những thông số hàm kernel Gaussian bao gồm một nhân tố phạt C và thông số kernel σ . Việc lựa chọn những thông số SVM không phải là công việc dễ dàng. Thông thường, C và σ được lựa chọn dựa trên kinh nghiệm vì thế dẫn đến những kết quả phân loại không tối ưu. Trong bài báo này thuật toán BSOA được dùng để tối ưu C và σ . Hàm mục tiêu là lỗi kiểm tra của SVM. Lỗi kiểm tra của SVM được biểu diễn như sau:

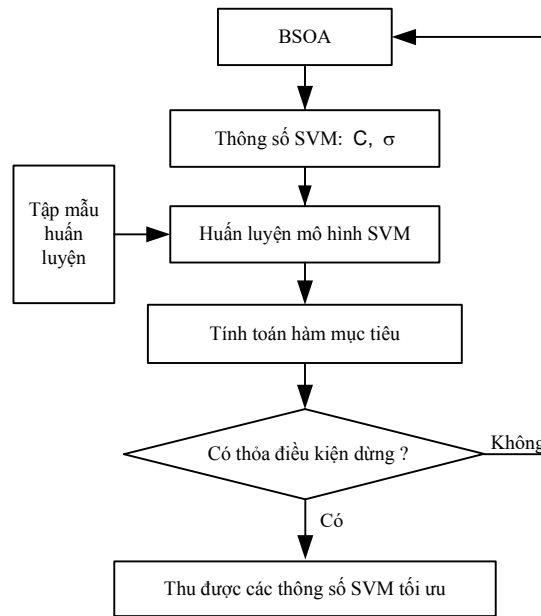
$$G(x) = LKT_{SVM}(x) \quad (11)$$

trong đó $G(x)$ hàm mục tiêu, LKT_{SVM} là lỗi kiểm tra và $x = \{C, \sigma\}$

Trong công thức (11) lỗi kiểm tra của SVM được định nghĩa:

$$LKT_{SVM} = \text{Số lượng mẫu sai trong những mẫu kiểm tra} / \text{Tổng số của mẫu trong tập kiểm tra} \quad (12)$$

Mô hình BSOA-SVM bao gồm bốn bước, được biểu diễn như Hình 2: (i) Khởi tạo những giá trị C và σ ; (ii) Huấn luyện những tập dữ liệu mẫu với những giá trị C và σ được tạo ra. (iii) Tính toán hàm mục tiêu; (iv) Lặp lại vòng lặp cho đến khi đạt được điều kiện dừng.



Hình 2. Sơ đồ thuật toán BSOA-SVM.

3 THỰC NGHIỆM

Sơ đồ giải thuật của phương pháp chẩn đoán trong bài báo này được minh họa trong Hình 3. Các bước tiến hành thực nghiệm như sau:

- (1) Dùng bộ đo gia tốc dao động, lấy mẫu N lần tại một tần số lấy mẫu cố định dưới những điều kiện làm việc như điều kiện bình thường, hư vòng ngoài, hư vòng trong. Tất cả những mẫu tín hiệu dao động được chia thành hai nhóm gồm nhóm mẫu huấn luyện và kiểm tra.
- (2) Mỗi tín hiệu mẫu được phân rã bởi phương pháp EEMD và thu được chuỗi các IMF . Số lượng tín hiệu thêm vào là 500 và biên độ nhiễu trắng là 0.2 dựa trên tài liệu [4].
- (3) Tạo ma trận véc tơ đặc tính đầu vào A cho mỗi tín hiệu dao động ồ lẩn của mỗi tình trạng làm việc

$$A = \begin{bmatrix} IMF_1 \\ IMF_2 \\ \vdots \\ IMF_J \end{bmatrix} \quad (13)$$

với J là số lượng IMF

- (4) Thu được các giá trị riêng λ của ma trận đặc tính đầu vào A bằng cách sử dụng kỹ phương pháp SVD.

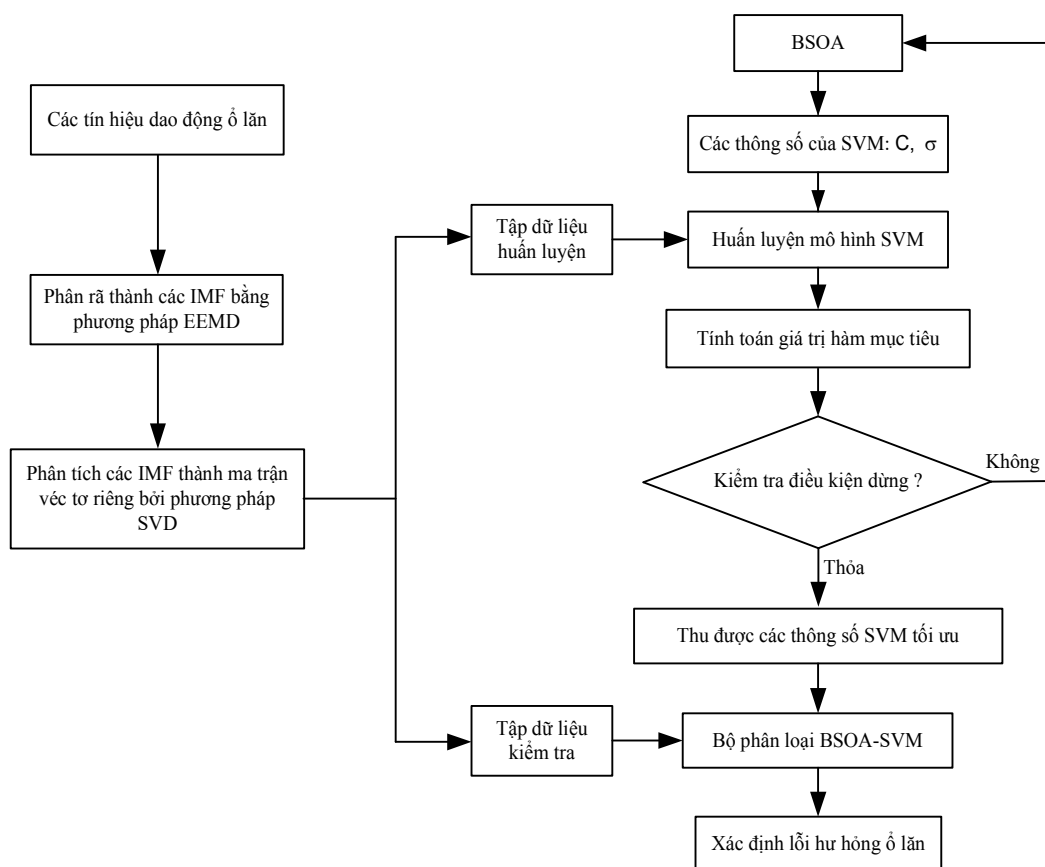
$$\lambda = [\lambda_1, \lambda_2, \dots, \lambda_J] \quad (14)$$

với

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_J \geq 0$$

J là số lượng các giá trị riêng.

- (5) Thiết kế bộ phân lớp BSOA-SVM và nhận dạng hư hỏng của ồ lẩn.



Hình 3. Sơ đồ thuật toán EEMD-SVD và BSOA-SVM.

3.1. Thu thập dữ liệu


Dữ liệu được thu thập từ trang web của trung tâm dữ liệu ổ lăn thuộc Đại học Case Western Reserve dưới sự cho phép của giáo sư K. A. Loparo [15]. Cách bố trí băng thử được thực hiện như Hình 4. Các ổ lăn được tạo hư hỏng bằng cách cắt các rãnh có độ sâu từ 0.007 đến 0.004 inch theo chiều hướng kính để tạo ra ba nhóm hư hỏng bao gồm hư vòng trong, hư vòng ngoài và hư bi. Tần số lấy mẫu ở 243938 Hertz tại tốc độ 1796 vòng/ phút. Loại ổ lăn được sử dụng là SKF mã 6205-2RS JEM. Bốn nhóm ổ lăn (hư vòng trong, hư vòng ngoài, hư bi và bình thường) được thu thập dữ liệu với mỗi tình trạng là 110 mẫu. Chọn ngẫu nhiên ra hai phần ba mẫu tín hiệu để huấn luyện và một phần ba để kiểm tra.

3.2. Ứng dụng


Mỗi bộ SVM chỉ phân lớp được hai tình trạng ổ lăn do vậy chúng tôi sử dụng 3 bộ BSOA-SVM để nhận dạng 4 tình trạng của ổ lăn như Hình 5. Bộ BSOA-SVM₁ dùng để nhận dạng ổ lăn hư vòng trong (nhãn là (+1)) và các tình trạng còn lại (nhãn là (-1)). Sau lần phân loại thứ nhất số mẫu còn lại là 330 mẫu do đã tách ra 110 mẫu của nhóm ổ lăn hư vòng trong. Phần còn lại được đưa qua bộ BSOA-SVM₂ để nhận dạng ổ lăn hư vòng ngoài (nhãn là (+1)) và tình trạng còn lại (nhãn là (-1)). Sau lần phân loại thứ hai số mẫu còn lại là 220 mẫu. Cuối cùng bộ BSOA-SVM₃ sẽ nhận dạng ổ lăn hư bi (nhãn là (+1)) và phần còn lại là ổ lăn bình thường (nhãn là (-1)). Sơ đồ nguyên lý hoạt động của bộ phân loại BSOA-SVM được trình bày trong Hình 5.

4 KẾT QUẢ VÀ THẢO LUẬN

Bảng 1 trình bày chi tiết kết quả phân loại tình trạng ổ lăn bằng phương pháp EEMD-SVD và BSOA-SVM. Tình trạng của ổ lăn được chia làm 4 loại, lần lượt là hư vòng trong, hư vòng ngoài, hư bi và bình thường. Giá trị trong Bảng 1 là giá trị trung bình của 30 lần chạy thuật toán tối ưu. Kết quả cho thấy tín hiệu dao động của ổ lăn sau khi được phân rã thành từng IMF kết hợp với trích chọn các thông số bởi mô hình SVD đã tạo giá trị đầu vào tốt cho bộ phân lớp SVM. Thêm vào đó, bộ phân lớp SVM với các thông số đã được tối ưu bởi thuật toán BSOA đã phân loại các mẫu kiểm tra thành từng nhóm riêng biệt. Để thấy rõ sự khác biệt của phương pháp đề xuất, chúng tôi cũng đồng thời thiết kế bộ phân lớp GA-SVM (sử dụng thuật toán di truyền) và PSO-SVM (sử dụng thuật toán bầy đàn) làm các đối tượng so sánh. Bảng 2 thể hiện kết quả phân lớp trên tập kiểm tra của các phương pháp được sử dụng. Theo đó, kết quả ở Bảng 2 cho thấy phương pháp đề xuất cho kết quả phân loại cao hơn cùng với thời gian ngắn hơn so với các phương pháp như EEMD-SVD-GA-SVM và EEMD-SVD-PSO-SVM.



Hình 4. Băng thử ổ lăn [15].



Hình 5. Sơ đồ thuật toán chẩn đoán hư hỏng ổ lăn bằng nhiều bộ phân lớp BSOA-SVM.

5 KẾT LUẬN

Bài báo đã đề xuất một mô hình chẩn đoán hư hỏng ổ lăn dựa trên máy véc tơ hỗ trợ SVM kết hợp với phương pháp trích chọn đặc trưng SVD. Bên cạnh đó, các thông số của SVM cũng được tối ưu bằng thuật toán BSOA giúp rút ngắn thời gian phân lớp và tăng cường độ chính xác của bộ phân lớp SVM. Các tín hiệu dao động ổ lăn được phân tích thành những IMF bằng phương pháp EEMD tạo thuận lợi cho việc trích chọn các thông số đặc trưng bằng phương pháp SVD ở bước tiếp theo. Các kết quả thực nghiệm cho thấy việc áp dụng phương pháp phân lớp BSOA-SVM kết hợp với việc trích chọn các thông số đặc trưng bằng phương pháp SVD vào bài toán chẩn đoán khuyết tật ổ lăn đạt độ chính xác cao và thời gian ngắn hơn khi so sánh với các phương pháp EEMD-SVD-GA-SVM hoặc EEMD-SVD-PSO-SVM.

Bảng 1: Kết quả phân loại hư hỏng ổ lăn bằng phương pháp EEMD-SVD và BSOA-SVM.

Mẫu kiểm tra	Giá trị đơn của đặc tính lỗi $\lambda_{x,x}$				BSOA-SVM ₁	BSOA-SVM ₂	BSOA-SVM ₃	Kết quả nhận dạng
(1) Hư vòng trong	8.3688	3.4794	1.8740	0.7525	(+1)			Hư vòng trong
(2) Hư vòng trong	7.9926	3.6306	2.1178	0.5437	(+1)			Hư vòng trong
(3) Hư vòng trong	8.2909	3.4952	2.1176	0.5795	(+1)			Hư vòng trong
(4) Hư vòng trong	8.3008	3.5721	2.0999	0.6860	(+1)			Hư vòng trong
(5) Hư vòng trong	8.4828	3.5163	2.0146	0.6118	(+1)			Hư vòng trong
(6) Hư vòng trong	8.1277	3.5373	2.0276	0.6471	(+1)			Hư vòng trong
(7) Hư vòng ngoài	7.8281	1.2276	0.8300	0.3407	(-1)	(+1)		Hư vòng ngoài
(8) Hư vòng ngoài	7.7405	1.2846	0.9411	0.4307	(-1)	(+1)		Hư vòng ngoài
(9) Hư vòng ngoài	7.5634	1.2106	0.8123	0.4441	(-1)	(+1)		Hư vòng ngoài
(10) Hư vòng ngoài	7.6344	1.0908	0.8268	0.4483	(-1)	(+1)		Hư vòng ngoài
(11) Hư vòng ngoài	7.7749	1.1739	0.8225	0.4465	(-1)	(+1)		Hư vòng ngoài
(12) Hư vòng ngoài	9.0698	1.4099	0.8481	0.4820	(-1)	(+1)		Hư vòng ngoài
(13) Hư bi	4.1805	0.7672	0.8116	0.3049	(-1)	(-1)	(+1)	Hư bi
(14) Hư bi	3.9870	0.8197	0.9460	0.3256	(-1)	(-1)	(+1)	Hư bi
(15) Hư bi	4.2638	0.8009	0.8394	0.2687	(-1)	(-1)	(+1)	Hư bi
(16) Hư bi	3.7106	0.8205	0.8263	0.3059	(-1)	(-1)	(+1)	Hư bi
(17) Hư bi	4.0366	0.7989	0.8829	0.3581	(-1)	(-1)	(+1)	Hư bi
(18) Hư bi	4.3475	0.7789	0.8561	0.3475	(-1)	(-1)	(+1)	Hư bi
(19) Bình thường	1.4208	0.7265	0.7713	0.3976	(-1)	(-1)	(-1)	Bình thường
(20) Bình thường	1.3549	0.6610	0.5822	0.4118	(-1)	(-1)	(-1)	Bình thường
(21) Bình thường	1.3042	0.7038	0.7461	0.4271	(-1)	(-1)	(-1)	Bình thường
(22) Bình thường	1.4459	0.7040	0.6723	0.3477	(-1)	(-1)	(-1)	Bình thường
(23) Bình thường	1.3649	0.6854	0.7166	0.3536	(-1)	(-1)	(-1)	Bình thường
(24) Bình thường	1.4979	0.6509	1.1465	0.4271	(-1)	(-1)	(-1)	Bình thường

Bảng 2: Kết quả phân lớp hư hỏng ổ lăn của phương pháp EEMD-SVD-BSOA-SVM so sánh với phương pháp EEMD-SVD-GA-SVM và EEMD-SVD-PSO-SVM.

Method	Training samples	Test samples	Optimal C	Optimal σ	Cost time (s)	Average Error Rate (%)
BSOA-SVM ₁	308	132	645.80	6.15	48.37	0
PSO-SVM ₁	308	132	15082.25	17.55	58.10	0
GA-SVM ₁	308	132	179.17	9.89	61.17	0
BSOA-SVM ₂	241	99	18230.57	16.23	45.19	0
PSO-SVM ₂	241	99	18839.57	21.04	54.80	0.2357
GA-SVM ₂	241	99	12716.35	22.14	56.58	0.2357
BSOA-SVM ₃	154	66	13764.40	7.94	31.95	0
PSO-SVM ₃	154	66	19094.51	20.23	35.41	0
GA-SVM ₃	154	66	21648.31	30.25	42.76	0

TÀI LIỆU THAM KHẢO

- [1] R. B. Randall and J. Antoni, "Rolling element bearing diagnostics—A tutorial," *Mechanical Systems and Signal Processing*, vol. 25, pp. 485-520, 2011/02/01/ 2011.
- [2] H. Ao, et al., "The support vector machine parameter optimization method based on artificial chemical reaction optimization algorithm and its application to roller bearing fault diagnosis," *Journal of Vibration and Control*, vol. 21, pp. 2434-2445, 2015/09/01 2013.

- [3] S. Luo, et al., "Application of LCD-SVD Technique and CRO-SVM Method to Fault Diagnosis for Roller Bearing," *Shock and Vibration*, vol. 2015, p. 8, 2015.
- [4] Z. Wu and N. E. Huang, "Ensemble Empirical Mode Decomposition: a Noise-Assisted Data Analysis Method," *Advances in Adaptive Data Analysis*, vol. 1, pp. 1-41, 2009.
- [5] Y. Yu, et al., "A roller bearing fault diagnosis method based on EMD energy entropy and ANN," *Journal of Sound and Vibration*, vol. 294, pp. 269-277, 2006/06/27/ 2006.
- [6] X. Zhang, et al., "Support vector machine with parameter optimization by a novel hybrid method and its application to fault diagnosis," *Neurocomputing*, vol. 149, pp. 641-651, 2015/02/03/ 2015.
- [7] H. Ao, et al., "Roller Bearing Fault Diagnosis Method Based on Chemical Reaction Optimization and Support Vector Machine," *Journal of Computing in Civil Engineering*, vol. 2014, pp. 1-13, 2014.
- [8] F. Ardjani, et al., "Optimization of SVM MultiClass by Particle Swarm (PSO-SVM)," presented at the Database Technology and Applications, 2010.
- [9] X. Zhang, et al., "An ACO-based algorithm for parameter optimization of support vector machines," *Expert Systems with Applications*, vol. 37, pp. 6618-6628, 2010.
- [10] P. Civicioglu, "Backtracking Search Optimization Algorithm for numerical optimization problems," *Applied Mathematics and Computation*, vol. 219, pp. 8121-8144, 2013.
- [11] N. E. Huang, et al., "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," *Proceedings of The Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 454, pp. 903-995, 1998.
- [12] Z. Wu and N. E. Huang, "Ensemble empirical mode decomposition: a noise-assisted data analysis method," *Advances in Adaptive Data Analysis*, vol. 01, pp. 1-41, 2009.
- [13] V. N. Vapnik, *The Nature of Statistical Learning Theory*; Springer: New York, 1995.
- [14] A. Aizerman, et al., "Theoretical foundations of the potential function method in pattern recognition learning," *Automation and Remote Control*, vol. 25, pp. 821-837, 1964.
- [15] K. A. Loparo. Bearings Vibration Data Set. Available: <<http://www.eecs.case.edu/laboratory/bearing/download.htm>> Ngày truy cập: 10/12/2018

Ngày nhận bài: 06/08/2019

Ngày chấp nhận đăng: 20/12/2019