

PHƯƠNG PHÁP CHẨN ĐOÁN HƯ HỒNG Ồ LẤN DỰA TRÊN THUẬT TOÁN AEDE-SVM VÀ VMD-SVD

AO HÙNG LINH

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

DOIs: <https://doi.org/10.46242/jstiuh.v57i03.4387>

Tóm tắt. Bài báo này giới thiệu một phương pháp mới để chẩn đoán hư hỏng ổ lăn dựa trên máy véc tơ hỗ trợ (SVM) với các thông số được tối ưu bởi thuật toán tiến hóa vi phân thích ứng (AEDE). Trước tiên, những tín hiệu dao động gia tốc của ổ lăn được phân rã thành các hàm thành phần bằng phương pháp phân rã mô hình biến đổi (VMD). Sau đó các hàm thành phần được trích xuất thành các ma trận đặc tính nhờ phương pháp phân rã giá trị đơn (SVD) để thu được các giá trị đơn. Thứ ba, các ma trận đặc tính này được dùng làm ma trận đầu vào cho bộ phân loại AEDE-SVM. Kết quả thực nghiệm cho thấy phương pháp đề xuất cho độ chính xác phân loại cao (100%) và thời gian ngắn hơn so với các phương pháp khác.

Từ khóa. Phương pháp phân rã mô hình biến đổi, Chẩn đoán hư hỏng, ổ lăn, phân rã giá trị đơn, Máy véc tơ hỗ trợ.

1 GIỚI THIỆU

Ổ lăn là chi tiết trung gian giữa bộ phận quay và bộ phận cố định. Hư hỏng ổ lăn sẽ dẫn đến hư hỏng nghiêm trọng của máy vì thế chẩn đoán hư hỏng ổ lăn giữ vai trò quan trọng để bảo đảm sự hoạt động liên tục của hệ thống.

Chẩn đoán hư hỏng ổ lăn bao gồm 3 giai đoạn: Thu thập dữ liệu, trích xuất đặc tính và nhận dạng vật thể trong đó 2 giai đoạn sau giữ vai trò then chốt. Khi xảy ra hư hỏng ổ lăn việc trích xuất thông tin đặc tính lỗi là việc không dễ dàng vì tín hiệu dao động của ổ lăn là tín hiệu không dừng.

Trích xuất đặc tính bao gồm phân rã tín hiệu và trích xuất đặc trưng. Các phương pháp phân rã tín hiệu bao gồm phân rã mô hình thực nghiệm (Empirical Mode Decomposition - EMD)[1], phân rã giá trị trung bình (Local Mean Decomposition - LMD)[2]. Các phương pháp này có điểm chung là phân rã một tín hiệu dao động thành tổng các tín hiệu thành phần và phần dư. Tuy nhiên phương pháp EMD và LMD có các khuyết điểm như hiệu ứng đoạn cuối (end effect), trộn lẫn mô hình (mode mixing). Các hiệu ứng này làm cho kết quả phân rã tín hiệu kém hiệu quả. Nên các phương pháp này không tự thích ứng với các tín hiệu đặc biệt là tín hiệu dao động ổ lăn. Gần đây tác giả K. Dragomiretskiy với cộng sự đã đề xuất phương pháp phân rã mô hình biến đổi (Variational Mode Decomposition -VMD) để phân rã tín hiệu[3]. Phương pháp này khắc phục được khuyết điểm của phương pháp EMD, LMD và cho hiệu quả cao.

Các tín hiệu thành phần được trích xuất đặc trưng để tạo thành các ma trận đặc tính bằng cách sử dụng các phương pháp phân tích tỷ lệ tần số [4], entropy năng lượng [5], phân rã giá trị đơn (Singular value decomposition-SVD)[6]. Giai đoạn trích xuất đặc trưng nhằm làm giảm kích thước đầu vào cho bước nhận dạng vật thể.

Các phương pháp nhận dạng vật thể bao gồm dùng hàm biệt thức (Variable predictive model class discrimination -VPMCD)[7], mạng nơ ron thần kinh nhân tạo (Artificial Neuron Network-ANN)[8] và máy véc tơ hỗ trợ (Support vector machine -SVM)[9]. VPMCD có khuyết điểm là khó thiết lập các thông số biến của mô hình. Phương pháp máy véc tơ hỗ trợ có ưu điểm so với ANN là có khả năng tổng quát cao với số lượng mẫu huấn luyện nhỏ. Điều này rất phù hợp khi xử lý các bài toán kỹ thuật vốn rất tốn kém khi thu thập số lượng mẫu lớn. Tuy nhiên thách thức cho người dùng SVM là việc lựa chọn các thông số của mô hình này. Thông thường việc lựa chọn các thông số này dựa trên kinh nghiệm hoặc các thuật toán tìm kiếm heuristic. Các thuật toán heuristic thường dùng để lựa tìm kiếm các thông số cho SVM như thuật toán di truyền (Genetic Algorithm), thuật toán tối ưu hóa bầy đàn (Particle Swarm Optimization-PSO), thuật toán tiến hóa vi phân (Differential Evolution-DE). Gần đây thuật toán tiến hóa vi phân thích ứng (Adaptive Elitist Differential Evolution-AEDE) được đề xuất cho bài toán tối ưu [10]. Thuật toán tiến hóa vi phân thích ứng cho thấy ưu điểm vượt trội trong việc giải quyết bài toán tối ưu khi so sánh với thuật toán GA,

PSO. Vì vậy trong bài báo này chúng tôi đề xuất dùng thuật toán tiến hóa vi phân thích ứng làm công cụ lựa chọn các thông số cho bộ phân loại SVM.

Trong bài báo này chúng tôi sử dụng phương pháp VMD kết hợp phân rã giá trị riêng (SVD) để trích xuất đặc tính và AEDE-SVM để nhận dạng hư hỏng. Trước tiên các tín hiệu dao động gia tốc của ổ lăn được phân rã thành các tín hiệu phụ bởi phương pháp VMD. Sau đó các tín hiệu phụ này được trích chọn thành ma trận đặc tính bởi phương pháp SVD. Các ma trận đặc tính được dùng làm ma trận đầu vào cho bộ phân loại SVM. Các thông số của SVM được tối ưu hóa bởi thuật toán AEDE để tạo ra bộ phân loại AEDE-SVM. Kết quả thực nghiệm cho thấy bộ phân loại AEDE-SVM cho kết quả phân loại cao hơn và thời gian ngắn hơn khi so sánh với bộ phân loại GA-SVM và PSO-SVM với cùng dữ liệu đầu vào. Bài báo được bố cục như sau: mục 2 trình bày thuật toán tiến hóa vi phân thích ứng, mục 3 trình bày tối ưu hóa thông số SVM dựa trên AEDE. Mục 4 trình bày ứng dụng AEDE-SVM để chẩn đoán hư hỏng ổ lăn và quá trình thực nghiệm cùng với kết quả được trình bày trong mục 5. Mục 6 trình bày Kết luận của bài báo.

2 THUẬT TOÁN TIẾN HÓA VI PHÂN THÍCH ỨNG (AEDE)

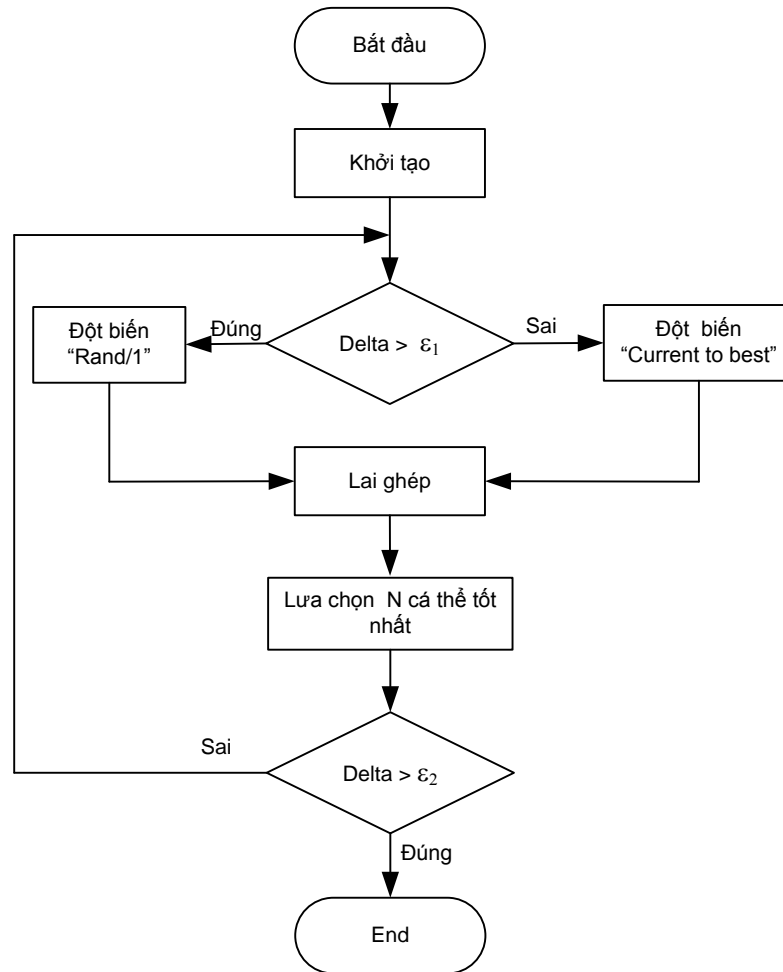
Thuật toán tiến hóa vi phân thích ứng là một phiên bản cải tiến của thuật toán tiến hóa vi phân (DE) với hai cải tiến trong giai đoạn đột biến và giai đoạn lựa chọn để nâng cao khả năng lựa chọn và tối ưu hóa cho các biến rời rạc. Trong tính toán tiến hóa, DE là một phương pháp tối ưu hóa bằng cách liên tục cải tiến một giải pháp ứng viên liên quan đến chất lượng. Trên thực tế, đây là một quá trình lặp đi lặp lại bao gồm các quá trình khởi tạo, đột biến, lai ghép và lựa chọn để tìm ra giải pháp tìm kiếm toàn cục cho các vấn đề tối ưu hóa chung. Tuy nhiên, các tham số DE ví dụ yếu tố đột biến, tham số điều khiển chéo và các chiến lược tạo vectơ thử nghiệm có tác động đáng kể đến hiệu suất của thuật toán. Để khắc phục những hạn chế phổ biến của các thuật toán tối ưu hóa, chẳng hạn như sử dụng một lượng lớn tài nguyên cũng như chi phí tính toán cao, AEDE đã được đề xuất với hai cải tiến. Kỹ thuật đầu tiên là kỹ thuật thích nghi dựa trên sự khác biệt của hàm mục tiêu giữa cá thể tốt nhất và toàn bộ quần thể ở thế hệ trước - được áp dụng trong giai đoạn đột biến để cải thiện khả năng tìm kiếm. Kỹ thuật thứ hai là kỹ thuật tối ưu để chọn ra những cá thể tốt nhất cho thế hệ tiếp theo được áp dụng trong giai đoạn chọn lọc nhằm nâng cao khả năng tìm kiếm và tăng tỷ lệ hội tụ.

Sơ đồ đột biến thích nghi mới của AEDE sử dụng hai toán tử đột biến. Loại đầu tiên là "rand / 1" nhằm mục đích đảm bảo sự đa dạng của quần thể và ngăn cá thể bị mắc kẹt ở một vị trí tối ưu cục bộ. Phương pháp thứ hai là "current-to-best / 1" giúp tăng tốc độ hội tụ của quần thể bằng cách dẫn dắt quần thể đến những cá thể tốt nhất. Mặt khác, cơ chế chọn lọc mới luôn tìm kiếm và lưu trữ những cá thể tốt nhất của cả quần thể để làm dữ liệu tham khảo cho việc định hướng thế hệ tiếp theo, giúp gắn chặt sự hội tụ. Lưu đồ thuật toán AEDE thể hiện trong Hình 1. Thông số delta được tính bằng độ lệch giữa trung bình các cá thể trong dân số và cá thể tốt nhất. Khi các cá thể này hội tụ về một điểm thì trung bình và giá trị "best" càng gần nhau. Epsilon là số thực rất nhỏ, được xem như là ngưỡng quyết định. Khi delta nhỏ hơn epsilon các cá thể đã xem như hội tụ về 1 điểm, thuật toán được dừng.

3 TỐI ƯU HÓA THÔNG SỐ SVM DỰA TRÊN AEDE

3.1 Máy véc tơ hỗ trợ

Máy véc tơ hỗ trợ được giới thiệu lần đầu tiên được giới thiệu bởi V. N. Vapnik và đã trở thành một trong những loại máy học phổ biến nhất dựa trên lý thuyết học thống kê. Đây là một phương pháp học có giám sát với các thuật toán học liên quan được sử dụng để phân loại và phân tích hồi quy. Bằng ý tưởng cơ bản là tách miền bài toán cho trước thành hai nửa không gian có dấu nghịch nhau (không gian dương và âm) chỉ bằng một số chỉ báo, được gọi là vectơ hỗ trợ. SVM cho thấy ưu điểm vượt trội trong dữ liệu nhiễu và hiệu suất vượt trội [9]. Tuy nhiên, việc lựa chọn các tham số SVM có ảnh hưởng mạnh đến độ chính xác của kết quả phân loại không bao giờ là một nhiệm vụ dễ dàng.



Hình 1 Lưu đồ thuật toán AEDE

SVM nhị phân tiêu chuẩn chấp nhận các vectơ đầu vào và phân loại chúng thành hai lớp khác nhau bằng một hàm dấu. Bằng cách sử dụng hàm ánh xạ Φ , SVM thực sự ánh xạ các mẫu huấn luyện từ không gian đầu vào thành không gian đặc trưng có chiều cao hơn để tăng khả năng phân tách lớp. Giả sử rằng có một tập mẫu huấn luyện $G = \{(x_i, y_i); i = 1, 2, \dots, l\}$, trong đó mỗi mẫu $x_i \in \mathbb{R}_d$ thuộc về một lớp của $y \in \{+1; -1\}$; và dữ liệu đào tạo không được phân tách rõ ràng trong không gian tính năng đầu vào, khi đó hàm mục tiêu được viết như sau:

$$\text{Cực tiểu } \phi(\omega) = \frac{1}{2} \langle \omega | \omega \rangle + C \sum_{i=1}^l \xi_i \quad (1)$$

$$\text{sao cho } y_i(\langle \omega, \phi(x_i) \rangle + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, i = \{1, 2, \dots, l\} \quad (2)$$

với ω là véc tơ pháp tuyến của siêu mặt, C là thông số phạt, b là độ lệch, ξ_i là những biến bù không âm và $\Phi(x)$ là hàm ánh xạ.

Bằng cách áp dụng nhân tử Lagrange không âm $\alpha_i \geq 0$, bài toán tối ưu hóa có thể được viết lại như sau:

$$\text{Cực đại } L(\omega, b, \alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3)$$

$$\text{sao cho } 0 \leq \alpha_i \leq C, \sum_{i=1}^l \alpha_i y_i = 0 \quad (4)$$

Hàm quyết định được biểu diễn:

$$f(x) = \text{sgn}[\sum_{i=1}^l \alpha_i y_i K(x_i, x) + b] \quad (5)$$

Trong công thức (5) hàm kernel được dùng là hàm “radial basis” được dùng để chuyển miền bài toán ban đầu sang miền Gaussian theo công thức sau:

$$K(x, x_i) = \exp\left(\frac{-\|x-x_i\|^2}{2\sigma^2}\right) \quad (6)$$

với σ là thông số kernel.

3.2 TỐI ƯU CÁC THÔNG SỐ SVM DỰA TRÊN AEDE

Như đã đề cập trong các nghiên cứu trước đây, các tham số SVM ảnh hưởng mạnh đến hiệu suất phân lớp. Việc lựa chọn các thông số tối ưu cho SVM chủ yếu dựa trên kinh nghiệm của người dùng. Trong bài báo này, chúng tôi đề xuất dùng AEDE để tối ưu hóa các thông số SVM.

Thông số phạt C và tham số kernel σ trong hàm nhân Gaussian được coi là các biến tối ưu hóa trong khi lỗi kiểm tra là phép đo phù hợp của bài toán tối ưu hóa. Hàm mục tiêu là lỗi kiểm tra của SVM và được biểu diễn như sau:

$$G(x) = LKT_{SVM}(x) \quad (7)$$

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

Trong công thức (7) lỗi kiểm tra của SVM được định nghĩa:

$$LKT_{SVM} = \text{Số lượng mẫu sai trong những mẫu kiểm tra} / \text{Tổng số của mẫu trong tập kiểm tra} \quad (8)$$

Nói chung, thuật toán AEDE đã được tích hợp vào quy trình huấn luyện SVM để có được các tham số tối ưu nhằm tối đa hóa độ chính xác phân loại và khả năng tổng quát hóa của SVM. Ban đầu, mỗi cá thể ở thế hệ đầu tiên được lấy ngẫu nhiên. Thuật toán SVM thường tính toán ma trận trọng số đầu ra tương ứng cho từng cá thể. Sau đó, AEDE có thể được áp dụng để tìm số đo giá trị tốt nhất cho từng cá thể trong quần thể. Quá trình này được lặp lại cho đến khi đạt được điều kiện dừng. Khi quá trình tiến hóa kết thúc, các thông số tối ưu của SVM đã sẵn sàng để thực hiện phân loại. Quy trình của thuật toán AEDE-SVM được trình bày như sau (Hình 2)

4 ỨNG DỤNG AEDE ĐỂ CHẨN ĐOÁN HƯ HỒNG Ồ LẤN

4.1 Tổng quan hệ thống

Máy véc tơ hỗ trợ cũng như các kỹ thuật dự đoán đã cho thấy ưu điểm của chúng trong việc phát hiện các hư hỏng của máy móc nhằm tránh hoặc giảm rủi ro và chi phí của những hư hỏng không mong muốn. Trong bài báo này, AEDE-SVM được sử dụng để phát hiện lỗi ồ lẩn vốn là một trong những bộ phận phổ biến nhất trong các ứng dụng công nghiệp.

Các tín hiệu rung động gia tốc ồ lẩn thu thập được đã được phân tách thành một số hàm thành phần bằng cách sử dụng phương pháp VMD. Sau đó, kỹ thuật SVD được sử dụng để thực hiện giảm kích thước các ma trận vector, kế tiếp các ma trận này được sử dụng làm véc tơ đầu vào của bộ phân loại AEDE-SVM.

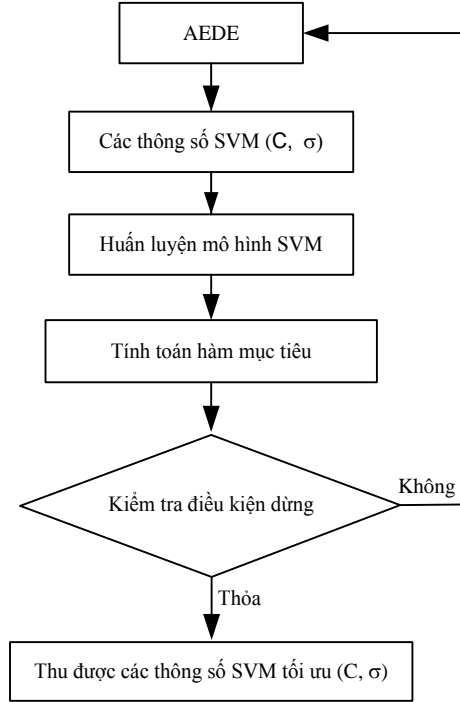
4.2 Phương pháp phân rã mô hình biến đổi (VMD)

Phương pháp VMD là phương pháp phân rã tín hiệu trực giao thích ứng. Đây là phương pháp mạnh cho việc lấy mẫu và chống nhiễu. VMD có thể phân rã một tín hiệu thực f thành một số hàm thành phần u_k [3]. Ở đây, mỗi dạng u_k chủ yếu nên được nén xung quanh một điểm trung tâm. Đề xuất của VMD có thể được tóm tắt như một bài toán biến đổi có ràng buộc:

$$\underset{\{u_k\}, \{\omega_k\}}{\text{Cực tiểu}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (9)$$

$$\text{sao cho } \sum_k u_k = f$$

với $u_k = \{u_1, u_2, \dots, u_k\}$ và $\omega_k = \{\omega_1, \omega_2, \dots, \omega_k\}$ tuần tự là tập hợp của các hàm thành phần và tần số trung tâm của chúng.



Hình 2. Lưu đồ thuật toán AEDE-SVM

Phương pháp nhân tử Lagrange và phương pháp phạt bậc 2 được đưa vào công thức (9) để chuyển bài toán biến có ràng buộc thành bài toán biến không ràng buộc. Tham số Lagrange L được biểu diễn như sau:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \|f(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (10)$$

Chi tiết của phương pháp VMD được trình bày trong tài liệu [3]. Số hàm thành phần u_k quyết định thời gian phân rã tín hiệu và thời gian phân lớp của bộ phân loại SVM. Trong bài báo này chúng tôi chọn số hàm thành phần là 4. Sau khi phân rã tín hiệu dao động gia tốc ổ lăn thành các hàm thành phần, bước kế tiếp các hàm thành phần này được trích xuất thành các ma trận đặc tính bởi phương pháp phân rã giá trị đơn.

4.3 Phương pháp phân rã giá trị đơn (SVD)

Phương pháp SVD là phân rã một ma trận để tạo ra những giá trị riêng gọi là những véc tơ riêng.

Giả sử có 1 ma trận Σ với kích thước $M \times N$ được biểu diễn như sau:

$$\Sigma = E \Delta V^T \quad (11)$$

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

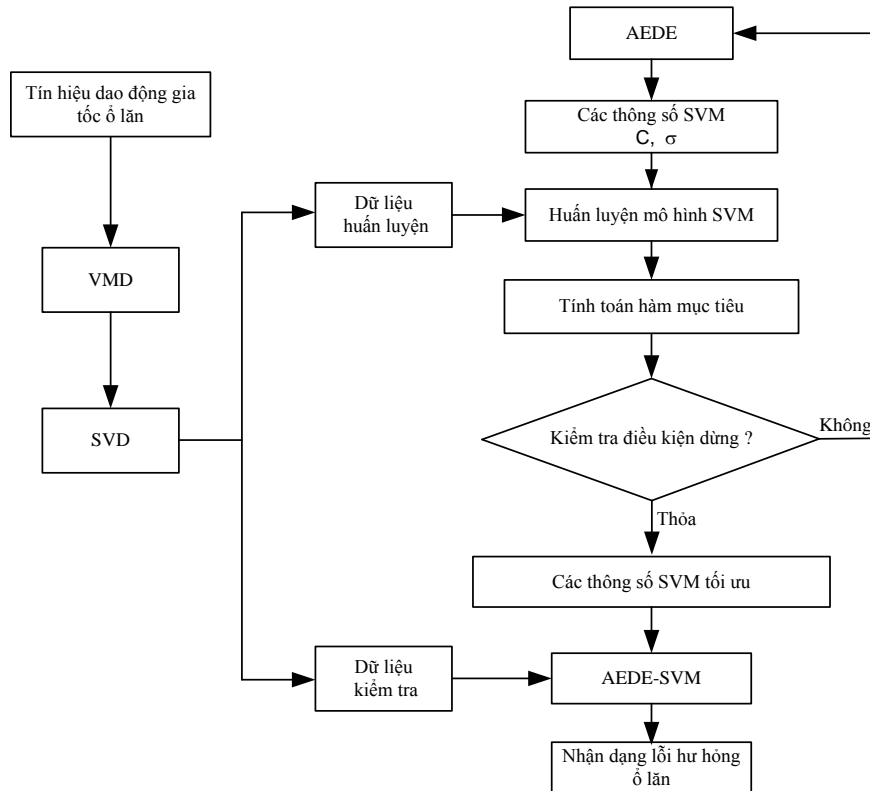
$\Delta = [diag\{\sigma_1, \dots, \sigma_p\}; 0]$, $p = \min(N, M)$, và $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p \geq 0$. Thành phần thứ i của véc tơ bên trái và phải của ma trận Σ tuần tự là những véc tơ e_i và v_i . Giá trị của σ_i là những giá trị riêng của ma trận Σ .

Trong bài báo này, phương pháp VMD được dùng để phân rã các tín hiệu dao động của ổ lăn thành các hàm thành phần u . Sau đó các hàm thành phần được phân rã thành 2 ma trận đặc tính X và Y .

$$X = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_J \end{bmatrix}, \quad Y = \begin{bmatrix} u_{J+1} \\ u_{J+2} \\ \vdots \\ u_n \end{bmatrix} \quad (12)$$

với $J = n/2$ (khi n là số chẵn) và $J = (n+1)/2$ (khi n là số lẻ). Ở đây, những đặc tính của tín hiệu dao động của ổ lăn $x(t)$ có thể được trích xuất từ những ma trận đặc tính đặc tính ban đầu X và Y . Thêm vào đó những véc tơ đặc tính lỗi có thể xem là những giá trị đơn phản ánh đặc tính tự nhiên. Bộ phân loại AEDE-SVM có thể được dùng để nhận dạng điều kiện làm việc và những mẫu ổ lăn lỗi.

Hình 3 mô tả lưu đồ của phương pháp chẩn đoán hư hỏng ổ lăn dựa trên VMD-SVD và AEDE-SVM. Trước tiên những tín hiệu dao động gia tốc của ổ lăn được phân tích thành các hàm con bởi thuật toán VMD, sau đó các hàm con được trích xuất thành các ma trận đặc tính dùng cho bộ phân loại SVM bởi phương pháp SVD. Kế tiếp ma trận đặc tính được tách làm 2 nhóm dùng để huấn luyện và kiểm tra. Sau khi huấn luyện các thông số tối ưu của SVM là C và σ được dùng để kiểm tra các mẫu.



Hình 3. Lưu đồ thuật toán phương pháp chẩn đoán hư hỏng ổ lăn dựa trên VMD-SVM và AEDE-SVM

5 THỰC NGHIỆM VÀ KẾT QUẢ


5.1 Thu thập dữ liệu

Dữ liệu của bài báo này được thu thập từ Trung tâm dữ liệu ổ lăn của Đại học Case Western Reserve dưới sự cho phép của Giáo sư K. A. Loparo cho thấy hiệu suất tốt của phương pháp đề xuất. Mô hình thử nghiệm bao gồm động cơ điện công suất 2 HP, bộ chuyển đổi mô men xoắn, lực kế và bộ điều khiển điện tử. Một bộ chuyển đổi tương tự sang kỹ thuật số cũng được sử dụng để lấy mẫu ở tần số 485063 Hz, trong khi tốc độ động cơ được cố định ở 1772 vòng / phút. Ổ lăn hiệu SKF loại 6205-2RS JEM được tạo hư hỏng bằng phương pháp cắt laser để ra các mẫu ổ lăn hư hỏng (Hình 4) [11]. Bốn tình trạng của ổ lăn bao gồm hư vòng trong (IR), hư vòng ngoài (OR), hư bi (Ball) và ổ lăn bình thường (Nor) gồm 432 mẫu. Trong mỗi vòng huấn luyện và kiểm tra các mẫu được chọn ra để kiểm tra và huấn luyện theo tỷ lệ là một phần ba. Hình 4 hiển thị cách bố trí thí nghiệm lấy mẫu dữ liệu dao động ổ lăn.

5.2 Thực nghiệm và kết quả

Bộ phân loại AEDE-SVM dùng trong bài báo là loại phân loại nhị phân. Với 4 nhóm tình trạng ổ lăn chúng tôi phải sử dụng 3 bộ phân loại. Bộ thứ nhất AEDE-SVM1 dùng để tách nhóm ổ lăn hư vòng trong, bộ thứ hai AEDE-SVM2 để tách nhóm ổ lăn hư vòng ngoài, bộ thứ ba AEDE-SVM3 để tách nhóm ổ lăn tình trạng hư bi. Phần còn lại là nhóm ổ lăn bình thường. Kết quả 4 tình trạng ổ lăn được trình bày chi tiết trong Bảng 1. Để đánh giá tính hiệu quả của phương pháp đề xuất chúng tôi đã so sánh bộ phân loại AEDE-SVM với bộ phân loại sử dụng thuật toán PSO và thuật toán GA. Để tạo sự công bằng trong so sánh, các thông số của 3 phương pháp được thiết lập như sau: số cá thể là 30 và số lần chạy chương trình là 30. Với thuật toán

PSO, các thông số được lấy là $W = 0.75$, $c_1 = c_2 = 1.5$. Các thông số tối ưu của bộ phân loại của 3 phương pháp được trình bày trong Bảng 2. Từ Bảng 2 cho thấy kết quả phân lớp của phương pháp đề xuất cho độ chính xác phân loại là tốt nhất (0%) so với 4 phương pháp kia. Đồng thời, thời gian chạy chương trình của phương pháp VMD-SVD-AEDE-SVM ngắn hơn khi so với EMD-SVD-AEDE-SVM, LMD-SVD-AEDE-SVM, VMD-SVD-PSO-SVM và VMD-SVD-GA-SVM.



Hình 4. Mô hình thu thập dữ liệu dao động ổ lăn[11].

Bảng 1. Kết quả phân lớp của phương pháp VMD-SVD và AEDE-SVM

Mẫu kiểm tra	Giá trị đơn của đặc tính lỗi $\sigma_{x,x}$				Bộ phân loại AEDE-SVM1	Bộ phân loại AEDE-SVM2	Bộ phân loại AEDE-SVM3	Kết quả phân loại tình trạng ổ lăn
(1) IR	2.7761	1.8401	4.8933	4.5838	(+1)			Hư vòng trong
(2) IR	2.9126	2.0058	4.7401	4.4795	(+1)			Hư vòng trong
(3) IR	2.7924	1.8047	4.5295	4.3316	(+1)			Hư vòng trong
(4) IR	2.7550	1.8927	4.4961	4.2803	(+1)			Hư vòng trong
(5) IR	2.7959	1.9007	4.8923	4.6756	(+1)			Hư vòng trong
(6) IR	2.9235	2.1059	4.7940	4.2828	(+1)			Hư vòng trong
(7) OR	0.8577	0.5376	5.2051	3.3693	(-1)	(+1)		Hư vòng ngoài
(8) OR	1.7118	0.6552	4.3116	2.7413	(-1)	(+1)		Hư vòng ngoài
(9) OR	2.3271	0.6228	5.7027	4.1664	(-1)	(+1)		Hư vòng ngoài
(10) OR	2.0091	0.6157	6.3539	2.7257	(-1)	(+1)		Hư vòng ngoài
(11) OR	0.6076	0.5563	4.9454	2.5839	(-1)	(+1)		Hư vòng ngoài
(12) OR	0.6413	0.5886	4.6188	3.0289	(-1)	(+1)		Hư vòng ngoài
(13) Ball	0.6385	0.6040	3.2876	1.5652	(-1)	(-1)	(+1)	Hư bi
(14) Ball	0.6858	0.6329	2.7909	1.8992	(-1)	(-1)	(+1)	Hư bi
(15) Ball	0.6520	0.6074	3.0904	1.8048	(-1)	(-1)	(+1)	Hư bi
(16) Ball	0.6765	0.6158	2.7749	1.5726	(-1)	(-1)	(+1)	Hư bi
(17) Ball	0.9085	0.6370	3.1661	1.4629	(-1)	(-1)	(+1)	Hư bi
(18) Ball	0.9458	0.6073	3.2765	1.8549	(-1)	(-1)	(+1)	Hư bi
(19) Nor	1.8843	1.1404	0.4915	0.0544	(-1)	(-1)	(-1)	Bình thường
(20) Nor	1.7389	1.1432	0.4882	0.0557	(-1)	(-1)	(-1)	Bình thường
(21) Nor	1.6609	1.1661	0.5737	0.4988	(-1)	(-1)	(-1)	Bình thường
(22) Nor	1.8967	1.0806	0.5005	0.0610	(-1)	(-1)	(-1)	Bình thường
(23) Nor	1.8109	1.2378	0.5112	0.0639	(-1)	(-1)	(-1)	Bình thường
(24) Nor	1.9469	1.5415	0.5582	0.5047	(-1)	(-1)	(-1)	Bình thường

6 KẾT LUẬN

Trong bài báo này phương pháp chẩn đoán hư hỏng ổ lăn đã được đề xuất. Trước tiên tín hiệu dao động gia tốc ổ lăn được phân rã thành các hàm con nhờ phương pháp VMD. Bước thứ hai các hàm con được trích xuất thành ma trận đặc tính nhờ phương pháp SVD. Các ma trận đặc tính được sử dụng làm ma trận đầu vào cho bộ phân loại máy véc tơ hỗ trợ. Các thông số của SVM được đề xuất tối ưu hóa bởi phương

PHƯƠNG PHÁP CHẨN ĐOÁN HƯ HỒNG Ồ LẤN...

pháp AEDE. Sau khi huấn luyện cho bộ phân loại AEDE-SVM, các thông số của máy véc tơ hỗ trợ được tối ưu bởi phương pháp AEDE để chọn ra các thông số tối ưu. Kết quả thực nghiệm cho thấy sự kết hợp phương pháp VMD-SVD và AEDE-SVM đạt được độ chính xác phân loại cao hơn với chi phí thời gian thấp hơn so với các phương pháp khác. Phương pháp này có hiệu quả tốt khi chẩn đoán hư hồng ồ lẩn và có thể chẩn đoán cho các chi tiết quay khác nếu có được tín hiệu dao động gia tốc. Trong các nghiên cứu kế tiếp tác giả sẽ chẩn đoán hư hồng cho các chi tiết quay khác dựa trên phương pháp đề xuất.

Bảng 2. Bảng so sánh kết quả phân loại hư hồng ồ lẩn của các bộ phân loại VMD-SVD-AEDE-SVM với các phương pháp EMD-SVD-AEDE-SVM, LMD-SVD-AEDE-SVM, VMD-SVD -PSO-SVM và VMD-SVD-GA-SVM.

Phương pháp	Số lượng mẫu huấn luyện	Số lượng mẫu kiểm tra	Thông số tối ưu C	Thông số tối ưu σ	Thời gian giá thành (s)	Mức độ lỗi phân loại (%)
VMD-SVD-AEDE-SVM1	288	144	4679.16	12.33	24.01	0
LMD-SVD-AEDE-SVM1	288	144	29594.13	9.12	25.04	0
EMD-SVD-AEDE-SVM1	288	144	28148.74	23.83	26.04	0
VMD-SVD -PSO-SVM1	288	144	15958.74	19.00	28.12	0
VMD-SVD -GA-SVM1	288	144	25194.23	10.21	34.35	0
VMD-SVD-AEDE-SVM2	216	108	10382.39	28.60	20.22	0
LMD-SVD-AEDE-SVM2	216	108	7843.03	18.19	21.80	0.101
EMD-SVD-AEDE-SVM2	216	108	16186.23	10.09	22.56	0.101
VMD-SVD -PSO-SVM2	216	108	19007.60	18.08	23.56	0.101
VMD-SVD -GA-SVM2	216	108	1569.12	17.12	28.31	0.101
VMD-SVD-AEDE-SVM3	144	72	9117.31	20.37	16.93	0
LMD-SVD-AEDE-SVM3	144	72	2813.18	30.15	17.08	0
EMD-SVD-AEDE-SVM3	144	72	15331.62	4.32	17.68	0
VMD-SVD -PSO-SVM3	144	72	19086.22	17.96	18.15	0
VMD-SVD -GA-SVM3	144	72	8173.41	19.53	23.41	0

LỜI CẢM ƠN

Tác giả cảm ơn Giáo sư K. A. Loparo ở đại học Case Western Reserve đã cho phép sử dụng dữ liệu của Trung tâm dữ liệu ổ lẩn để phục vụ cho bài báo này.

TÀI LIỆU THAM KHẢO

[1] N. Huang *et al.*, The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis, *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, vol. 454, pp. 903-995, 1998.

[2] J. S. Smith, The local mean decomposition and its application to EEG perception data, (in eng), *Journal of the Royal Society, Interface*, vol. 2, no. 5, pp. 443-454, 2005.

[3] K. Dragomiretskiy and D. Zosso, Variational Mode Decomposition, *IEEE Transactions on Signal Processing*, vol. 62, no. 3, pp. 531-544, 2014.

[4] H. Ao, J. Cheng, Y. Yang, and T. K. Truong, 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. 2013, no. 2013, 2013.

[5] H. Ao, J. Cheng, K. Li, and T. K. Truong, A Roller Bearing Fault Diagnosis Method Based on LCD Energy Entropy and ACROA-SVM, *Shock and Vibration*, vol. 2014, no. 2014, pp. 1-6, 2014.

[6] J. Cheng, D. Yu, J. Tang, and Y. Yang, Application of SVM and SVD Technique Based on EMD to the Fault Diagnosis of the Rotating Machinery, *Shock and Vibration*, vol. 16, p. 519502, 2009.

- [7] R. Raghuraj and S. Lakshminarayanan, VPMCD: variable interaction modeling approach for class discrimination in biological systems, *FEBS Lett*, vol. 581, no. 5, pp. 826-30, 2007.
- [8] W. S. McCulloch and W. Pitts, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*, vol. 5, no. 4, pp. 115-133, 1943.
- [9] V. N. Vapnik, *The Nature of Statistical Learning Theory*; Springer: New York. 1995.
- [10] V. Ho-Huu, T. Nguyen-Thoi, T. Vo-Duy, and T. Nguyen-Trang, An adaptive elitist differential evolution for optimization of truss structures with discrete design variables, *Computers & Structures*, vol. 165, pp. 59-75, 2016.
- [11] L. K. A. (2003, 1 Nov.). *Bearings vibration dataset*, Case Western Reserve University. Available: <https://engineering.case.edu/bearingdatacenter/download-data-file>

A NEW ROLLER BEARING FAULT DIAGNOSIS METHOD BASED ON AEDE-SVM METHOD AND VMD-SVD

AO HUNG LINH

Faculty of Mechanical Engineerin, Industrial University of Ho Chi Minh City
aohunglinh@iuh.edu.vn

Abstract. This paper presents a new method for roller bearing fault diagnosis based on support vector machine (SVM) with parameters optimized by Adaptive Elitist Differential Evolution method (AEDE). First, roller bearing acceleration vibration signals are decomposed into function by using Variational Mode Decomposition (VMD) method. Second, initial feature matrices are extracted from there functions by singular value decomposition (SVD) techniques to obtain single values. Thirdly, these values serve as input vector for AEDE-SVM classifier. Experimental results show that the proposed method gives high classification accuracy (100%) and shorter time than other methods.

Keywords. Variational mode decomposition, Fault diagnosis, roller bearing, singular value decomposition, support vector machine.

Ngày gửi bài: 14/12/2021

Ngày chấp nhận đăng: 02/03/2022