

SỬ DỤNG PHÉP BIẾN ĐỔI NÉN ĐỒNG BỘ WAVELET KẾT HỢP MÁY HỌC VECTOR HỖ TRỢ ĐỂ PHÂN LOẠI HƯ HỒNG BỘ TRUYỀN BÁNH RĂNG

Nguyễn Trọng Du^{1*}, Nguyễn Thanh Hải², Phùng Minh Ngọc³

Tóm tắt: Bộ truyền bánh răng đóng vai trò quan trọng trong việc bảo đảm hoạt động liên tục, an toàn của máy móc và thiết bị. Bất kỳ một hư hỏng nào của bánh răng cũng ảnh hưởng tới hoạt động bình thường của máy, đặc biệt là những bộ truyền bánh răng cỡ lớn. Bài báo này đưa đến một cách tiếp cận mới và hiện đại trên cơ sở phép biến đổi nén đồng bộ Wavelet (Synchrosqueezed Wavelet Transform - SWT) và máy học vector hỗ trợ (Support Vector Machine - SVM) nhằm mục đích phát hiện và phân loại hư hỏng có trong bộ truyền bánh răng. Tín hiệu dao động đo được tại vỏ sẽ được phân tích thành các hàm dạng cơ sở (Intrinsic Mode Functions - IMF) bằng SWT. Tiến hành lấy giá trị đặc trưng của các hàm dạng cơ sở để làm đầu vào huấn luyện các vector hỗ trợ, từ đó phân loại được hư hỏng của bánh răng.

Từ khóa: Chẩn đoán kỹ thuật; Bánh răng; Phép biến đổi nén đồng bộ; Máy vector hỗ trợ.

1. ĐẶT VẤN ĐỀ

Trí tuệ nhân tạo được áp dụng rộng rãi trong rất nhiều lĩnh vực của đời sống và được xem là một trong các thành phần thiết yếu của một nền công nghiệp 4.0. Từ năm 2007, một loạt nghiên cứu do Rafiee [1] đứng đầu đã nghiên cứu về ứng dụng mạng nơ ron trong chẩn đoán hư hỏng hộp số bánh răng kéo dài tới những năm 2010 [2]. Ở Việt Nam, năm 2014 tại Đại học Bách Khoa Hà Nội đã thực hiện những nghiên cứu về việc ứng dụng trí tuệ nhân tạo, cụ thể là mạng nơ ron, trong giám sát và chẩn đoán hư hỏng bánh răng [3]. Tuy nhiên, có nhiều mô hình trí tuệ nhân tạo khác nhau với rất nhiều tiềm năng ứng dụng trong giám sát và chẩn đoán kỹ thuật. Một trong số đó là máy học vector hỗ trợ. Bài báo đề xuất một quy trình phân loại hư hỏng tự động dựa trên sự kết hợp giữa Nén đồng bộ Wavelet và máy học vector hỗ trợ. Bên cạnh đó, nhóm tác giả cũng sẽ đánh giá sự ảnh hưởng của các tham số tới hiệu quả của quá trình tự động phân loại hư hỏng bánh răng.

2. CƠ SỞ LÝ THUYẾT

2.1. Phép biến đổi nén đồng bộ Wavelet

Phép biến đổi Wavelet là một phương pháp phân tích thời gian – tần số phổ biến, sử dụng các hàm Wavelet cơ sở $\psi_0(t) \in L^2(R)$ và tỷ lệ s để biểu diễn tín hiệu $x(t)$ dưới dạng [4]:

$$WT_x(\tau, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \psi_0^* \left(\frac{t - \tau}{s} \right) dt \quad (1)$$

Nhằm cải thiện độ phân giải của phép biến đổi Wavelet năm 2011, L. Daubechies và cộng sự đề xuất một phép biến đổi dựa trên phép biến đổi Wavelet được gọi là phép biến đổi nén đồng bộ Wavelet (Synchrosqueezed Wavelet Transform-SWT) [5].

$$T_x(\tau, f_x) = (\Delta f)^{-1} \int_{s: |f(\tau, s) - f_x| \leq \Delta f_x / 2} WT_x(\tau, s) s^{-3/2} ds \quad (2)$$

Với các tín hiệu có dạng:

$$x(t) = \sum_1^K x_k(t) = \sum_1^K A_k(t) e^{i\phi_k(t)} \quad (3)$$

Trong đó, $x_k(t)$ là các hàm dạng cơ sở (*Intrinsic Mode Function-IMF*). Các hàm này chỉ chứa một dạng dao động đơn giản mô tả bởi một tín hiệu có dải tần hẹp nên việc tách riêng các thành phần tín hiệu này bằng các phương pháp phân tích thời gian - tần số thông thường, vốn có độ phân giải thấp, gặp nhiều khó khăn. Tuy nhiên, với phương pháp nén đồng bộ, ta có thể tách và phục hồi các thành phần tín hiệu này [5]:

$$x_k(t) \approx \frac{1}{R_\psi} \int_{|f_x - f_k(\tau)| < \gamma} V(\tau, f_x) df_x \quad (4)$$

Với $R_\psi = \sqrt{2\pi} \int \zeta^{-1} \Psi(\zeta) d\zeta$, $f_k(t)$ là tần số tức thời của tín hiệu $x_k(t)$, γ là ngưỡng chọn trước.

2.2. Máy học Vector hỗ trợ

Máy học vector hỗ trợ là một phương pháp được sử dụng nhiều trong lĩnh vực trong khoa học máy tính, nhằm mục đích để phân tích dữ liệu, từ đó phân loại dữ liệu vào các lớp khác nhau. Bản chất của thuật toán SVM là đi xây dựng một siêu phẳng (Hyper-Plane) nhằm mục đích phân loại dữ liệu vào các lớp khác nhau. Gọi siêu phẳng (H) mà chúng ta cần xây dựng có dạng:

$$\omega^T x + b = 0 \quad (5)$$

trong đó, ω^T là vector pháp tuyến của siêu phẳng, b là số thực. Khoảng cách từ mỗi điểm tới siêu phẳng (H) là:

$$d = \frac{|\omega^T x_i + b|}{\|\omega\|} = \frac{y_i (\omega^T x_i + b)}{\|\omega\|} \quad (6)$$

Một siêu phẳng được xây dựng cần phải cách đều các tập dữ liệu cần phân chia và phải cách chúng một khoảng là xa nhất để đảm bảo kết quả phân loại đạt độ chính xác cao nhất. Do đó, bài toán của chúng ta là cần tìm các hệ số của siêu phẳng (H) thỏa mãn:

$$\begin{cases} \frac{1}{2} \|\omega\|^2 \min \\ y_i (\omega^T x_i + b) - 1 \geq 0 \\ y_i = \pm 1; i = \overline{1, n} \end{cases} \quad (7)$$

Đây là một bài toán tìm cực trị có điều kiện đầu ràng buộc, sử dụng phương pháp Lagrange ta sẽ tìm được giá trị tối ưu cho ω , b và λ . Với bộ dữ liệu là phân biệt tuyến tính, các lớp dữ liệu khá tách biệt nhau, thì phương pháp SVM đã trình bày ở trên tỏ ra khá hữu hiệu, nhưng với bộ dữ liệu không phân biệt tuyến tính thì phương pháp này tỏ ra kém hiệu quả. Để giải quyết điều này, ta cần chuyển tập dữ liệu lên một không gian mới mà tại đó tập dữ liệu trở nên phân biệt tuyến tính để có thể dễ dàng trong việc phân loại.

Ta sẽ sử dụng một ánh xạ Φ để chuyển đổi không gian tập dữ liệu.

$$\Phi : \begin{matrix} x \rightarrow \Phi(x) \\ \mathbb{R}^d \rightarrow \mathbb{R}^D \end{matrix} \quad (8)$$


Siêu phẳng trong không gian mới :

$$\sum_{i=1}^n \lambda_i y_i \Phi(x_i)^T \Phi(x_j) + b = 0 \quad (9)$$

Việc tính toán trực tiếp các hàm $\Phi(x)$ trên chiều không gian mới có số chiều cao hơn sẽ mất nhiều thời gian và công sức. Để khắc phục vấn đề này, ta sẽ tính biểu thức tích vô hướng có dạng $\Phi(x_i)^T \Phi(x_j)$. Kỹ thuật này có tên gọi là *Kernel Trick*. Và biểu thức tích vô hướng có tên gọi riêng là Hàm nhân (Kernel Function).

Khi cần phân chia dữ liệu vào nhiều lớp khác nhau, (bài toán multi-Class Classification), ta có thể sử dụng hai phương pháp phổ biến là: Một chống lại tất cả (*One-against-all_OAA*) và Một chống lại một (*One – Against – One_OAO*).

2.3. Xây dựng quy trình phương án đề xuất




Hình 1. Quy trình phân loại hư hỏng bánh răng bằng phương pháp kết hợp.

Bằng việc sử dụng kết hợp phép biến đổi nén Wavelet và Vector máy hỗ trợ, nhóm tác giả đề xuất quy trình phân loại hư hỏng bánh răng như trên hình 1. Tín hiệu đầu là tín hiệu gia tốc đo tại vỏ hộp số được đo bằng đầu đo gia tốc với một tần số lấy mẫu cố định, sau đó sử dụng phép biến đổi nén đồng bộ Wavelet để phân tích tín hiệu đầu vào thành các IMF. Tiến hành lấy các tham số đặc trưng của các IMF để xây dựng ma trận vector đặc trưng. Các vector đặc trưng này chính là đầu vào của SVM. Cuối cùng SVM sẽ phân loại các hư hỏng trên cơ sở các vector đặc trưng của tín hiệu đo được.

3. MỘT SỐ KẾT QUẢ ĐẠT ĐƯỢC

3.1. Mô hình thí nghiệm



Hình 2. Mô hình thí nghiệm (A: mô hình tổng quát, B: vị trí cảm biến gia tốc, C: bánh răng bị gãy, D: bánh răng mòn nhẹ).

Mô hình thí nghiệm được mô tả chi tiết như trên hình 2 được tham khảo từ những nghiên cứu công bố trên mạng [2]. Mô hình được xây dựng nhằm mục đích đo tín hiệu dao

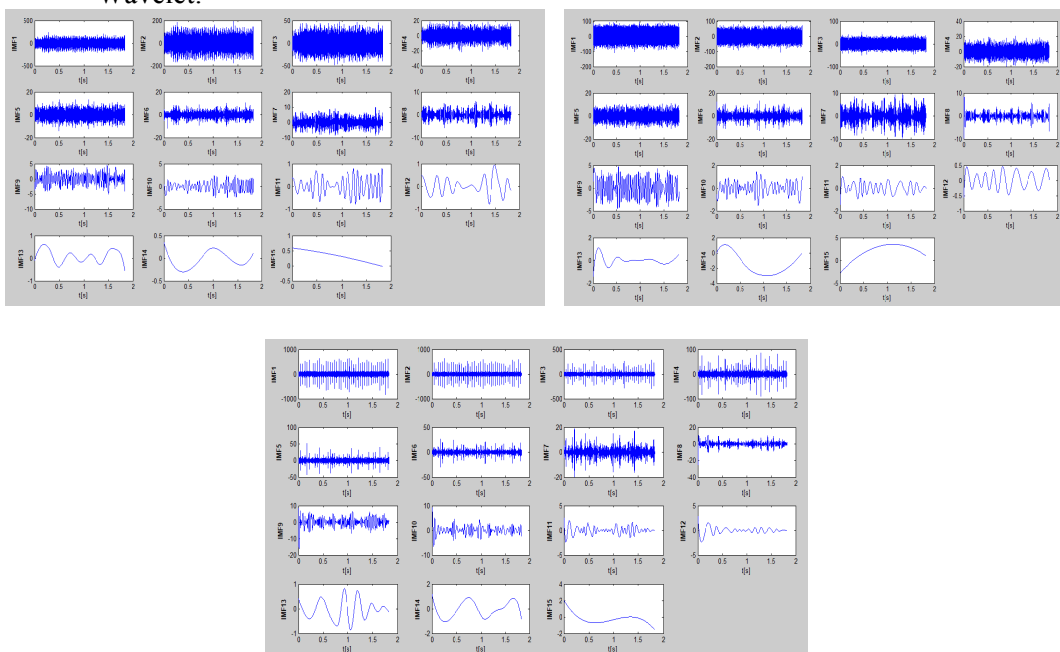
động của một hộp số xe máy. Tín hiệu dao động được thu thập thông qua đầu đo gia tốc có vị trí như trong hình B.

Các thông số bao gồm:

- Tốc độ quay của trục : 1420 vòng/phút
- Số răng : 32 răng
- Tần số lấy mẫu : 16384 Hz

3.2. Kết quả phân tích tín hiệu

❖ Bước 1: Phân tích tín hiệu thành các IMF bằng phép biến đổi nén đồng bộ Wavelet:



Hình 3. Các IMF của bánh răng bình thường (a), mòn nhẹ (b) và bị gãy (c).

❖ Bước 2: Tính toán các tham số đặc trưng của các IMF và rút ra các vector đặc trưng.

Như ta đã biết, có nhiều tham số đặc trưng cho tín hiệu như là: Giá trị trung bình hiệu dụng, độ lệch chuẩn, hệ số Crest,... Ở đây, ta sẽ lựa chọn 2 tham số đặc trưng chính của tín hiệu là: Năng lượng và Hệ số Kurtosis. Kết quả, ta thu được vector đặc trưng là vector 2 chiều, tương ứng với mỗi chiều là Năng lượng và Hệ số Kurtosis.

❖ Bước 3: Sử dụng SVM để huấn luyện dữ liệu

Đây là bài toán phân nhiều lớp, cụ thể là 3 lớp: Bánh răng bình thường, Bánh răng mòn nhẹ và Bánh răng bị gãy răng. Áp dụng phương pháp phân loại OAA, ta chọn dữ liệu của một lớp bất kỳ trong 3 lớp và gọi lớp này là A. Dữ liệu trong lớp này được đánh dấu là 1. Dữ liệu còn lại không thuộc lớp này được đánh dấu là -1. Sau đó, tiến hành phân loại dữ liệu 1 và -1 với nhau, ta sẽ phân loại được lớp A tách biệt với hai lớp còn lại. Làm lần lượt với dữ liệu trong tất cả các lớp, ta sẽ giải quyết được bài toán phân nhiều lớp.

❖ Bước 4: Đánh giá các yếu tố ảnh hưởng tới hiệu quả phân loại

Trong nội dung bài báo này, nhóm tác giả sẽ tập trung đánh giá các yếu tố: hàm nhân, hệ số Kernel (Kernel Option) và λ .

Qua kết quả được thể hiện trong **Bảng 1**, ta thấy việc lựa chọn hàm nhân ảnh hưởng lớn tới kết quả của việc phân loại cả về độ chính xác và thời gian tính toán. Trong trường

hợp này, hàm nhân Gaussian cho kết quả tốt hơn nhiều so với hàm nhân Polynomial. Trong thực tế, hàm nhân Gaussian cũng được sử dụng phổ biến nhất.

Bảng 1. Kết quả phân loại SVM giữa hai Hàm nhân.

Hàm nhân	Kernel option	λ	C	Độ chính xác	Thời gian thực hiện
Gaussian	0,1	10^{-7}	10^5	100%	0,3390 (s)
Polynomial	0,1	10^{-7}	10^5	33,33%	0,6384 (s)

Bảng 2. Kết quả phân loại SVM khi thay đổi Kernel option.

Hàm nhân	Kernel option	λ	C	Độ chính xác	Thời gian thực hiện
Gaussian	0,1	10	10^5	100 %	0,3445 (s)
Gaussian	1	10	10^5	95,56 %	0,3389 (s)
Gaussian	10	10	10^5	86,67 %	0,3544 (s)
Gaussian	20	10	10^5	82,22 %	0,3570 (s)

Bảng 3. Kết quả phân loại SVM khi thay đổi C.

Hàm nhân	Kernel option	λ	C	Độ chính xác	Thời gian thực hiện
Gaussian	0,1	10^{-7}	10	100 %	0,3390 (s)
Gaussian	0,1	10^{-7}	10^2	100 %	0,3342 (s)
Gaussian	0,1	10^{-7}	10^3	100 %	0,3445 (s)
Gaussian	0,1	10^{-7}	10^4	100 %	0,3387 (s)

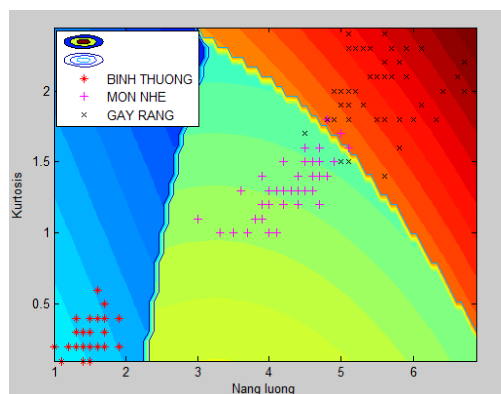
Bảng 4. Kết quả phân loại SVM khi thay đổi λ .

Hàm nhân	Kernel option	λ	C	Độ chính xác	Thời gian thực hiện
Gaussian	0,1	10^{-7}	10^5	100 %	0,3390 (s)
Gaussian	0,1	10	10^5	100 %	0,3445 (s)
Gaussian	0,1	100	10^5	73,33 %	0,3564 (s)
Gaussian	0,1	120	10^5	68,89 %	0,3581 (s)

Từ các kết quả trên **bảng 2, 3, 4**, ta thấy tham số C khi thay đổi không làm ảnh hưởng nhiều đến kết quả phân loại. Tuy nhiên, khi tăng các tham số Kernel Option và λ độ chính xác phân loại giảm đáng kể. Như vậy, có thể thấy việc lựa chọn các tham số Kernel Option và λ là cực kỳ quan trọng trong việc phân loại. Thông thường, các tham số Kernel Option và λ được chọn thường là số rất nhỏ. Khi đó, kết quả phân loại của ta sẽ đạt được độ chính xác cao và giảm thiểu sai lệch không mong muốn.

4. KẾT LUẬN

Với việc kết hợp phương pháp SVM và phép biến đổi SWT bằng cách sử dụng các vector đặc trưng, ta có thể xây dựng một hệ thống giám sát và nhận dạng hư hỏng một cách tự động cho bộ truyền bánh răng. Hình 4 là kết quả phân loại tự động hư hỏng một cách trực quan nhất mà phương pháp đề xuất của bài báo mang lại. Qua đồ thị này ta có thể thấy rõ được từng vùng hư hỏng trong hộp số bánh răng. Qua đó giúp những người làm kỹ thuật tiết kiệm được nhiều thời gian và công sức cũng như mang lại hiệu quả kinh tế kỹ thuật cao. Áp dụng hệ thống chẩn đoán tự động các nhà máy có thể chủ động trong việc bảo trì hỏng hóc và sửa chữa, đặc biệt là với các hộp số cỡ lớn.



Hình 4. Kết quả phân loại hư hỏng bánh răng bằng SVM.

TÀI LIỆU THAM KHẢO

- [1]. J. Rafiee, F. Arvani, A. Harifi, & M. H. Sadeghi. "Intelligent condition monitoring of a gearbox using artificial neural network". Mechanical Systems and Signal Processing, 21 (2007), 1746-1754.
- [2]. J. Rafiee, M. A. Rafiee, & P. W. Tse. "Application of mother wavelet functions for automatic gear and bearing fault diagnosis". Expert Systems with Applications, 37 (2010), 4568–4579.
- [3]. N. T. Du, & N. P. Dien. "Gear fault identification using artificial neural network and wavelet packet transform". Proceedings of the 3rd International Conference on Engineering Mechanics and Automation - ICEMA 3 (2014), 17 – 22.
- [4]. S. Mallat. "A Wavelet Tour of Signal Processing": Elsevier (2008).
- [5]. I. Daubechies, J. Lu, & H.-T. Wu. "Synchrosqueezed wavelet transform: An empirical mode decomposition-liked tool". Applied and Computational Harmonic Analysis, 30 (2010), 243-261.

ABSTRACT

CLASSIFYING GEAR FAULTS BY SYNCHROSQUEEZED WAVELET TRANSFORM COMBINED SUPPORT VECTOR MACHINE

Gear transmissions play an important role in continuous and safe operation of machineries. Any fault in gears has a negative influence on machineries, especially large gears. This paper aims to propose a new approach based on Synchrosqueezed wavelet transforms (SWT) and support vector machine (SVM) in order to detect and classify gears' faults. First of all, the vibration signal is decomposed into different intrinsic mode functions (IMFs) by SWT. Indicators of these IMFs are then used to train SVM so as to categorise gears' faults.

Keywords: Vibration diagnosis; Gear transmission; Synchrosqueezed wavelet transform; Support vector machine.

Nhận bài ngày 01 tháng 7 năm 2018

Hoàn thiện ngày 10 tháng 9 năm 2018

Chấp nhận đăng ngày 20 tháng 9 năm 2018

Địa chỉ ¹ Khoa Cơ khí, Trường Đại học Điện Lực.

² Khoa Cơ khí, Trường Đại học Thủy lợi.

³ Viện Cơ khí, Trường Đại học Bách khoa Hà Nội.

* Email: dunt@epu.edu.vn.