

ĐỀ XUẤT PHƯƠNG PHÁP KHỬ NHIỄU TÍN HIỆU RUNG PHỤC VỤ CHO VIỆC CHẨN ĐOÁN LỖI CỦA ĐỘNG CƠ

PROPOSING A METHOD TO ELIMINATE SIGNAL NOISE OF VIBRATION FOR ENGINE FAULT DIAGNOSIS

Nguyễn Hồ Sĩ Hùng^{1,*}, Trần Đình Khoa¹

DOI: <https://doi.org/10.57001/huih5804.2023.049>

TÓM TẮT

Trong những năm gần đây, học sâu (DL) đã trở thành chìa khóa thành công trong nhiều ngành sản xuất. Chẩn đoán lỗi động cơ dựa trên dữ liệu rung động là một trong những ứng dụng học sâu trong mô hình sản xuất hiện đại. Do dữ liệu rung động rất nhạy cảm với một số tín hiệu nhiễu. Các chuyển động không cần thiết có thể có tác động tiêu cực đến đầu vào thông tin của cảm biến gia tốc. Đó là lý do tại sao khử nhiễu của tín hiệu rung được xem là giai đoạn quan trọng đầu tiên để chẩn đoán lỗi động cơ. Trong bài báo này, một phương pháp mới dựa trên biến đổi Fast Fourier Transform (FFT) và phân cụm K-mean lần đầu tiên được đề xuất để cải thiện hiệu quả của chẩn đoán lỗi động cơ. Sau đó, mạng nơ-ron CNN được áp dụng để phân loại các lỗi của động cơ. Để xác nhận hiệu quả của phương pháp được đề xuất, bộ dữ liệu mã nguồn mở Case Western Reserve University (CWRU) được sử dụng để chạy thực nghiệm. Các kết quả thử nghiệm khẳng định những ưu điểm của phương pháp đề xuất trong việc hỗ trợ chẩn đoán lỗi cho động cơ khi so sánh với các phương pháp hiện có khác.

Từ khóa: Giảm tín hiệu, tín hiệu rung động, học sâu, mạng nơ-ron, chẩn đoán lỗi động cơ.

ABSTRACT

Deep Learning (DL) has lately emerged as the secret to success in the industrial sector. A current trend in the scientific community is the identification of motor defects based on vibration data, one of the deep learning applications in the contemporary manufacturing model. As a result of the vibration data's great sensitivity to various disturbances. The information input for the acceleration sensor may be negatively impacted by background movements that are unneeded. For this reason, cleansing vibration signals may be thought of as the initial step in diagnosing a bearing machine's issue. In order to enhance the effectiveness of the motor defect detection, a new denoising approach based on Fast Fourier Transform (FFT) and K-means clustering is first suggested in this study. In this paper, a new denoising method based on Fast Fourier Transform (FFT) and K-means clustering is firstly proposed to improve the performance of the motor fault diagnosis. Convolutional Neural Network (CNN) is then applied to classify the motor faults. To validate the performance of the proposed approach, the open-source Case Western Reserve University (CWRU) data-set is considered. The experimental results confirm the advantages of the proposed denoising method when compared to the other existing methods.

Keywords: Signal denoising, vibration signal, deep learning, convolutional neural network, motor fault diagnosis.

¹Khoa Điện, Trường Đại học Bách khoa, Đại học Đà Nẵng

*Email: nhshung@dut.udn.vn

Ngày nhận bài: 26/10/2022

Ngày nhận bài sửa sau phản biện: 02/02/2023

Ngày chấp nhận đăng: 15/3/2023

1. GIỚI THIỆU

Trong nhiều lĩnh vực sản xuất, sự cố thiết bị có thể dẫn đến tổn thất lợi nhuận đáng kể hoặc thậm chí gây nguy hiểm đến tính mạng của nhân viên. Do đó, một cơ sở đánh giá sức khỏe của thiết bị là rất quan trọng để đưa ra các lựa chọn kế hoạch bảo trì tốt nhất. Học máy đã được sử dụng và phát triển rộng rãi trở thành một công cụ mạnh mẽ để chẩn đoán máy móc, đặc biệt là phân loại lỗi động cơ dựa trên dữ liệu rung động, do sự phát triển của giám sát kỹ thuật và dữ liệu. Thật vậy, một số kỹ thuật học máy như Support Vector Machine (SVM) [1], Decision Trees (DT) [2], K-nearest neighbors algorithm (KNN) [3], Principal Component Analysis (PCA) [4]... đã thành công áp dụng cho các vấn đề chẩn đoán khác nhau. Tuy nhiên, chúng thường được áp dụng trong trường hợp tập dữ liệu thuần túy mà không xem xét các nhiễu hiện có. Hiệu quả của các phương pháp này khá hạn chế. Để khắc phục sự cố chẩn đoán động cơ với dữ liệu nhiễu, trước tiên chúng tôi đề xuất một phương pháp khử nhiễu mới là sự kết hợp của phép biến đổi fast Fourier transform and the K-means clustering, để làm sai lệch dữ liệu. Mạng nơ-ron Convolutional Neural Network (CNN) [5] sau đó là được sử dụng để phân loại các lỗi động cơ. Trong các phần tiếp theo của bài báo, chúng tôi sẽ trình bày chi tiết hơn về các phương pháp khử nhiễu (phần 2), phương pháp làm giảm nhiễu của chúng tôi được trình bày trong phần 3. Mô hình CNN dự đoán lỗi của động cơ được trình bày trong phần 4. Cuối cùng, đánh giá hiệu quả của mô hình được thực nghiệm trên nguồn dữ liệu mở Case Western Reserve University (CWRU).

2. CÁC PHƯƠNG PHÁP KHỬ NHIỄU HIỆN CÓ

Trong phần này, chúng tôi sẽ trình bày chi tiết hơn các phương pháp khử nhiễu hiện có:

2.1. Biến đổi Wavelet

Biến đổi Wavelet [6] là một kỹ thuật để phân tích miền tần số thời gian. Đối với các loại phương pháp khử nhiễu khác nhau dựa trên biến đổi Wavelet, một ngưỡng mềm đã được xác định cho các ứng dụng cụ thể để loại bỏ các nhiễu hiện có trong dữ liệu. Tồn tại một số phương pháp biến thể dựa trên biến đổi Wavelet, ví dụ như ngưỡng cố định, ngưỡng phụ thuộc mức, ngưỡng mềm và cứng [7]. Trong bài báo này, thuật toán ngưỡng cứng sẽ được so

sánh với phương pháp khử nhiễu được đề xuất của chúng tôi. Theo phương pháp này, ngưỡng cứng được cố định như sau:

$$\alpha_m(x) = \begin{cases} 1, & \text{Nếu } x \geq T \\ 0, & \text{Nếu } x < T \end{cases} \quad (1)$$

Từ phương trình trên, có thể thu được một dải tần mới

$$\tilde{x} = \sum_{m=0}^{N-1} \rho_T(X_B[m]) g_m \quad (2)$$

Với

$$\rho_T = \alpha_m(x) * x = \begin{cases} x, & \text{Nếu } x \geq T \\ 0, & \text{Nếu } x < T \end{cases} \quad (3)$$

2.2. Phân rã giá trị đơn lẻ (Singular Value Decomposition)

Phân rã giá trị đơn lẻ (SVD) [8] là một phương pháp nhân tạo để thiết lập dữ liệu chiếu thấp thành xấp xỉ dữ liệu chiếu cao theo các mẫu phổ biến. SVD xây dựng một hình ảnh trực quan kiến trúc mới của dữ liệu theo miền gốc. Việc giảm kích thước của nó đã tạo ra một số ứng dụng tuyệt vời. Trong nghiên cứu này, chúng tôi kiểm tra khả năng giảm nhiễu của SVD bằng cách sử dụng ngưỡng cho các giá trị kỳ dị trong các ma trận thành phần. Một cách tuyệt vời để thoát khỏi nhiễu càng nhiều càng tốt đã được thảo luận trong bài báo [8]. Phương pháp ngưỡng cứng, giải phóng thứ hạng thấp hơn trong thành phần phân rã giá trị đơn lẻ của ma trận dữ liệu Y , chọn ước lượng tốt nhất của thứ hạng r . Hai trường hợp được đưa vào phương pháp ngưỡng cứng, tùy thuộc vào độ dài của từng thứ nguyên của dữ liệu ma trận đối với Y . Ví dụ, công thức cho ma trận n -by- n và ma trận m -by- n có thể được sử dụng để xác định một thứ hạng r thích hợp để cắt bớt giá trị kỳ dị. Từ thứ hạng hợp lý r này, tín hiệu đầu vào có ngưỡng thấp đại diện cho tín hiệu nhiễu sẽ được di chuyển. Mặt khác, tín hiệu chính vẫn còn.

2.3. Savitzky-Golay filter

Nhiều tần số cao có thể được giảm một cách hiệu quả bằng cách sử dụng [9], nhưng nhiễu vẫn giữ nguyên dạng ban đầu của nó. Nguyên tắc cơ bản của cách tiếp cận này là để phù hợp từng điểm của một hình vuông nhỏ nhất với một tập hợp các đa thức bậc cao trên một cửa sổ có kích thước lẻ tập trung tại điểm đó. Đường trung bình động lần đầu tiên được sử dụng để ổn định dữ liệu thất thường. Trong quá trình này, một số điểm nhất định phải được căn chỉnh trên tọa độ của chúng để có được tọa độ trung bình. Thứ hai, ý tưởng về phép toán tích chập rời rạc được đưa vào thực tế. Hạn chế chính của các phương pháp tiếp cận hiện tại là cần phải cấu hình ngưỡng theo cách thủ công cho từng ứng dụng riêng lẻ.

Do đó, chúng tôi đề xuất một phương pháp làm giảm tín hiệu nhiễu mới dựa trên FFT và K-means, sẽ được mô tả trong phần sau, để tự động chọn ngưỡng và nâng cao hiệu quả của các phương pháp làm giảm.

3. FAST FOURIER TRANSFORM (FFT)

Ý tưởng của FFT [10] là tối ưu hóa cài đặt hệ số và do đó giảm thời gian tính toán khi so sánh với Biến đổi Fourier rời

rạc (DFT). Thật vậy, thuật toán FFT dựa trên các phương trình sau:

$$\text{Forward } X_F(k) = \sum_{n=0}^{N-1} x(n)w_N^{kn}, k = 0, 1, \dots, N - 1 \quad (4)$$

$$\text{Inverse } x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X_F(k)w_N^{-kn}, k = 0, 1, \dots, N - 1 \quad (5)$$

Trong đó, N là số lượng mẫu dữ liệu; $x(n)$ là một dãy mẫu có khoảng cách đều nhau, X_F là tập hợp các số phức trong cùng một dãy số có độ dài giống nhau của mẫu cách đều nhau, w_N^{kn} là căn thứ N của các hệ số DFT thứ k . Nói cách khác, w_N^{kn} là một tập hợp thứ k thống nhất w_N

$$w_N = \exp\left(\frac{-j2\pi}{N}\right) \quad (6)$$

4. PHƯƠNG KHÁP KHỬ NHIỄU ĐƯỢC ĐỀ XUẤT DỰA TRÊN FFT VÀ K-MEANS (DFK)

Quy trình khử nhiễu bao gồm bốn bước chính. Đầu tiên, mỗi mẫu dữ liệu đầu vào được FFT đảo ngược về phía trước. Tín hiệu được chuyển đổi bây giờ là một tập hợp các số thực. Tiếp theo, phổ tần số được tính toán để dàng từ tập hợp số thực trước đó. Tiếp theo, từ phổ tần số thu được, nhiễu và tín hiệu tinh khiết cần được phân biệt dựa trên biên độ của chúng. Một ngưỡng sẽ được chọn ra để tách biệt 2 loại biên độ đại diện cho tín hiệu đặc trưng và nhiễu. Trong bài báo này, phân cụm K-mean đã được chọn để đóng vai trò của ngưỡng này để tách phổ tần số thành hai lớp ($K = 2$). Một lớp đại diện cho tín hiệu nhiễu và lớp kia đại diện cho tín hiệu thuần túy. Ở bước cuối cùng, tín hiệu đặc trưng (thuần túy) thu được bằng cách chuyển đổi lại từ phổ tần số sang tần số bằng Inverse Fourier (IFFT).

Để biết thêm chi tiết, hãy lấy một ví dụ trong đó dữ liệu $f(x)$ được tạo ra dưới dạng kết hợp của tín hiệu tinh khiết $g(x)$ và nhiễu trắng Gaussian N .

$$f(x) = g(x) + N \quad (7)$$

$$= \sin 2\pi f_1 t + \sin 2\pi f_2 t + N \quad (8)$$

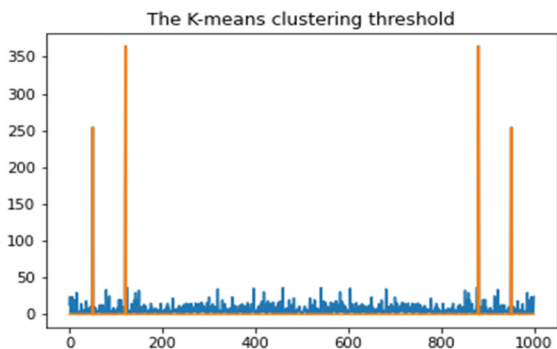
Với, $f_1 = 60$ (Hz) và $f_2 = 100$ (Hz).

Đầu tiên, $f(x)$ được FFT chuyển đổi thành $F(x)$ theo phương trình 4. Bằng định nghĩa [11], phổ công suất $P(x)$ được tính toán để dàng dựa trên $F(x)$:

$$P(x) = \langle |F(x)|^2 \rangle \quad (9)$$

Rõ ràng là biên độ của tín hiệu thuần túy và nhiễu có độ lớn khác nhau đáng kể. Do đó, tín hiệu thuần túy và nhiễu có thể được tự động phân tách bằng K-means với K được đặt thành 2 lớp (hình 1).

Một lớp (màu cam) đại diện cho phổ công suất của tín hiệu tinh khiết và lớp còn lại (màu xanh lam) đại diện cho phổ tần số của nhiễu. Cuối cùng, F_i của lớp đầu tiên với biên độ cao được chuyển trở lại tín hiệu ban đầu bằng Biến đổi Inverse Fourier (IFFT) eq.5. Cần lưu ý rằng các phương pháp phân cụm khác có thể được sử dụng thay cho K-means. Ngoài ra, ví dụ này tương đối đơn giản, ưu điểm của K-means sẽ được chứng minh rõ ràng hơn trong phần tiếp theo với một tập dữ liệu thực.



Hình 1. K-means clustering để tách tín hiệu thuần túy và nhiễu

5. CHẨN ĐOÁN ĐỘNG CƠ BẰNG DFK VÀ CNN

Trong phần này, phương pháp đề xuất DFK của chúng tôi được áp dụng để giảm nhiễu trong tập dữ liệu CWRU. Mạng lưới thần kinh kết hợp (CNN), một mô hình ANN mạnh mẽ cho vấn đề phân loại, được sử dụng để phân loại các lỗi động cơ khác nhau dựa trên dữ liệu bị nhiễu.

5.1. Dữ liệu

Tập dữ liệu CWRU là một tập dữ liệu có sẵn mã nguồn mở [12]. Dữ liệu được thu thập về các ổ trục thông thường, ổ trục điểm đơn (DE) và lỗi ở đầu quạt (FE). Một động cơ cảm ứng điện Reliance 2 mã lực, một bộ chuyển đổi mô-men xoắn, một lực kế và thiết bị điện tử điều khiển, không được hiển thị trong hình tạo nên vòng bi thiết lập giàn thử nghiệm đã được sử dụng để thu thập tập dữ liệu CWRU. Trục động cơ được hỗ trợ bởi các ổ trục thử nghiệm. Thông qua một hệ thống điều khiển điện tử và động cơ, mô-men xoắn được cung cấp cho trục. Mỗi ổ trục bị lỗi là được khôi phục trên giàn thử nghiệm sau khi các lỗi được tạo ra trên REBs, IR và OR. Các vòng bi thử nghiệm được gia công phóng điện để tạo ra các khuyết tật điểm đơn lẻ với kích thước lỗi là 7, 14, 21, 28 và 40 mils. 0,001 inch tương đương với một triệu Đối với các lỗi 7, 14 và 21 triệu, vòng bi SKF được sử dụng, trong khi các vòng bi tương đương NTN được sử dụng cho các lỗi 28 triệu và 40 triệu. Ngoại trừ vòng bi bị lỗi của bên trong có đường kính 0,028 inch, vòng bi bị lỗi ở bên ngoài có đường kính 0,040 inch, và lỗi ổ bi có đường kính 0,028 inch, tất cả các ổ trục có độ sâu lỗi là 0,011 inch. Cả ổ trục lỗi bên trong 0,028 inch và vòng bi lỗi đường đua bên ngoài 0,040 inch đều có độ sâu lỗi là 0,050 inch. Ngoài ra, theo [13], độ sâu của lỗi ổ bi đường kính 0,028 inch là 0,150 inch.

Để xác nhận mô hình của chúng tôi, dữ liệu lỗi đường kính 7 và 21 mils sẽ được sử dụng trong bài báo này. Tập dữ liệu thử nghiệm được chia thành hai bộ để phục vụ cho công việc đào tạo và xác nhận. Phần trăm dữ liệu đào tạo là 75% và phần trăm dữ liệu xác nhận là 25%. Mỗi mẫu được cắt thành các mẫu nhỏ bằng nhau, độ dài của mỗi mẫu nhỏ là 200.

5.2. Thông số của CNN

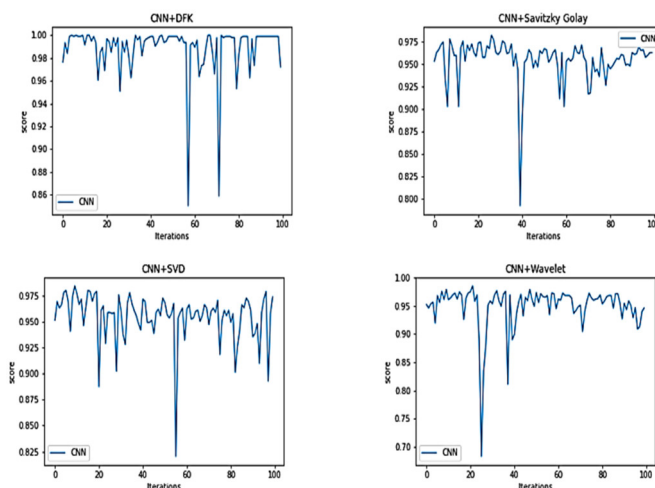
Mô hình CNN đề xuất trong [14] được sử dụng trong thử nghiệm này. Quá trình đào tạo sẽ ổn định hơn và giảm

nguy cơ sai sót dữ liệu. Bởi vì lỗi trung bình bình phương (MSE) [15] đóng vai trò của hàm loss function đối với mô hình của chúng tôi. Hơn nữa, Adam optimizer đã được sử dụng để cải thiện điểm số chính xác và tăng tốc thời gian đào tạo. Mỗi lượt được huấn luyện 100 vòng, có vẻ như đây là một cuộc chạy đua với thời gian để có được sự kết hợp phù hợp nhất giữa các phương pháp khử nhiễu và mô hình CNN này cho tập dữ liệu CWRU. Các phương pháp khử nhiễu thực nghiệm đã được trình bày trong phần 3. Để đánh giá hiệu quả của kết quả trong mỗi lần lặp và lần lặp cuối cùng. Theo bài báo [16], Accuracy, Precision, Recall, F1 score được thực hiện để đánh giá hiệu quả của từng phương pháp. Để đảm bảo khả năng giảm thiểu của mỗi phương pháp, hiệu quả của mỗi phương pháp được đánh giá dựa trên các chỉ số S/N. Ý tưởng chính về chỉ số S/N được lấy từ bài báo [17]. Giá trị S/N càng thấp thì nhiễu càng được giảm được nhiều.

Bảng 1. Bảng so sánh các phương pháp khử nhiễu

Phương pháp xử nhiễu	S/N
SVD	20,62
Wavelet	20,6
Savitzky-Golay	20,51
DFK	17,2

Bảng 1 cho thấy khả năng của DFK tốt hơn nhiều so với những người khác. Đặc biệt, điều này rõ ràng hơn khi DFK được thử nghiệm trên tập dữ liệu CWRU. Vì tín hiệu thu vào trong loại data này cực kỳ bị ảnh hưởng bởi nhiễu từ các bộ phận động cơ khác.

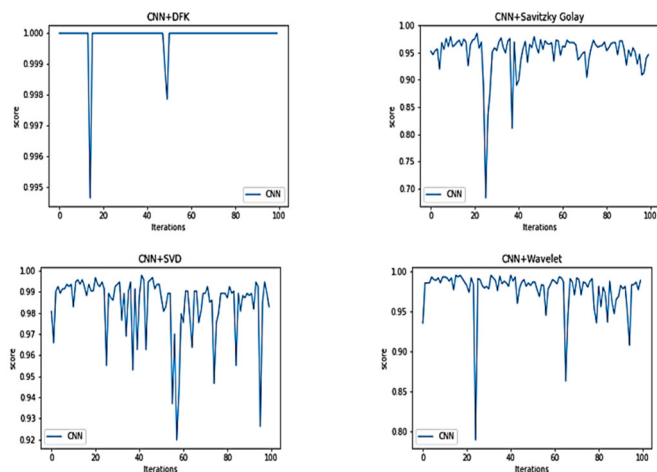


Hình 2. Accuracy score của từng sự kết hợp trên dữ liệu với đường kính cơ bản là 21 mils

Để tìm ra cấu hình tốt nhất để xử lý tập dữ liệu CWRU, mỗi loại khử nhiễu lần lượt được kết hợp với mô hình CNN. Do đó, sự kết hợp tốt nhất sẽ được tìm ra từ so sánh chúng một cách rõ ràng nhất. Để có được cái nhìn tổng thể, hiệu quả của từng kết hợp được đánh giá Accuracy score.

Dữ liệu về lỗi đường kính 21 mils lần đầu tiên được sử dụng và kết quả thu được được thể hiện trong hình 2. Theo hình này, điểm độ chính xác của mô hình trong suốt các

vòng lặp không được ổn định trong mọi trường hợp. Nhưng hiệu quả của phương pháp DFK được xem là nhất với điểm số chính xác dao động từ 86% đến 100%. Mặt khác, độ chính xác của mô hình CNN giảm xuống 70% khi được kết hợp với phương pháp khử nhiễu Wavelet.



Hình 3. Accuracy score của từng sự kết hợp trên dữ liệu với đường kính cơ bản là 7 mils

Chúng tôi cũng kiểm tra hiệu quả của các phương pháp khác nhau bằng cách sử dụng bộ dữ liệu lỗi đường kính 07 mils. Kết quả thu được được báo cáo trong hình 3. Theo hình 3, tất cả các phương pháp khử nhiễu đều có điểm chính xác cao, từ 80% đến 100%. Hơn nữa, biểu đồ phía trên bên trái cho thấy hiệu quả lớn của phương pháp đề xuất. Điểm chính xác đã đạt xấp xỉ 100%. Điểm chính xác trên tập dữ liệu xác thực đạt tới 100% trong lần lặp đầu tiên. Tín hiệu thuần khiết và nhiễu đã được tách biệt tốt nhờ DFK. Từ đó, mô hình CNN đã thực hiện rất tốt công việc học và dự đoán dữ liệu. Phương pháp DFK buộc mô hình CNN phải mạnh mẽ hơn. Rõ ràng là mô hình CNN đã tận dụng để xuất của chúng tôi để đạt được điểm chính xác của thử nghiệm là 100% trong lần lặp cuối cùng. So sánh thành tích của chúng tôi với bài báo [18], DFK đã góp phần cải thiện điểm số chính xác Accuracy cho CNN từ 93,88% đến 100% so sánh với các phương pháp khử nhiễu khác với cùng một thông số cài đặt mặc định.

6. KẾT LUẬN

Trong bài báo này, chúng tôi đề xuất một phương pháp khử nhiễu mới DFK. DFK và CNN sau đó được sử dụng để chẩn đoán lỗi động cơ. Mô hình đề xuất được thử nghiệm trên bộ dữ liệu CWRU. Các thử nghiệm cho thấy rằng phương pháp đề xuất của chúng tôi hiệu quả hơn nhiều so với các phương pháp hiện có về khả năng khử nhiễu và góp phần vào độ chính xác của mạng thần kinh dự đoán. Trong tương lai, các mô hình mạng thần kinh dự đoán có thể được phát triển để cải thiện đáng kể cả thời gian học và độ chính xác cho vấn đề chẩn đoán lỗi động cơ.

LỜI CẢM ƠN

Bài báo này được tài trợ bởi Trường Đại học Bách khoa - Đại học Đà Nẵng với đề tài có mã số: T2022-02-34.

TÀI LIỆU THAM KHẢO

- [1]. Noble W.S., 2006. *What is a support vector machine?*. Nature biotechnology 24(12), 1565–1567.
- [2]. Quinlan J.R., 1987. *Simplifying decision trees*. International journal of manmachine studies 27(3), 221–234.
- [3]. Sarkar M., Leong T.Y., 2000. *Application of k-nearest neighbors algorithm on breast cancer diagnosis problem*. In: Proceedings of the AMIA Symposium, p. 759. American Medical Informatics Association.
- [4]. Wold S., Esbensen K., Geladi P., 1987. *Principal component analysis*. Chemometrics and intelligent laboratory systems 2(1-3), 37–52.
- [5]. Albawi S., Mohammed T.A., Al-Zawi S., 2017. *Understanding of a convolutional neural network*. In: 2017 International Conference on Engineering and Technology (ICET), pp. 1–6.
- [6]. Zhang D., 2019. *Wavelet transform*. In: Fundamentals of Image Data Mining, pp. 35–44. Springer.
- [7]. Luo G., Zhang D., Baleanu D., 2012. *Wavelet denoising*. Advances in wavelet theory and their applications in engineering, physics and technology, 634.
- [8]. Donoho D.L., Gavish M., 2013. *The optimal hard threshold for singular values is 4/3*. Citeseer.
- [9]. Savitzky A., Golay M.J., 1964. *Smoothing and differentiation of data by simplified least squares procedures*. Analytical chemistry 36(8), 1627–1639.
- [10]. Peters T., 2019. *Data-driven science and engineering: machine learning, dynamical systems, and control by SL Brunton and JN Kutz*, 2019, Cambridge. Cambridge University Press, 472 pp., ISBN 9781108422093. Taylor & Francis.
- [11]. Cui W., Liu L., Yang X., Wang Y., Feng L., Springel V., 2008. *An ideal mass assignment scheme for measuring the power spectrum with fast fourier transforms*. The Astrophysical Journal 687(2), 738.
- [12]. Zhang S., Zhang S., Wang B., Habetler T.G., 2020. *Deep learning algorithms for bearing fault diagnostics - a comprehensive review*. IEEE Access 8, 29857–29881.
- [13]. Loparo K. *Case western reserve university bearing data center*. Bearings Vibration Data Sets, Case Western Reserve University: <http://csegroups>.
- [14]. Lu X., Liao W., Huang W., Xu Y., Chen X., 2021. *An improved linear quadratic regulator control method through convolutional neural network-based vibration identification*. Journal of Vibration and Control 27(7-8), 839–853.
- [15]. Prasad N.N., Rao J.N., 1990. *The estimation of the mean squared error of small-area estimators*. Journal of the American statistical association 85(409), 163–171.
- [16]. Sokolova M., Japkowicz N., Szpakowicz S., 2006. *Beyond accuracy, f-score and roc: a family of discriminant measures for performance evaluation*. In: Australasian Joint Conference on Artificial Intelligence, pp. 1015–1021, Springer.
- [17]. Alsberg B.K., Woodward A.M., Winson M.K., Rowland J., Kell D.B., 1997. *Wavelet denoising of infrared spectra*. Analyst 122(7), 645–652.
- [18]. Eren L., Ince T., Kiranyaz S., 2019. *A generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier*. Journal of Signal Processing Systems 91(2), 179–189.

AUTHORS INFORMATION

Nguyen Ho Si Hung, Tran Dinh Khoa

Faculty of Electrical Engineering, DaNang University of Science and Technology