PHÁT HIỆN TRẠNG THÁI LÀM VIỆC TRONG QUÁ TRÌNH PHAY DỰA TRÊN RUNG ĐỘNG – MỘT ỨNG DỤNG CỦA MẠNG THẦN KINH NHÂN TẠO

Phan Thành Đạt*

Tóm tắt: *Trong nghiên cứu này, Mạng Nơ-ron (Neural network - NN) được sử dụng để xác định xem liệu công cụ cắt phay có đang thực sự hoạt động (phay) hay không (chạy không tải) dựa trên độ rung của 3 trục. Dữ liệu thu thập được trong các thí nghiệm được phân tích và sử dụng trong quá trình học ngoại tuyến (off-line) của mạng NN. Các công trình trước đây cho thấy kết quả phân loại lên đến 93%. Mục tiêu của chúng tôi là xử lý dữ liệu và đạt được kết quả tốt hơn. Do đó, NN được sử dụng với sự hỗ trợ của chương trình Matlab. Ngoài ra, Thuật toán di truyền (Genetic Algorithm - GA) được sử dụng để tối ưu hóa cấu trúc liên kết NN bao gồm ba tham số: tham số trễ (tapped delay), số hệ số Biến đổi Fourier Nhanh (Fast Fourier Transform- FFT) và số nơ-ron ẩn. Kết quả phân tích đã đạt được là 99,6%.*

Từ khóa: Trạng thái phay; Rung động; Mạng nơron; Giải thuật di truyền.

1. GIỚI THIỆU

1.1. Giám sát điều kiện trong gia công CNC

Vào năm 2015, có một báo cáo từ một nhà máy không người điều khiển (unmanned factory) ở Trung Quốc rằng tỷ lệ sai hỏng giảm từ 25% xuống dưới 5% và năng lực sản xuất tăng từ 8.000 chiếc/người/tháng lên 21.000 chiếc. Sự kiện đáng chú ý này là một ví dụ cho thấy thực tế của ngành sản xuất không nhân công trong tương lai gần. Xu hướng của ngành công nghiệp gia công là giảm giá thành, nâng cao chất lượng sản phẩm và giảm cả nguồn nhân lực [1]. Hệ thống giám sát và chẩn đoán tình trạng, có khả năng xác định các khiếm khuyết của hệ thống và vị trí của chúng sẽ đóng một vai trò quan trọng trong hệ thống. Đối tượng của hệ thống giám sát là dụng cụ cắt, độ nhám bề mặt, các thông số gia công,… và hầu hết các nghiên cứu tập trung vào tình trạng của dụng cụ cắt. Rung động, phát ra âm thanh, lực cắt, nhiệt độ, âm thanh,… là một trong những phương tiện được sử dụng để theo dõi trạng thái làm việc [2]. Chúng lưu trữ thông tin dưới dạng dữ liệu chuỗi thời gian. Những dữ liệu này cần được phân tích và trích xuất để có thông tin hữu ích cùng với việc giảm nhiễu để hỗ trợ phân loại trong việc nhận biết trạng thái làm việc.

Biến dạng dẻo, đứt gãy cơ học và mài mòn cơ học trên dao phay là những vấn đề chính thường xảy ra trong quá trình máy phay làm việc [3]. Những trường hợp này khi xảy ra dẫn đến máy chạy không tải mặc dù máy vẫn ở trạng thái làm việc khi không có sự quan sát của người vận hành. Do đó, việc thiết kế một hệ thống giám sát tự động là rất quan trọng đối với máy phay CNC. Hầu hết các nghiên cứu về giám sát trạng thái làm việc của máy phay (condition monitoring) không tiếp cận theo hướng phân tích trạng thái cắt và không cắt của máy. Kết quả mới nhất của hướng tiếp cận này có thể được tìm thấy trong [4] là 93%.

1.2. Vai trò của mạng nơron trong giám sát tình trạng

Cho đến nay, mạng nơ-ron nhân tạo (Artificial Neural network- ANN) thường được gọi là Mạng nơ-ron (NN) là công cụ trí tuệ tính toán mạnh mẽ nhất. NN được giới thiệu vào đầu những năm 1940 [5] với ý tưởng thú vị đằng sau nó: máy tính có khả năng làm việc giống não bộ của con người. NN thường có ba lớp: lớp đầu vào, lớp ẩn và lớp đầu ra. Lớp đầu vào nhận dữ liệu chưa được đào tạo cho mạng NN, trong khi lớp ẩn và lớp đầu ra chứa các nút. Tất cả các lớp và nút này được kết nối từng lớp. Như đã đề cập trong [6], mạng nơ-ron đã được nhiều nhà nghiên cứu sử dụng do những ưu điểm của nó như khả năng thích ứng cao, khả năng khử nhiễu và tính chất hướng dữ liệu.

2. PHƯƠNG PHÁP LUẬN

2.1. Xử lý tín hiệu

Đầu vào dữ liệu thô tại thời điểm k có thể được mô tả như [a_k^x, a_k^y, a_k^z]. Tham số độ trễ N_d được thêm vào để biết tăng thêm thông tin của dữ liệu đầu vào $p_k = [a_k^x, a_{k-1}^x, \dots a_{k-d}^x, a_k^y, a_{k-1}^y, \dots a_{k-d}^y, a_k^z, a_{k-1}^z, \dots, a_{k-d}^z]$. Việc chọn giá trị N_d là một vấn đề quan trọng đối với đầu vào của NN. Giá trị N_d lớn hơn cung cấp thêm thông tin trạng thái phay. Tuy vậy, N_d lớn hơn cũng tạo ra nhiều nhiễu hơn và thời gian tính toán nhiều hơn.

Để có được thông tin cần thiết về trạng thái xay, dữ liệu được xử lý thông qua thuật toán Fast Fourier Transform (FFT). Thuật toán này thực sự hoạt động dựa trên Biến đổi Fourier rời rạc (DFT) (1).

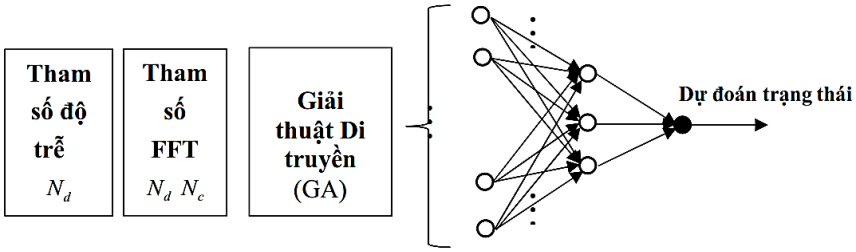
$$P_k = \sum_{n=0}^{N-1} p_n e^{-i2\pi k\frac{n}{N}} \qquad 0 \le k \le N-1 \tag{1}$$

Trong đó: p_n là viết tắt của tín hiệu N điểm trong miền thời gian $(p_0, p_1, \dots, p_{N-1})$; n và k là chỉ số thời gian và tần số rời rạc; P thuộc N tín hiệu miền tần số $(P_0, P_1, \dots, P_{N-1})$.

Vì độ dài của tín hiệu trong miền tần số bằng tín hiệu trong miền thời gian nên số hệ số FFT $N_c = c$ nên có độ dài hợp lý.

Hơn nữa, số lượng nơ-ron trong lớp ẩn N_h cũng rất quan trọng đối với cấu trúc liên kết và hiệu suất của NN. Như thảo luận trong [7], tham số này chủ yếu được lựa chọn bởi kiến thức nền tảng và thực nghiệm. Con số này có thể được chọn trong khoảng từ năm đến một trăm như đã đề cập trong [8]. Một số nhà nghiên cứu sử dụng phương pháp xác nhận chéo và chính quy hóa để tìm tham số tối ưu [9, 10] trong khi những nhà nghiên cứu khác có thể chỉ cần chọn giá trị N_h đó bằng giá trị trung bình của các nơron trong lớp đầu vào cộng với số nơron của lớp đầu ra. Trong trường hợp này, phương pháp GA được áp dụng cùng với NN để tìm các giá trị tối ưu cho N_d, N_c, N_h.

2.2. Neural Network



Hình 1. *Sơ đồ phân tích dữ liệu của mạng Nơ-ron nhân tạo.*

Mạng NN dạng suy luận tiến (Feedforward Neural network) được áp dụng để theo dõi tình trạng cắt từ dữ liệu rung động của máy phay. Trong [12], nhóm nghiên cứu của G. Zhang cho thấy rằng đối với dữ liệu đào tạo, một lớp ẩn là đủ. Cấu trúc của mạng được trình bày như trong hình 1.

Bởi vì phương pháp đào tạo ngoại tuyến (offline) đã được sử dụng nên tại thời điểm k đầu vào của NN có thể được trình bày dưới dạng: $[a_k^x, \dots, a_{c+k-1}^x, a_k^y, \dots, a_{c+k-1}^y, a_k^z, \dots, a_{c+k-1}^z]$ với a_k^x là giá trị có được từ biến đổi FFT tại thời điểm k của gia tốc trục x. Mỗi thành phần của đầu vào x_k kết nối với các nơ-ron ẩn thông qua trọng số và độ lệch. Sau khi áp dụng hàm kích hoạt cho các nơron ẩn, đầu ra từ nơron ẩn i^{th} có thể được mô tả như sau:

$$u_k^i = v(\sum_{j=1}^{C} w_k^{ji} \cdot p_k^j + w_k^{jb}) \tag{2}$$

Trong đó, u_k^i là đầu ra tại nơron ẩn i^{th} tại thời điểm k, $C = 3 \cdot c$ là số lượng mẫu đầu vào, w_k^{ji}, w_k^{jb} là trọng số và độ lệch của nơron ẩn i^{th} tại thời điểm k, v là hàm sigmoid.

Đầu ra NN vào thời điểm k được tính như sau:

$$y_k = s(\sum_{i=1}^{h} w_k^{oi} \cdot u_k^i + w_k^{ob}) \quad (3)$$

Trong đó, y_k là đầu ra của NN tại thời điểm k, u_k^i là đầu ra tại nơ-ron ẩn i^{th} tại thời điểm k, w_k^{oi}, w_k^{ob} là trọng số và độ lệch của lớp đầu ra tại thời điểm k, s là hàm softmax của lớp đầu ra.

Hàm sigmoid và softmax lần lượt được mô tả trong phương trình (4) và (5).

$$sigmoid(p) = \frac{1}{1 + e^{-p}} \quad (4)$$

$$softmax(p) = \frac{e^p}{\sum e^p} \quad (5)$$

2.3. Giải thuật di truyền (GA)

Giải thuật di truyền được áp dụng để tìm ra các thông số $[N_d, N_c, N_h]$ tối ưu về khả năng phân loại và thời gian huấn luyện của NN.

Thuật toán được diễn giải như sau:

Bước 1. Khởi tạo: Tạo quần thể gồm 30 nhiễm sắc thể (NST) của 3 tham số $[N_d, N_c, N_h]$

Bước 2. Đánh giá: Rèn luyện NN với từng bộ NST và đạt hiệu suất kiểm tra cuối cùng T_i.

Bước 3. Bắt đầu vòng lặp từ bước 4 đến bước 7.

Bước 4. Đánh giá giá trị fitness F_i của từng nhiễm sắc thể dựa trên kết quả của hàm mục tiêu.

Tính toán sự phù hợp của từng nhiễm sắc thể. Các nhiễm sắc thể phù hợp nhất có xác suất cao hơn P_i sẽ được chọn cho thế hệ tiếp theo.

$$F_i = \frac{1}{1 + T_i} \quad (6)$$

$$C_i = \sum_{1}^{i} P_i \quad (7)$$

Bước 5. Lựa chọn nhiễm sắc thể: Sử dụng phương pháp Bánh xe quay Roulette.

Bước 6. Chéo: tỷ lệ chéo μ_c = 0,7 đã được áp dụng.

Bước 7. Đột biến: áp dụng tỷ lệ đột biến μ_m= 0,1.

Bước 8. Giải pháp (Nhiễm sắc thể tốt nhất): 30 thế hệ đã được xử lý để tìm ra loại tốt nhất $[N_d, N_c, N_h]$.

3. THIẾT LẬP THÍ NGHIỆM

3.1. Hệ thống để thu thập dữ liệu

Một hệ thống cảm biến không dây điều khiển máy thu hoạch năng lượng điện từ có thể gắn vào được thiết kế như trong [4] để thu thập dữ liệu. Tổng số 59,946 mẫu dữ liệu cho mỗi mẫu chứa các tín hiệu từ trục x, trục y và trục z được sử dụng cho các thí nghiệm. Giá trị dữ liệu nằm trong khoảng từ 0,8581 đến 2,5484 theo trục.

3.2. Hệ thống thực thi mạng NN

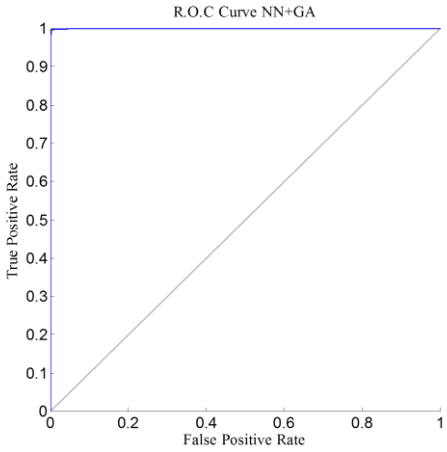
Chương trình Matlab R2016a được sử dụng để huấn luyện NN chạy trên CPU Intel Core i7 3,60 Ghz với RAM 28G và card màn hình NVIDIA GeForce GT 610 4GB. Các tham số cho hộp công cụ Mạng thần kinh được hiển thị trong bảng 1.

Bảng 1. *Bảng thông số dữ liệu sử dụng cho huấn luyện mạng NN.*

Data division	Random
Training	Trainlm
Performance	Cross-entropy
Derivative	Default
Gradient	1.00e-06
Min MSE goal	1.00e-09
Max epochs	50
Validation Checks	10

4. KẾT QUẢ THÍ NGHIỆM VÀ THẢO LUẬN

NN với GA được thực hiện đã đạt được phân loại 99,6% như trong hình 2 - Đường cong R.O.C. Kết quả đạt được với N_d= 71, N_c= 48 & N_h= 53 lần lượt là độ trễ khai thác, hệ số FFT và số nơ-ron ẩn trong lớp ẩn.



Hình 2. *Kết quả phân loại biểu diễn bằng đường cong R.O.C.*

Vẫn còn 114 lỗi trên 59.946 mẫu dữ liệu trong thử nghiệm. Đã xảy ra 48 lỗi (~ 42%) khi chuyển đổi "trạng thái phay" và "trạng thái không phay". Chi tiết được hiển thị bên dưới:

Bảng 2. *Các lỗi dữ đoán.*

Dự đoán	Thực tế	Lỗi	Lỗi tại thời điểm chuyển tiếp
1	0	68	23
0	1	46	25
Tổng cộng		114	48

5. KẾT LUẬN

Nghiên cứu đã nâng cao thành công khả năng phân loại trạng phay trong quá trình làm việc. Với cơ sở độ chính xác cao 99,6% phát hiện trạng thái làm việc và chạy không tải của quá trình gia công hứa hẹn một hệ thống tự động mà yêu cầu lao động của con người là tối thiểu. Trong các thử nghiệm gần đây, tác giả cũng áp dụng các phương pháp khác như "Trích xuất dữ liệu từ hình ảnh để phân loại dữ liệu kiểu thời gian Extracting Texture Feature for Time Series classification" dựa trên biểu đồ lặp lại "recurrent plot" [11], Máy vectơ hỗ trợ [12] và các lần chạy thử khác để thử cấu trúc liên kết mạng khác nhau như được đề xuất trong [13]. Có bằng chứng trong một số lần chạy cho thấy kết quả tốt hơn khi làm việc với SVM (tức là 99,7%). Do đó, tác giả tin tưởng rằng tỷ lệ phát hiện có thể được cải thiện khi nghiên cứu được phát triển thêm.

TÀI LIỆU THAM KHẢO

[1]. J. V. Abellan-Nebot and F. R. Subirón, *"A review of machining monitoring systems based on artificial intelligence process models,"* The International Journal of Advanced Manufacturing Technology, vol. 47, pp. 237-257, 2010.

[2]. P. N. Botsaris and J. A. Tsanakas, *"State-of-the-art in methods applied to tool condition monitoring (TCM) in unmanned machining operations: a review,"* in Proceedings of the International Conference of COMADEM, 2008, pp. 73-87.

[3]. C. Lauro, L. Brandão, D. Baldo, R. Reis, and J. Davim, *"Monitoring and processing signal applied in machining processes–A review,"* Measurement, vol. 58, pp. 73-86, 2014.

[4]. T.-K. Chung, P.-C. Yeh, H. Lee, C.-M. Lin, C.-Y. Tseng, W.-T. Lo, *et al., "An attachable electromagnetic energy harvester driven wireless sensing system demonstrating milling-processes and cutter-wear/breakage-condition monitoring,"* Sensors, vol. 16, p. 269, 2016.

[5]. J. Bishop and R. Mitchell, *"Neural networks-an introduction,"* in IEE Colloquium on Neural Networks for Systems: Principles and Applications, 1991, pp. 1/1-1/3.

[6]. N. Ambhore, D. Kamble, S. Chinchanikar, and V. Wayal, *"Tool condition monitoring system: A review,"* Materials Today: Proceedings, vol. 2, pp. 3419-3428, 2015.

[7]. G. Zhang, B. E. Patuwo, and M. Y. Hu, *"Forecasting with artificial neural networks:: The state of the art,"* International journal of forecasting, vol. 14, pp. 35-62, 1998.

[8]. J. Friedman, T. Hastie, and R. Tibshirani, *"The elements of statistical learning"* vol. 1: Springer series in statistics New York, 2001.

[9]. K. D. Theja, G. H. Gowd, and S. Kareemulla, *"Prediction & optimization of end milling process parameters using artificial neural networks,"* International Journal of Emerging Technology and Advanced Engineering, vol. 3, pp. 117-122, 2013.

[10]. C.-X. J. Feng, Z.-G. S. Yu, U. Kingi, and M. P. Baig, *"Threefold vs. fivefold cross validation in one-hidden-layer and two-hidden-layer predictive neural network modeling of machining surface roughness data,"* Journal of manufacturing systems, vol. 24, pp. 93-107, 2005.

[11]. V. M. Souza, D. F. Silva, and G. E. Batista, *"Extracting texture features for time series classification,"* in 2014 22nd International Conference on Pattern Recognition, 2014, pp. 1425-1430.

[12]. C.-C. Chang and C.-J. Lin, *"LIBSVM: A library for support vector machines,"* ACM transactions on intelligent systems and technology (TIST), vol. 2, pp. 1-27, 2011.

[13]. S. Karsoliya, *"Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture,"* International Journal of Engineering Trends and Technology, vol. 3, pp. 714-717, 2012.

ABSTRACT

DETECTION OF WORKING STATUS DURING MILLING PROCESS BASED ON VIBRATION - AN APPLICATION OF NEURAL NETWORK

In this research, a Neural Network was used to defy whether the cutting tool of milling is actually working (i.e., milling) or not (i.e., idling) based on the vibration of 3 axes. Data harvested during experiments were analyzed and used in batch learning. Previous works showed the result of up to 93% classification. Our goal is to investigate the data and reach a higher performance. Therefore, the NN is adopted to recognize the milling status and is implemented by Matlab. Moreover, Genetic Algorithm was used to optimize the NN topology including three parameters: number of tapped delay parameters, number of Fast Fourier Transform (FFT) coefficients, and number of hidden neurons. A preferable recognition rate of 99.6% was achieved.

Keywords: Milling status; Vibration; Neural network; Batch training; Genetic Algorithm.

Nhận bài ngày 14 tháng 4 năm 2021
Hoàn thiện ngày 05 tháng 8 năm 2021
Chấp nhận đăng ngày 05 tháng 9 năm 2021

Địa chỉ: Đại học Kỹ thuật Công nghiệp – Đại học Thái Nguyên.
*Email: leophanvn@gmail.com.