

PHƯƠNG PHÁP DỰ ĐOÁN MẪU HÀNH VI HỖ TRỢ HỆ THỐNG ĐIỀU KHIỂN TỰ ĐỘNG TRÊN CƠ SỞ PHÂN TÍCH DỮ LIỆU IOT SỬ DỤNG MẠNG NƠ-RON SÂU

BEHAVIORAL PATTERN PREDICTION METHOD BASED ON IOT DATA ANALYSIS USING DEEP NEURAL NETWORK FOR AUTOMATIC CONTROL

Nguyễn Ngọc Trung, Bùi Thị Duyên

Đại học Điện lực

Ngày nhận bài: 16/06/2022, Ngày chấp nhận đăng: 12/08/2022, Phản biện: TS. Phạm Văn Nam

Tóm tắt:

Kỹ thuật càng phát triển, các hệ thống máy móc và thiết bị ngày càng hiện đại và phức tạp. Nghiên cứu các giải pháp ứng dụng thành tựu công nghệ của cuộc cách mạng công nghiệp lần thứ tư (CMCN4.0) nhằm nâng cao hiệu quả của việc khai thác và sử dụng thiết bị máy móc có ý nghĩa hết sức quan trọng và cấp thiết. Trong bài báo này chúng tôi đề xuất phương pháp dự đoán mẫu hành vi trong hỗ trợ điều khiển tự động của hệ thống, trên cơ sở phân tích dữ liệu internet kết nối vạn vật (IoT) dựa trên mạng nơ-ron sâu. Kết quả đạt được của các thí nghiệm trên tập dữ liệu tổng hợp cho thấy độ chính xác dự đoán cao, trung bình 98% với mô hình đề xuất trên tập dữ liệu kiểm tra gồm 5000. Từ đó có thể ứng dụng kết quả nghiên cứu để phát triển các hệ thống tự động và điều khiển thông minh các thiết bị máy móc theo thời gian thực.

Từ khóa:

Tự động hóa và điều khiển; IoT; AI; Mạng nơ-ron sâu; Dự đoán mẫu hành vi

Abstract:

With the improvement of technologies, the systems are increasingly modern, and complex. The study of solutions to apply technological achievements of the Fourth Industrial Revolution aims to improve the efficiency of exploitation and use of technical systems is very important and urgent. In this paper, we propose a behavioral pattern prediction method based on IoT data analysis using a deep neural network for automatic control. The general results of experiments on synthetic data showed high accuracy of prediction, the accuracy of the classifier on 5000 test samples averaged 98%. Therefore, this method can be applied to develop automatic systems and smart control machinery equipment in real-time.

Keyword:

Automation and control; IoT; AI; Deep Neural Network; Behavioral Pattern forecasting

1. MỞ ĐẦU

Trong bối cảnh cuộc CMCN 4.0 đang phát triển mạnh mẽ, với sự đột phá và phát triển nhanh chóng của các công nghệ như trí tuệ nhân tạo (AI), dữ liệu lớn (Big data), IoT, v.v. Việc phân tích và xây dựng các mô hình dự báo về điều kiện, trạng thái


hoạt động của máy móc thực sự thiết thực và có ý nghĩa cho các dây chuyền, hệ thống tự động hóa ngày nay [1], [2]. Trong hoạt động sản xuất, một sự cố máy móc có thể dẫn đến ngưng trệ cả dây chuyền sản xuất, gây ra chi phí xử lý cực kì tốn kém (chi phí để đặt hàng gấp, chi phí thuê thêm nhân

viên kỹ thuật để khắc phục sự cố, chi phí do quá trình sản xuất bị dừng lại, v.v.). Do đó, việc phân tích và dự báo sớm trạng thái hệ thống nhằm đảm bảo độ tin cậy trong quá trình hoạt động của các loại máy móc hiện đại, đồng thời nâng cao hiệu quả trong hoạt động sản xuất. Vấn đề này được quan tâm cả trong lĩnh vực dân sự lẫn quốc phòng, an ninh.

Có một số mô hình và phương pháp hỗ trợ ra quyết định chủ động thông minh trong quá trình quản lý và điều khiển trạng thái kỹ thuật của thiết bị máy móc hiện đại. Tuy nhiên, mạng nơ-ron sâu (Deep Neural Network, DNN) thích hợp và cho kết quả vượt trội hơn so với các phương pháp truyền thống khác, mô hình DNN giúp cải thiện gần 20% độ chính xác so với các nghiên cứu khác, đạt trung bình 98.05 %

đối với bài toán nhận dạng tình trạng kỹ thuật cho động cơ máy bay [2].

Bài toán dự đoán mẫu hành vi hệ thống từ sớm, trước khi chúng xảy ra dựa trên cơ sở phân tích dữ liệu IoT được đề cập trong bài báo [3]. Tuy nhiên ở nghiên cứu này tác giả mới chỉ dừng lại ở bài toán dự đoán dữ liệu chuỗi thời gian thu được từ IoT, sau đó đem so sánh các giá trị dự đoán với một ngưỡng được quy định trước để tự động đưa ra quyết định bật tắt máy bơm, và độ chính xác chưa cao. Chính vì vậy, trong khuôn khổ của bài báo, chúng tôi đề xuất phương pháp dự đoán mẫu hành vi với độ chính xác cao hỗ trợ điều khiển tự động hệ thống trên cơ sở phân tích dữ liệu IoT sử dụng mạng nơ-ron sâu được thể hiện trong hình 1.



Hình 1. Mô tả quá trình hỗ trợ ra quyết định thông minh sử dụng IoT và AI

Cơ sở dữ liệu được thu thập từ các hệ thống IoT, việc nhận dạng và dự đoán các mẫu trạng thái không nhìn thấy hoặc bị ẩn từ sớm chính là cơ sở để đưa ra các quyết định trong điều khiển phù hợp và kịp thời. Đây chính là cơ sở để xây dựng và phát triển các hệ thống hỗ trợ ra quyết định điều khiển thông minh thực hiện các chức

năng phân tích dự đoán [4], dựa trên ý tưởng tính toán chủ động (proactive computing), được thực hiện theo quy trình: phát hiện → dự đoán → đưa ra quyết định → hành động như hình 1. Giả sử tồn tại tập hợp $\{M_i | i=1..n\}$ mẫu hành vi khác nhau ẩn trong tập hợp các đặc trưng $\{X(t)\}$, giá trị của các đặc trưng này có thể được thu thập

theo thời gian. Kết quả thu được là một tập dữ liệu chuỗi thời gian (Time series) rời rạc: $X(1), X(2), \dots, X(t)$. Trong đó, một số mẫu hành vi có thể dự đoán được từ sớm trước khi chúng xảy ra là yếu tố thực sự quan trọng, để đưa ra các quyết định điều khiển tác động vào hệ thống một cách tự động và kịp thời. Dự đoán này không những giúp hệ thống tự động hóa hoàn toàn mà còn tối ưu hóa việc sử dụng, khai thác các thiết bị máy móc trong hệ thống. Bài toán được mô tả như sau:

Dựa trên thông tin tiên nghiệm (priori information) được đưa ra bởi tập dữ liệu X , yêu cầu xây dựng một thuật toán F :

$$X'(t) \xrightarrow{F} M_i(t+k) \quad (1)$$

Từ đó cho phép dựa vào chuỗi giá trị $X'(t)$ tại thời điểm t dự đoán mẫu hành vi M_i sẽ xảy ra tại thời điểm $(t+k)$ (dữ liệu của tập X' không tham gia vào quá trình xây dựng và hiệu chỉnh thuật toán). Để giải quyết bài toán này cần phải nghiên cứu và sử dụng các kỹ thuật phân tích và dự đoán chuỗi thời gian khác nhau. Một trong những kỹ thuật phân tích dữ liệu chuỗi thời gian được sử dụng phổ biến và rộng rãi đó là các mô hình thống kê truyền thống như: mô hình chuỗi tự hồi quy AR (auto regression), mô hình trung bình chuyển động tự hồi quy ARIMA (AutoRegressive Integrate Moving Average), v.v. Tuy nhiên các kỹ thuật thống kê này chỉ hoạt động tốt khi dữ liệu có cấu trúc tuyến tính hoặc có thể chuyển đổi được sang cấu trúc tuyến tính. Nhược điểm của các mô hình thống kê truyền thống là: các đặc trưng bị thiếu sẽ ảnh hưởng đến hiệu suất của các mô hình, các mô hình không thể nhận ra các mẫu phức tạp trong dữ liệu, không có hiệu quả tốt trong dự báo dài hạn [5]. Để khắc phục các nhược điểm nêu trên, xu thế

gần đây các giải pháp ứng dụng các phương pháp phương pháp và thuật toán thuộc lĩnh vực AI như là học máy (Machine Learning) và học sâu (Deep Learning) phát triển rất nhanh chóng trong lĩnh vực này [4, 5, 6, 7, 8]. Các công bố đã chứng minh hiệu quả vượt trội của mạng nơ-ron.

Một trong những mô hình mạng nơ-ron điển hình được sử dụng phổ biến và đạt hiệu quả cao trong phân tích và dự đoán chuỗi thời gian là mạng nơ-ron hồi quy (Recurrent Neural Network, RNN) với phiên bản cải tiến của nó là mạng bộ nhớ ngắn dài (Long Short Term Memory, LSTM). Cấu trúc mạng nơ-ron LSTM phù hợp để mô hình hóa sự phụ thuộc dài hạn giữa các giá trị trong dữ liệu chuỗi thời gian thu được từ cảm biến, có tính chất tuần tự. Chính vì vậy, mạng nơ-ron LSTM được chúng tôi lựa chọn để xây dựng phương pháp dự đoán trong nghiên cứu này.

2. ĐỀ XUẤT PHƯƠNG PHÁP DỰ ĐOÁN MẪU HÀNH VI HỆ THỐNG.


Để dự đoán mẫu hành vi, đề xuất phương pháp dựa trên mạng nơ-ron LSTM, gồm hai quá trình được thể hiện trong hình 2:

(1) Mô hình mạng LSTM để dự đoán giá trị chuỗi thời gian từ cảm biến.

(2) Mô hình mạng nơ-ron thực hiện bài toán phân lớp.

Dữ liệu dự đoán thu được từ mô hình dự đoán chuỗi thời gian LSTM cùng với một phần của giá trị thực chuỗi dữ liệu được đưa vào mô hình mạng nơ-ron phân lớp để xác định mẫu hành vi trước khi chúng xảy ra. Khi đó bài toán dự đoán mẫu hành vi được biến đổi về bài toán phân lớp dựa trên giá trị đầu vào là chuỗi các giá trị cảm biến


thực tế và chuỗi các giá trị cảm biến dự đoán thu được từ mạng LSTM.



Hình 2. Phương pháp dự đoán mẫu hành vi hệ thống

Mạng LSTM là một phiên bản cải tiến của mạng RNN để xử lý dữ liệu dạng chuỗi. RNN chứa các vòng lặp cho phép ghi nhớ và duy trì thông tin, nó có thể sử dụng để kết nối thông tin trước đó với tác vụ hiện tại. Tuy nhiên khi khoảng thời gian giữa thông tin liên quan và vị trí dự đoán

hiện tại trở lên lớn hơn, RNN sẽ mất khả năng học cách kết nối với thông tin xa như vậy. LSTM được thiết kế để giải quyết vấn đề này. Cấu trúc của mô-đun lặp trong LSTM tại thời điểm t được thể hiện trong hình 3.



Hình 3. Cấu trúc của ba cổng trong ô LSTM

LSTM sử dụng cấu trúc ba cổng để điều khiển trạng thái của ô nhớ $c(t)$. Ba cổng có khả năng loại bỏ hoặc thêm thông tin vào trạng thái của ô. Đầu ra $h(t-1)$ và trạng thái ẩn $c(t-1)$ của ô LSTM tại thời điểm $(t-1)$ sẽ đóng vai trò là đầu vào của LSTM tại thời điểm t được đưa ra bởi thuật toán lan truyền chuyển tiếp của mạng LSTM:

Đầu vào: Ma trận các đặc trưng $X(t)$ và ma trận mục tiêu $h(t)$.

Khởi tạo: Khởi tạo ngẫu nhiên ma trận trọng số W và bias vector

Cổng quên:

$$f(t) = \sigma(W_x^f X(t) + W_h^f h(t-1) + W_c^f C(t-1) + b^f) \quad (2)$$

Cổng đầu vào:

$$i(t_k) = \sigma(W_x^i X(t) + W_h^i h(t-1) + W_c^i C(t-1) + b^i) \quad (3)$$

Giá trị ứng viên:

$$\tilde{C}(t) = \tanh(W_x^c X(t) + W_h^c h(t-1) + b^c) \quad (4)$$

Cập nhật trạng thái của ô:

$$C(t) = f(t) \odot C(t-1) + i(t) \odot \tilde{C}(t) \quad (5)$$

trong đó $\odot$ là phép nhân nguyên tố

Cập nhật đầu ra của LSTM:

$$o(t) = \sigma(W_x^o X(t) + W_h^o h(t-1) + W_c^o C(t) + b^o) \quad (6)$$

$$h(t) = o(t) \odot \tanh(C(t)) \quad (7)$$

Đầu ra: giá trị $h(t)$

Ô LSTM lấy dữ liệu cảm biến $X(t)$ làm đầu vào, có ba cổng kiểm soát luồng thông tin bên trong ô: (1) cổng vào $i(t)$ kiểm soát thông tin nào sẽ được

chuyển đến ô nhớ dựa trên đầu ra trước đó $h(t-1)$ và giá trị hiện tại của cảm biến $X(t)$, (2) cổng ra $o(t)$ kiểm soát thông tin nào sẽ được chuyển đến bước thời gian tiếp theo và (3) cổng quên $f(t)$ kiểm soát cách ô nhớ sẽ được cập nhật.

Hoạt động của phương pháp được mô tả theo trình tự các bước như sau:

Bước 1: Thu thập mẫu dữ liệu và dán nhãn các mẫu hành vi.

Bước 2: Xây dựng mô hình mạng nơ-ron LSTM nhận dữ liệu đầu vào là một chuỗi giá trị cảm biến tại thời điểm t có chiều dài l nhất định $\{X(t-l), \dots, X(t-1), X(t)\}$ để dự đoán chuỗi k giá trị tiếp theo của cảm biến $\{X(t+1), X(t+2), \dots, X(t+k)\}$.

Bước 3: Xây dựng mô hình mạng nơ-ron phân loại, nhận dữ liệu đầu vào là một chuỗi các giá trị cảm biến và chuỗi các giá trị dự đoán thu được từ mạng LSTM tại thời điểm t để đưa đầu ra là kết quả phân lớp các mẫu hành vi khác nhau của hệ thống tại thời điểm $(t+k)$.

3. KẾT QUẢ THỬ NGHIỆM VÀ ĐÁNH GIÁ HIỆU QUẢ CỦA PHƯƠNG PHÁP

Dữ liệu tổng hợp

Trong thực tế, quá trình thu thập dữ liệu thường gặp khó khăn và cần thời gian dài để triển khai các cơ sở hạ tầng cho phép thu thập và lưu trữ dữ liệu. Mặt khác tính khả dụng của dữ liệu cũng thường bị giới hạn bởi các yêu cầu về quyền riêng tư và bảo mật, do dữ liệu mà các công ty hoặc cơ quan tổ chức hiện đang có đều mang tính chiến lược đối với họ nên khó có thể tiếp cận. Chính vì vậy, để thử nghiệm các

sản phẩm, phần mềm mới, người ta thường sử dụng dữ liệu tổng hợp (synthetic data). Dữ liệu tổng hợp là dữ liệu được tạo ra một cách nhân tạo, đang ngày càng được sử dụng phổ biến trong các nghiên cứu để kiểm chứng độ hiệu quả của các giải pháp, phương pháp đề xuất, bởi nó tiết kiệm chi phí, đồng thời có thể hỗ trợ phát triển các mô hình AI, hay thử nghiệm một cách nhanh chóng [9].

Do đó trong khuôn khổ của nghiên cứu này, để kiểm chứng hiệu quả của phương pháp đề xuất, chúng tôi xây dựng và triển khai module tổng hợp dữ liệu trên ngôn ngữ lập trình python để mô phỏng dữ liệu các đặc trưng thu được từ hệ thống IoT. Module nhận tham số đầu vào như sau:

(i) Kích thước khối H – số lượng mẫu rời rạc đặc trưng cho độ dài của tập dữ liệu được tổng hợp.

(ii) Danh sách các cơ chế tổng hợp với phạm vi giá trị tương ứng dùng để mô tả các trạng thái (chế độ làm việc) khác nhau của hệ thống:

$$\{ 'm_1': [a_1, b_1], 'm_2': [a_2, b_2], 'm_3': [a_3, b_3], \dots, 'm_n': [a_n, b_n] \}$$

trong đó:


$m_1 \dots m_n$ các chế độ làm việc khác nhau của hệ thống.

$a_1 \dots a_n$ các phân tử của vector, trái và cận dưới của tín hiệu ứng với mỗi trạng thái của hệ thống.

$b_1 \dots b_n$ các phân tử của vector, phải và cận trên của tín hiệu ứng với mỗi trạng thái của hệ thống.

(iii) Cơ chế mô tả dữ liệu (mô tả hoạt động của hệ thống), có thể được chỉ định rõ ràng. Nếu không được chỉ định rõ ràng thì được đặt ngẫu nhiên ở dạng sau: $[('m_1', k_1), ('m_2', k_2), \dots, (m_n, k_n)]$, trong đó: $m_1 \dots m_n$ - là tên các chế độ hoạt động của hệ thống và giá trị thứ 2 trong danh sách $(k_1 \dots k_n)$ mô tả số lượng mẫu được tạo cho mỗi chế độ.

Ở hình 4 mô tả các tập dữ liệu với độ dài khác nhau (đặc trưng bởi kích thước khối H) được tổng hợp sử dụng module tổng hợp dữ liệu đã xây dựng.




Hình 4. Minh họa một số tập dữ liệu với độ dài khác nhau được tổng hợp bằng mô đun

Xây dựng mô hình


Phương pháp và các mô hình đề xuất được xây dựng và triển khai bằng ngôn ngữ Python. Lý do chính cho sự lựa chọn ngôn ngữ lập trình này là do nó cung cấp một hệ sinh thái thư viện lớn, đang được các nhà khoa học trên khắp thế giới trong mọi lĩnh vực sử dụng cho việc viết chương trình và phát triển các thuật toán trí tuệ nhân tạo (machine learning và deep learning). Các mô hình mạng nơ-ron trong nghiên cứu này được xây dựng bằng thư viện Keras [10] và Tensorflow [11].

Để dự đoán giá trị của các thông số của hệ thống, xây dựng trên mô hình Seq-to-Seq trên cơ sở mạng LSTM. Lớp đầu tiên - LSTM, bao gồm N đầu vào - số lượng các giá trị trong quá khứ được tính đến (tương ứng với kích thước của khối tín hiệu). Lớp thứ hai là khối Dense với k đầu ra - số lượng các giá trị dự đoán (khoảng dự đoán - forecast horizon). Trình tối ưu hóa Adam và hàm mất mát MSE được sử dụng để huấn luyện mô hình dự đoán. Cấu trúc của mô hình dự đoán được thể hiện trong hình 8 cho $N = 30$ và $k = 3$. Sơ đồ cấu trúc của bộ phận lớp thể hiện ở hình 5



Hình 5. Sơ đồ các lớp của mô hình dự đoán với $N = 30$ và $M = 3$

Để nhận dạng hành vi của thiết bị dựa trên giá trị dự đoán thu được từ mô hình LSTM, một bộ phân lớp trên cơ sở mô hình Sequential với một lớp Dense được xây dựng. Mô hình phân lớp có đầu vào là: (i) chuỗi các giá trị đặc trưng, (ii) chuỗi giá trị dự đoán (kết quả dự đoán thu được từ mạng LSTM), đầu ra là mẫu hành vi cụ thể. Số lượng đầu vào của mô hình tương ứng với kích thước của khối tín hiệu và số lượng đầu ra tương ứng với số lớp (chế độ làm việc). Để huấn luyện bộ phân lớp, đề xuất sử dụng hàm kích hoạt softmax cho lớp Dense, bộ tối ưu hóa Adam, hàm mất mát - categorical_crossentropy. Sơ đồ cấu trúc của bộ phận lớp thể hiện ở hình 6



Hình 6. Sơ đồ các lớp của bộ phận lớp giúp nhận diện mẫu hành vi hệ thống

Kết quả

Các thử nghiệm được tiến hành trên dịch vụ đám mây Google Colaboratory (Colab) với GPU NVIDIA Tesla K80 12 GB. Ngôn ngữ lập trình là Python 3.9 và sử dụng thư viện Keras và Tensorflow để tạo và huấn luyện các mô hình mạng nơ-ron sâu.

Để đánh giá độ chính xác dự đoán của mô hình dự đoán chuỗi thời gian sử dụng sai số tuyệt đối trung bình MAE (Mean Absolute Error):


$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| = \text{mean}(|e_i|), \quad (8)$$

trong đó $e_i = (y_i - \hat{y}_i)$, y_i , $\hat{y}_i$ – giá trị thực tế và giá trị dự đoán tại mỗi thời điểm i tương ứng.

Để đánh giá hiệu quả của mô hình phân lớp, sử dụng ma trận lỗi (Confusion Matrix) phân lớp $M = \{m_{ij}\}_{i,j=1}^N$. Ma trận này hiển thị số lượng đối tượng thực tế thuộc về lớp C_i , nhưng được dự đoán thành lớp C_j .

Để huấn luyện bộ phân lớp, tạo một số bộ tín hiệu cho mỗi lớp bằng cách sử dụng

mô đun tổng hợp dữ liệu đã mô tả ở trên. Việc huấn luyện mô hình được thực hiện trên 45.000 mẫu trong 10 Epoch. Độ chính xác của bộ phân lớp trên mẫu dữ liệu thử nghiệm gồm 5000 mẫu đạt trung bình 98%. Kết quả chung của các thí nghiệm trên dữ liệu tổng hợp cho thấy độ chính xác dự đoán cao (sai số dự đoán tối đa MAE 0,075) và phân lớp (sai số phân lớp tối đa 6,78% trên chuỗi dữ liệu có độ dài ngắn nhất). Hình 7 minh họa giải pháp của vấn đề dự đoán mẫu hành vi hệ thống. Các mô hình dự đoán và phân loại đã được huấn luyện trên các kích thước khối khác nhau. Độ chính xác của mô hình cho các kích thước khối khác nhau được trình bày trong bảng 1



Hình 7. Tín hiệu thực (xanh lam), tín hiệu dự đoán (đỏ), các mẫu hành vi (chế độ làm việc) m1- m5 (trong đó màu đỏ là dự đoán sai, màu xanh lá cây là khớp).

Bảng 1. Độ chính xác của các mô hình dự đoán mẫu hành vi hệ thống cho các kích thước khối


Kích thước khối H	Sai số phân lớp, %	Sai số dự đoán (MAE)
20	6.78	0.075
30	3.39	0.070
40	3.39	0.072
50	0.41	0.072

60	1.69	0.066
70	1.69	0.071
80	0.18	0.065
90	1.69	0.064

Đề xuất mô hình để áp dụng và triển khai phương pháp

Sau khi kiểm chứng được độ chính xác của mạng DNN trong dự đoán mẫu hành vi hệ thống, chúng tôi đề xuất mô hình để áp dụng và triển khai phương pháp trong thực tế như được trình bày trên hình 8. Các thông số khác nhau đặc trưng cho các chế độ làm việc khác nhau của hệ thống được giám sát và thu thập thông qua mạng lưới các cảm biến. Dữ liệu chuỗi thời gian $X(t)$ trong hình 8 đặc trưng cho một số mẫu hành vi (chế độ làm việc, trạng thái làm việc) nhất định của hệ thống. Mục tiêu là tìm hiểu và dự đoán các mẫu hành vi này

dựa trên các giá trị cảm biến, các hành động điều khiển theo các kịch bản khác nhau sẽ được kích hoạt dựa trên các kết quả dự đoán (ví dụ đơn giản nhất là có thể kích hoạt ON/OFF một relay thực hiện chức năng nào đó). Để thực hiện công việc này, chúng tôi đề xuất xây dựng mô hình gồm hai giai đoạn. Trong giai đoạn đầu, các mô hình DNN khác nhau được xây dựng và áp dụng cho dữ liệu thu được từ cảm biến và mô hình tốt nhất sẽ được lựa chọn để sử dụng cho giai đoạn 2 dựa trên một số thước đo nhất định. Trong giai đoạn thứ 2, hệ thống hỗ trợ điều khiển được xây dựng để đưa ra các hành động điều khiển dựa trên các mẫu hành vi được dự đoán.



Hình 8. Đề xuất mô hình hỗ trợ điều khiển tự động trên cơ sở dự đoán mẫu hành vi hệ thống

4. KẾT LUẬN

Trong bài báo này, chúng tôi đã trình bày phương pháp mới để dự đoán mẫu hành vi hỗ trợ điều khiển tự động hệ thống trên cơ sở phân tích dữ liệu IoT sử dụng mạng nơ-ron sâu. Phương pháp gồm hai phần chính, đó là mạng nơ-ron LSTM dự đoán nhiều bước giá trị cảm biến và mạng nơ-ron thực hiện nhiệm vụ phân lớp các giá trị dự đoán thu được từ mạng LSTM. Trên cơ sở kết quả thu được, có thể đưa ra kết luận về độ chính xác của phương pháp đề xuất. Cách tiếp cận này cho phép phát triển và triển khai các hệ thống điều

khiển chủ động không cần sự tham gia của con người với độ chính xác cao áp dụng trong điều khiển hệ thống, thiết bị máy móc trong các ngành công nghiệp khác nhau với mục đích tương tự của kết quả bài báo. Trong các nghiên cứu tiếp theo nhóm tác giả sẽ hướng tới việc áp dụng, thử nghiệm phương pháp trong bài toán thực tế, đồng thời nghiên cứu ứng dụng các thuật toán học tăng cường (Reinforcement Learning) để giải quyết bài toán tự động, xác định các kịch bản điều khiển khác nhau dựa trên hoàn cảnh mẫu hành vi cụ thể để đạt được lợi ích cao nhất trong phát triển các hệ thống tự động điều khiển.

TÀI LIỆU THAM KHẢO

- [1] Cuong Sai, M. V. Shcherbakov and V. P. Tran. Data-driven framework for predictive maintenance in industry 4.0 concept. Creativity in Intelligent Technologies and Data Science. CIT&DS 2019. Communications in Computer and Information Science, vol 1083. Springer, Cham. https://doi.org/10.1007/978-3-030-29743-5_28.
- [2] M. Shcherbakov and Cuong Sai. (2022). A hybrid deep learning framework for intelligent predictive maintenance of Cyber-Physical Systems. ACM Transactions on Cyber-Physical Systems (TCPS), 6(2), 1-22.
- [3] Khan, N. S., Ghani, S., & Haider, S. (2018). Real-time analysis of a sensor's data for automated decision making in an IoT-based smart home. Sensors, 18(6), 1711.
- [4] Cuong Sai and M. Shcherbakov. (2019). PdM: A predictive maintenance modeling tool implemented as R-package and web-application. In Proceedings of the Tenth International Symposium on Information and Communication Technology (pp. 433-440).
- [5] Cuong Sai and M. Shcherbakov. (2020). Statistical and machine learning high-frequency time series forecasting methods in automatic mod. Heraald of computer and information technologies (pp. 3-11)
- [6] Sagheer, A. Unsupervised pre-training of a Deep LSTM-based Stacked Autoencoder for Multivariate time Series forecasting problems / A. Sagheer, M. Kotb // Scientific Reports. – 2019. – № 9(1). – P.1–16.
- [7] Tra, V. Bearing Fault Diagnosis under Variable Speed Using Convolutional Neural Networks and the Stochastic Diagonal Levenberg-Marquardt Algorithm / V. Tra, J. Kim, S. A. Khan // Sensors. – 2017. – Vol 17(12). – P. 1–16.
- [8] Zheng, S. Long Short-Term Memory Net-work for Remaining Useful Life estimation / S. Zheng, K. Ristovski, A. Farahat, C. Gupta // In Proceedings of the 2017 IEEE In-ternational Conference on Prognostics and Health Management (ICPHM), Dallas, TX, USA. – 2017. – P. 88–95.
- [9] What are its Use Cases & Benefits? Available at: <https://research.aimultiple.com/synthetic-data/> (accessed 12.05.2022).
- [10] Keras: The Python Deep Learning library. Available at: <https://keras.io/> (accessed 19.05.2022).
- [11] Tensorflow. The Python Deep Learning Library Available at: <https://www.tensorflow.org/> (accessed 19.05.2022).

Giới thiệu tác giả:

	Tác giả Nguyễn Ngọc Trung tốt nghiệp đại học ngành hệ thống điện, nhận bằng Thạc sĩ ngành kỹ thuật điện tại Trường Đại học Bách khoa Hà Nội vào các năm 2003 và 2006; nhận bằng Tiến sĩ ngành kỹ thuật điện năm 2014 tại Đại học Palermo, Cộng hòa Italia. Hiện tại, tác giả là giảng viên, Phó trưởng phòng Phòng Quản lý khoa học và Hợp tác quốc tế, Trường Đại học Điện Lực. Lĩnh vực nghiên cứu: lưới điện thông minh - SmartGrid, giám sát, đo lường điều khiển, bảo vệ và tự động hóa trong hệ thống điện.
	Tác giả Bùi Thị Duyên tốt nghiệp đại học chuyên ngành Kỹ thuật đo và Tin học công nghiệp năm 2004; nhận bằng Thạc sĩ chuyên ngành Tự động hóa năm 2007v; nhận bằng tiến sĩ chuyên ngành Kỹ thuật điều khiển và Tự động hóa năm 2020 tại trường Đại học Bách khoa Hà Nội. Hiện nay tác giả là giảng viên của khoa Điều khiển và Tự động hóa, Trường Đại học Điện Lực. Lĩnh vực nghiên cứu: hệ thống đo lường điều khiển, thiết kế các hệ thống nhúng ứng dụng trong điều khiển và tự động hóa, mạng cảm biến không dây, anten và mạch cao tần.