

Mô hình xác suất LSTM-MC Dropout sử dụng Biểu đồ dự báo Kiểm soát Chất lượng công trình

A probabilistic LSTM-MC dropout model for Control Chart Pattern prediction

Nguyễn Trọng Dũng^{1,*}, Vũ Ngọc Trụ², Hồ Anh Cường³, Nguyễn Huy Hùng³, Hoàng Thanh Thủy³, Vũ Hải Cảnh⁴, Huỳnh Khắc Tuấn⁵

¹Trường Đại học Mỏ-Địa chất

²Trường Đại học Xây dựng Hà Nội

³Trường Đại học Giao thông vận tải

⁴Trường Đại học Công nghệ Compiègne, Pháp

⁵Trường Đại học Công nghệ Troyes, Pháp

*Email liên hệ: nguyentrongdung@humg.edu.vn

Tóm tắt:

Biểu đồ kiểm soát là một công cụ hiệu quả trong kiểm soát quá trình thống kê, giám sát chất lượng công trình. Trong thực tế, mỗi mẫu trong biểu đồ kiểm soát chất lượng thường tương ứng với các trạng thái hoạt động/hư hỏng của các công trình. Hầu hết các công trình nghiên cứu hiện tại đều tập trung vào việc xác định các mẫu biểu đồ kiểm soát (Control Chart Pattern - CCP). Trong bài báo này, nhóm tác giả đề xuất một mô hình tiên lượng cho dự báo CCP. Mô hình được xây dựng dựa trên kỹ thuật học sâu mạng nơ ron hồi quy nhân tạo LSTM (Long-Short-Term Memory) có tính xác suất để nắm bắt các yếu tố phụ thuộc và không chắc chắn của dữ liệu biểu đồ kiểm soát. Hiệu quả của mô hình được đề xuất được xác nhận thông qua một nghiên cứu số. Các kết quả dự báo có thể sử dụng như là cơ sở cho việc ra quyết định bảo trì mang tính dự báo và giúp tránh những hư hỏng không mong muốn.

Từ khóa: Kiểm soát quá trình thống kê; Dự báo mẫu biểu đồ kiểm soát chất lượng; Học sâu có tính xác suất; Kỹ thuật học sâu mạng nơ ron hồi quy nhân tạo (LSTM); Phương pháp loại bỏ ngẫu nhiên Monte Carlo (MC).

Abstract:

Control chart, a powerful tool of statistical process control, monitors efficiently the production quality. In practice, it is realized that each pattern in a control chart usually corresponds to a functional/failed to state of the production process. Most existing works in the literature focus on the identification of control chart patterns (CCPs). In this paper, we propose a prognostic model for CCPs forecasting. The model is constructed based on the probabilistic long-short-term memory (LSTM) network to capture the dependencies and uncertainties of the control chart data. The performance of the proposed model is then validated through a numerical study. The prediction results can be used as a basis for the predictive maintenance decision-making and helping to avoid unexpected failures of the production process.

Keywords: Statistical process control; Control Chart Patterns forecasting, Probabilistic deep learning, Long short Term Memory (LSTM), Monte Carlo (MC) Dropout.

1. Giới thiệu

Chất lượng công trình là yếu tố cốt lõi của doanh nghiệp. Các vấn đề về chất lượng dẫn đến các hậu quả đáng kể chẳng hạn như chi phí thi công bổ sung,

sự không hài lòng của khách hàng, hình ảnh thương hiệu tiêu cực,... Kiểm soát quá trình thống kê (SPC) đã được áp dụng thành công trong công nghiệp để giám sát và cải thiện chất lượng công trình. Như được chỉ ra bởi tên của nó, một trong những ưu điểm

của SPC là có thể tính đến sự bất ổn của quá trình thi công (liên quan đến lỗi máy móc hoặc điều kiện khai thác) nhờ vào nguyên tắc thống kê của nó [1].

Biểu đồ kiểm soát, một trong những công cụ phổ biến nhất của SPC, là sự mô tả bằng đồ họa của một đặc tính chất lượng được tính toán từ một mẫu công trình theo thời gian [2]. Sự phát triển của biểu đồ kiểm soát không hoàn toàn ngẫu nhiên và thường tuân theo một số xu hướng/khuôn mẫu CCP. Mỗi khuôn mẫu biểu thị dấu hiệu của một trạng thái hoạt động/hư hỏng cụ thể của quá trình thi công. Theo Zan [3], có sáu loại CCP bao gồm mẫu bình thường (NOR), mẫu dịch chuyển lên (US), mẫu dịch chuyển xuống (DS), mẫu có xu hướng tăng (UT), mẫu có xu hướng giảm (DT) và mẫu chu kỳ (CYC). Việc nhận dạng/phân biệt các khuôn mẫu bất thường đã được nghiên cứu rộng rãi trong các tài liệu tham khảo vì nó giúp phát hiện và xác định nguyên nhân của các vấn đề thuộc hệ thống thi công [4]. Phương pháp học máy đã được sử dụng rộng rãi cho việc xác định các CCP dựa vào mức độ phức tạp của dữ liệu CCP, ví dụ, mạng nơ ron nhân tạo RBF [5], mã hóa tự động sâu [6], mạng tích chập (CNN - convolutional neural network) [3], cây quyết định và phương pháp thực nghiệm tập mờ [7], kỹ thuật cụm quang phổ và máy véc tơ hỗ trợ [8]. Tuy nhiên, theo hiểu biết của nhóm tác giả, chưa có công trình nào tập trung vào việc dự đoán các CPP. Việc dự đoán các CCP có thể cung cấp các thông tin hữu ích cho việc phát hiện sớm các vấn đề về chất lượng công trình và hoạt động bất bình thường của hệ thống thi công. Các kết quả đạt được có thể sử dụng như là một nền tảng cho việc ra quyết định dự báo công tác bảo trì [9], [10], để tránh được các hư hỏng máy móc và/hoặc các vấn đề về chất lượng không mong đợi, đây cũng là công nghệ nền tảng cho khái niệm thi công không lỗi của nền công nghiệp 4.0 (zero-defect manufacturing) [11].

Để dự đoán sự phát triển của các biểu đồ kiểm soát, các mạng lưới LSTM được đề xuất trong tài liệu [12] được sử dụng. Các mạng lưới LSTM có thể nắm bắt được tính phụ thuộc phức tạp của chuỗi dữ liệu thời gian (time series) khi so sánh với các phương pháp học máy khác. Mạng LSTM là một dạng đặc biệt của mạng nơ ron hồi quy (RNN -

Recurrent Neural Network) [13], nó có khả năng học được các phụ thuộc xa để khắc phục sự triệt tiêu và bùng nổ của gradient, chính là thách thức phổ biến nhất trong thiết kế vào đào tạo các mạng RNN. LSTM đã được ứng dụng rộng rãi và thành công cho việc dự báo chuỗi thời gian [14]. Với nhiều ưu điểm, LSTM nói riêng và các phương pháp học sâu xác định khác nói chung thường chỉ cung cấp một ước tính đầu ra tại một thời điểm tương lai và do đó, không nắm bắt được tính bất ổn của dự đoán [15]. Tính bất ổn có thể đến từ nhiều nguồn khác nhau như tạp nhiễu dữ liệu (tạp nhiễu cố hữu), số lượng dữ liệu hạn chế, và sự khác biệt giữa dữ liệu lịch sử và dữ liệu tương lai (tính bất ổn của mô hình) [16]. Để xem xét tính bất ổn này, các mô hình học sâu mang tính xác suất đã được phát triển, có thể được chia thành hai loại sau [17]: Mạng nơ ron nhân tạo Bayesian (BNN) và mạng nơ ron nhân tạo kết hợp với loại bỏ ngẫu nhiên Monte Carlo. Mạng nơ ron nhân tạo Bayesian (BNN) [18], [19] đưa tính bất ổn vào các mô hình học sâu trên quan điểm Bayesian. Các trọng số và độ lệch của mạng lưới được mô hình hóa bằng phân bố xác suất. Các BNN nhằm mục đích tìm ra các phân bố sau về trọng số và độ lệch của chúng khi đã có phân bố trước và dữ liệu lịch sử dựa trên định lý của Bayes. Trong suốt giai đoạn đào tạo, các phân phối sau được tìm thấy bằng các phương pháp suy luận khác nhau như Bayes biến thiên, lan truyền ngược xác suất, Bayes bởi BackProp,... Các thuật toán trên đưa vào các thông số ngoài mô hình và việc thực hiện các thuật toán là phức tạp. Việc tích hợp các thuật toán này vào những phương pháp học sâu hiện có là một thách thức. Ngoài ra, các mạng lưới thần kinh với phương pháp loại bỏ ngẫu nhiên Monte Carlo lại dễ thực hiện và có thể áp dụng trực tiếp cho mọi mạng lưới thần kinh hiện có. Ý tưởng cơ bản là thêm lớp loại bỏ ngẫu nhiên Monte Carlo (MC) vào mỗi lớp ẩn của mạng lưới thần kinh. Một số nơ ron bị loại bỏ một cách ngẫu nhiên trong quá trình tính toán đầu ra của mô hình. Khi quá trình tính toán được lặp lại một số lần, các tác giả đã thu được một mẫu đầu ra của mô hình có thể được coi gần đúng như một mẫu ngẫu nhiên phát sinh từ các phân bố trước trong thực tế [21]. Mục đích của bài báo này là phát triển một mô hình dự đoán dựa trên các

mạng lưới LSTM và loại bỏ ngẫu nhiên MC cho việc dự báo CCP.

Bài báo được bố cục như sau: Phần một nhóm trình bày chi tiết hơn về CPP và cách thức mô hình hóa dữ liệu CPP được giới thiệu trong phần thứ hai. Phần thứ ba là phát triển mô hình dự báo dựa trên các mạng lưới LSTM và loại bỏ ngẫu nhiên MC. Phần thứ tư và thứ năm trình bày một số kết quả phân tích số và kết luận.

2. Các mẫu biểu đồ kiểm soát

Biểu đồ kiểm soát là một mô tả bằng đồ họa về đặc tính chất lượng có thể đo đạc hoặc tính toán từ một mẫu các công trình theo số lượng mẫu/thời gian [2]. Trong số các biểu đồ kiểm soát hiện có, biểu đồ thanh X là phổ biến nhất vì nó cho phép giám sát giá trị trung bình của quá trình và phát hiện một cách hiệu quả các vấn đề về chất lượng công trình. Trong biểu đồ này, ngoài những giá trị trung bình của các mẫu khác nhau, đường trung tâm biểu thị giá trị trung bình của một đặc tính chất lượng X và hai đường theo phương ngang còn lại biểu thị giới hạn kiểm soát trên UCL (Upper Control Limit) và giới hạn kiểm soát dưới LCL (Lower Control Limit). Các giới hạn này được tính toán như sau:

$$UCL = \mu_x + L \cdot \sigma_x \text{ và } LCL = \mu_x - L \cdot \sigma_x \quad (1)$$

Trong đó μ_x và σ_x lần lượt là giá trị trung bình và độ lệch tiêu chuẩn của X; L là hằng số và thường bằng 3.

Kết quả của quá trình thi công nằm trong giới hạn cho phép nếu các giá trị trung bình của các mẫu nằm trong các giới hạn kiểm soát, không cần thêm tiến trình nào. Mặt khác, khi một điểm nằm ngoài các giới hạn kiểm soát tức là quá trình ngoài tầm kiểm soát, cần tiến hành các hoạt động sửa chữa để phát hiện và loại trừ những nguyên nhân hư hỏng [4]. Tuy nhiên, trong thực tế, cần chú ý rằng một quá trình thi công vẫn có thể nằm ngoài tầm kiểm soát và gây ra một số vấn đề chất lượng mặc dù tất cả các điểm nằm trong giới hạn kiểm soát. Nguyên nhân là các điểm này tuân theo một số xu hướng không ngẫu nhiên. Việc nghiên cứu các mẫu CCP là cần thiết để phát hiện các vấn đề về chất lượng [22].

Đối với một quá trình thi công, thường có sáu loại CCP phổ biến: Mẫu bình thường (NOR), mẫu chuyển dịch lên (US), mẫu chuyển dịch xuống (DS), mẫu có xu hướng tăng (UT), mẫu có xu hướng giảm (DT) và mẫu chu kỳ (CYC) [3]. Dữ liệu của các CCP này có thể được tạo ra bằng cách sử dụng mô hình Monte Carlo và biểu thức toán học sau:

$$y(t) = \mu_x + \epsilon_x(t) + \mathcal{U}(t) \quad (2)$$

Trong đó, $y(t)$ biểu thị giá trị trung bình của mẫu được xem xét tại thời điểm t ; $\epsilon_x(t) \sim \mathcal{N}(0, \sigma_x^2)$ là tập nhiễu quá trình khi nằm trong tầm kiểm soát; $\mathcal{U}(t)$ biểu thị cho sự nhiễu loạn đặc biệt gây ra bởi các vấn đề cụ thể trong quá trình thi công từ thời điểm t . Từ (2), các CCP khác nhau được định nghĩa như sau:

- **Mẫu bình thường:** Quá trình nằm trong tầm kiểm soát, cụ thể là $\mathcal{U}(t) = 0$:

$$y_{NOR} = \mu_x + \epsilon_x(t) \quad (3)$$

- **Mẫu dịch chuyển lên:** Giá trị trung bình của đặc tính X tăng δ_x đơn vị tại thời điểm dịch chuyển $t = t_{US}$, cụ thể là $\mathcal{U}(t) = \Pi_{\{t \geq t_{US}\}} \cdot \delta_x$, trong đó $\Pi_{\{t \geq t_{US}\}}$ là một hàm chỉ thị, $\Pi_{\{t \geq t_{US}\}} = 1$ nếu $t \geq t_{US}$ hoặc $\Pi_{\{t \geq t_{US}\}} = 0$ nếu $t < t_{US}$:

$$y_{US}(t) = \mu_x + \epsilon_x(t) - \Pi_{\{t \geq t_{US}\}} \cdot \delta_x \quad (4)$$

- **Mẫu dịch chuyển xuống:** Giá trị trung bình của đặc tính X giảm δ_x đơn vị tại thời điểm dịch chuyển $t = t_{US}$:

$$y_{DS}(t) = \mu_x + \epsilon_x(t) - \Pi_{\{t \geq t_{DS}\}} \cdot \delta_x \quad (5)$$

- **Mẫu có xu hướng tăng:** Giá trị trung bình của đặc tính X tăng theo thời gian, cụ thể $\mathcal{U}(t) = \eta \cdot t$, η là độ dốc của xu hướng:

$$y_{UT}(t) = \mu_x + \epsilon_x(t) + \eta t \quad (6)$$

- **Mẫu có xu hướng giảm:** Giá trị trung bình của đặc tính X giảm theo thời gian:


$$y_{DT}(t) = \mu_x + \epsilon_x(t) - \eta t \quad (7)$$

- **Mẫu chu kỳ:** Giá trị trung bình của đặc tính X giảm và tăng theo thời gian theo quy luật hình sin, cụ thể $\mathcal{U}(t) = \beta \cdot \sin\left(\frac{2\pi t}{\omega}\right)$, β là biên độ của chu kỳ và ω là quãng của một chu kỳ:

$$y_{CYC}(t) = \mu_x + \epsilon_x(t) + \beta \cdot \sin\left(\frac{2\pi t}{\omega}\right) \quad (8)$$

Một ví dụ về CCP được biểu diễn trong hình 1. Có 100 điểm được tạo nên cho mỗi biểu đồ kiểm soát với các thông số như sau: $\mu_x = 10$, $\sigma_x = 0.1$, $t_{US} = t_{DS} = 40$, $\delta_x = 1/3$, $\eta = 0.01$, $\omega = \pi/25$, $\beta = 0.5$. Trừ mẫu bình thường, các CCP bất thường khác chỉ ra các vấn đề trong quá trình thi công. Như được đề cập trong phần giới thiệu, hầu hết các công trình nghiên cứu hiện tại tập trung vào việc nhận biết các mẫu bất thường để phát hiện các vấn đề và nguyên nhân hình thành vấn đề. Trong bài báo này, nhóm

tập trung vào việc dự đoán các CPP. Các kết quả dự báo có thể được sử dụng cho việc ra quyết định bảo trì dự đoán (predictive maintenance), giúp tránh các vấn đề thi công và cải thiện chất lượng công trình. Theo biểu diễn trong hình 1, dữ liệu các CCP có thể nhận thấy là các chuỗi thời gian không tuyến tính và không đều. Đặc biệt, chúng luôn bao gồm các phần xác định và ngẫu nhiên. Với các lý do này, các mạng lưới Bayesian-LSTM được áp dụng cho việc dự báo các CCP. Một miêu tả chi tiết của thuật toán sẽ được trình bày trong phần tiếp theo.



Hình 1. Ví dụ về các mẫu biểu đồ kiểm soát khác nhau.

3. Mô hình học sâu mang tính xác suất cho việc dự báo các mẫu biểu đồ kiểm soát

Phần này giải thích cách thức LSTM và loại bỏ ngẫu nhiên MC được sử dụng để dự báo các mẫu biểu đồ kiểm soát. Các bước chính của khung chương trình đề xuất được trình bày trong hình 2.

3.1. Tiền xử lý dữ liệu

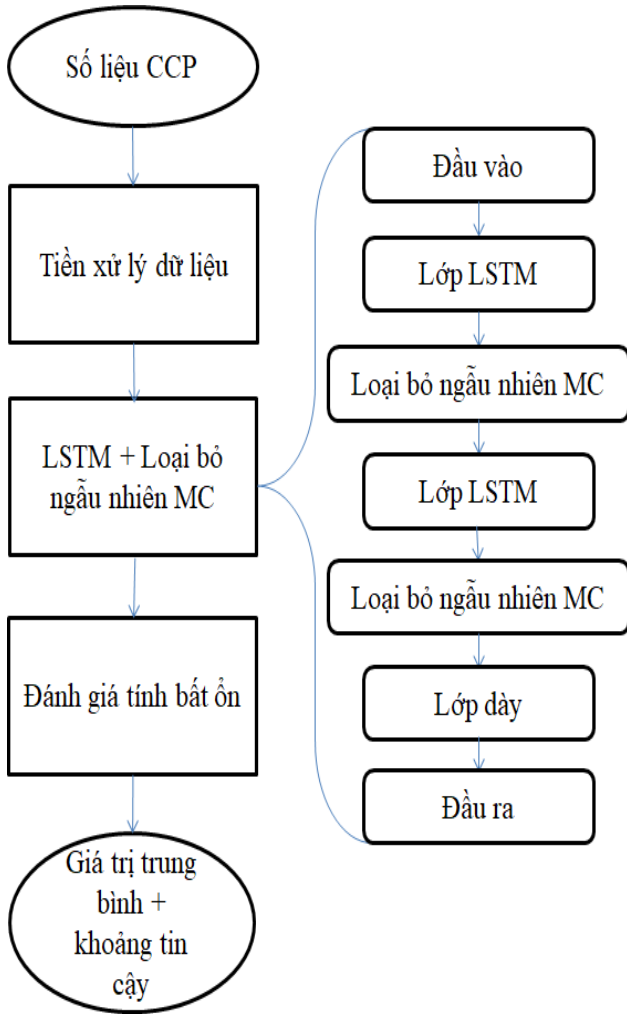
Chuẩn hóa tối thiểu-tối đa: Số liệu biểu đồ kiểm soát $y(t)$ đầu tiên được chuẩn hóa thành các dữ liệu trong

khoảng $[0, 1]$ bằng cách sử dụng chuẩn hóa tối thiểu-tối đa.

$$y_{\text{chuẩn hóa}} = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (9)$$

Chuyển đổi thành bài toán học tập có giám sát: Bài toán được chuyển đổi sang bài toán được giám sát với đầu ra là $Y_t = y(t + p)$ và đầu vào $X_t = \{x_t^1 =$

$y(t)$, $x_t^2 = y(t+1), \dots, x_t^p = y(t+p-1)$, $p \geq 1$, $t \geq 0$. Các bước thời gian p là thông số được tối ưu hóa.



Hình 2. Nguyên lý của mô hình LSTM kết hợp với kỹ thuật loại bỏ ngẫu nhiên MC để dự báo các mẫu biểu đồ kiểm soát.

3.2. Mạng lưới LSTM

Bài báo này sử dụng nhiều lớp LSTM (hình 2). Một lớp LSTM được kết hợp theo sau bởi một lớp loại bỏ ngẫu nhiên MC (xem phần tiếp theo). Một lớp LSTM là một chuỗi các ô LSTM. Số lượng các ô LSTM phụ thuộc vào kích thước đầu vào và bằng số bước thời gian p . Kích thước đầu ra của các lớp LSTM bằng số lượng đơn vị được biểu thị bởi n . Cuối cùng, để có được duy nhất một đầu ra một chiều, một lớp dày chỉ chứa một nơ ron được thêm vào cuối mô hình. LSTM sử dụng cơ chế các cửa kiểm soát quá trình ghi nhớ. Thông tin trong LSTM có thể được lưu trữ, viết hoặc đọc thông qua các cổng mở hoặc đóng. Có ba cổng khác nhau trong

một ô LSTM: Cổng quên, cổng đầu vào, và cổng đầu ra [23], [24]:

- Cổng quên: Thông tin từ đầu vào hiện tại x_t và trạng thái ẩn trước đó $h(t-1)$ được thông qua hàm σ để quyết định thông tin nào cần được chú ý và thông tin nào có thể được loại bỏ.

$$f_t = \sigma(W_f \odot h_{t-1} + U_f \odot x_t + b_f) \quad (10)$$

Trong đó, \odot biểu thị phép nhân Hadamard; W_f , U_f và b_f là trọng số và độ dốc của cổng quên; f_t , đầu ra của cổng quên, là một số giữa khoảng 0 và 1. $f_t = 1$ biểu thị “thông tin được lưu giữ hoàn toàn”; hoặc $f_t = 0$ biểu thị “thông tin bị loại bỏ hoàn toàn”.

- Cổng đầu vào và cập nhật bộ nhớ: Giống cổng quên, thông tin từ đầu vào hiện tại x_t và trạng thái ẩn trước đó được thông qua hàm xích ma để có được đầu ra của cổng đầu vào i_t .

$$i_t = \sigma(W_i \odot h_{t-1} + U_i \odot x_t + b_i) \quad (11)$$

Trong đó W_i , U_i và b_i là trọng số và độ dốc của cổng đầu vào. Giá trị của cổng đầu vào sau đó được sử dụng cho việc cập nhật bộ nhớ (C_t) như sau:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (12)$$

Trong đó:

$$\tilde{C}_t = \tanh(W_c \odot h_{t-1} + U_c \odot x_t + b_c) \quad (13)$$

Trong đó \tanh là hàm tiếp tuyến hyperbolic; W_c , U_c và b_c là trọng số và độ dốc của quá trình cập nhật bộ nhớ.

- Cổng đầu ra: Quyết định đầu ra của ô LSTM dựa trên đầu vào hiện tại x_t và trạng thái ẩn trước đó.

$$o_t = \sigma(W_o \odot h_{t-1} + U_o \odot x_t + b_o) \quad (14)$$

Và,

$$h_t = o_t \odot \tanh(C_t) \quad (15)$$

3.3. Kỹ thuật loại bỏ ngẫu nhiên MC cho mạng lưới LSTM

Loại bỏ ngẫu nhiên MC cho LSTM được thực hiện bằng cách loại bỏ ngẫu nhiên một vài nơ ron tại mỗi bước thời gian, các đầu vào, các đầu ra và các kết nối với xác suất p . Kỹ thuật loại bỏ này khác với kỹ thuật loại bỏ truyền thống trong đó các đơn vị mạng

lưới khác nhau được bỏ rơi tại các bước thời gian khác nhau và không áp dụng thao tác loại bỏ với các kết nối LSTM. Kỹ thuật loại bỏ ngẫu nhiên MC có thể được coi như suy luận biến thiên gần đúng trong mạng lưới nơ ron Bayesian (chi tiết tại tài liệu [21]).

3.4. Dự báo và đánh giá tính bất ổn

Phương pháp được đề xuất trong tài liệu [16] được sử dụng để ước tính các bất ổn trong dự báo. Toàn bộ số liệu đầu tiên được chia thành hai bộ: Bộ đào tạo và bộ thử nghiệm. Phương pháp được đề xuất bao gồm hai giai đoạn sau:

- Giai đoạn 1: Tính toán tập nhiều vốn có và đào tạo mô hình. Mô hình LSTM với loại bỏ ngẫu nhiên MC được đào tạo bằng cách sử dụng bộ dữ liệu đào tạo bao gồm n_1 dữ liệu $y_i (i = 1, \dots, n_1)$. Mô hình LSTM được đào tạo để tạo ra đầu ra \hat{y}_i gần nhất với dữ liệu thực y_i . Phương trình sau tính toán tập nhiều vốn có :

$$Var(y_i, \hat{y}_i) = \frac{1}{n_1} \sum_{i=1}^{n_1} (y_i - \hat{y}_i)^2 \quad (16)$$

- Giai đoạn 2: Dự báo và tính toán các bất ổn của mô hình. Mô hình đào tạo được áp dụng để dự đoán n_2 điểm tiếp theo trong tương lai. Việc dự đoán trên được lặp lại K lần liên tiếp. Mô hình cho ra các kết quả khác nhau tại các lần dự đoán khác nhau do có sự kết hợp với kỹ thuật loại bỏ ngẫu nhiên MC. Lấy \hat{y}_j^k là kết quả dự báo của mô hình tại lần dự báo thứ $k (k = 1, 2, \dots, K)$ tại thời điểm thứ j trong tương lai ($j = 1, 2, \dots, n_2$). Cuối cùng, có thể tính toán giá trị trung bình dự báo:

$$\bar{y}_j = \frac{1}{K} \sum_{k=1}^K \hat{y}_j^k \quad (17)$$

Các bất ổn của mô hình được dự báo từ số liệu j^{th} :

$$Var(y_i, \bar{y}_j) = \frac{1}{K} \sum_{k=1}^K (\hat{y}_j^k - y_j)^2 \quad (18)$$

Độ lệch tiêu chuẩn của dự báo số liệu j^{th} :

$$\sigma(y_j) = \sqrt{Var(y_i, \hat{y}_i) + Var(y_j, \bar{y}_j)} \quad (19)$$

Khoảng dự báo gần đúng cấp độ α được xây dựng bởi $\left[\bar{y}_j - z_{\frac{\alpha}{2}} \sigma(y_j), \bar{y}_j + z_{\frac{\alpha}{2}} \sigma(y_j) \right]$, trong đó

$z_{\frac{\alpha}{2}}$ là điểm vi phân $\frac{\alpha}{2}$ cận trên của chuẩn bình thường.

4. Phân tích số

4.1. Mô phỏng và tiền xử lý số liệu CPP

Do gặp nhiều khó khăn trong việc thu thập dữ liệu về chất lượng của các công trình, thêm vào đó việc khó đánh giá hiệu năng của mô hình trong thực tế, do đó để kiểm tra tính đúng đắn của mô hình đề xuất ở trên, các số liệu của các CPP khác nhau được tạo ra bằng phương pháp mô phỏng Monte Carlo và các phương trình (3), (6), (7), (8) với các thông số như sau: $\mu = 10$, $\sigma_x = 0.5$, $\omega = \pi/50$. Với mỗi CPP, có $n = 1000$ số liệu được tạo ra. Số liệu được chuẩn hóa bằng cách sử dụng chuẩn hóa tối thiểu-tối đa và biến đổi thành các bài toán học tập có giám sát với các bước thời gian $p = 5$. Số liệu được chia thành hai phần: bộ dữ liệu đào tạo chứa $n_1 = 700$ số liệu và bộ dữ liệu thử nghiệm chứa $n_2 = 300$ số liệu.

4.2. Các thông số đào tạo mô hình

Cụm LSTM chứa hai lớp LSTM như được trình bày trong hình 2. Mỗi lớp LSTM có năm ngăn LSTM ($p = 5$) và mỗi ngăn có 16 đơn vị. Xác suất p của kỹ thuật loại bỏ ngẫu nhiên MC được lấy bằng 5%.

Để chạy mô hình, bộ dữ liệu dùng để đào tạo mô hình chứa 700 số liệu và bộ dữ liệu kiểm tra mô hình chứa 300 số liệu cho mỗi loại CPP đã được sử dụng. Kỹ thuật tối ưu hóa Adam [25] được áp dụng với 200 vòng lặp. Lỗi trung bình bình phương gốc (RMSE: Root-Mean-Square Error) dùng cho việc đánh giá tính chính xác của dự báo thu được từ mô hình.

$$RMSE = \sqrt{\frac{1}{n_1} \sum_{i=1}^{n_1} (y_i + \hat{y}_i)^2} \quad (20)$$

4.3. Các thông số thử nghiệm mô hình


Việc dự báo được thực hiện $K = 100$ lần. Tuy nhiên, RMSE đo hiệu suất dự báo, tính toán RMSE cần được thích ứng với bộ dữ liệu thử nghiệm:

$$RMSE = \sqrt{\frac{1}{n_1} \sum_{i=1}^{n_2} (y_i - \bar{y}_i)^2} \quad (21)$$

Khoảng tin cậy được tính toán và vẽ biểu đồ với cấp độ $\alpha = 0.95$.

4.4. Dự báo mẫu thường

Hiệu suất của mô hình tốt ở cả giai đoạn đào tạo và giai đoạn thử nghiệm. Các giá trị của RMSE lần lượt là 0.43 và 0.45 cho giai đoạn đào tạo và giai đoạn thử nghiệm.



Hình 3. Dự báo mẫu thường.

Error! Reference source not found. biểu diễn các kết quả dự báo của mẫu thường. Để nhận thấy rõ ràng các kết quả, nhóm vẽ biểu đồ của 70 số liệu đầu tiên thay vì tất cả 300 số liệu trong bộ thử

thử nghiệm. Có thể thấy giá trị trung bình dự đoán bằng giá trị trung bình thực tế $\mu_k = 10$. Hơn nữa, hầu hết số liệu thực nằm trong khoảng tin cậy 95%.

4.5. Dự báo các mẫu khác


Bảng 1. RMSE của các mẫu khác.

RMSE	Giai đoạn đào tạo	Giai đoạn thử nghiệm
Mẫu có xu hướng tăng	0,56	0,58
Mẫu có xu hướng giảm	0,55	0,56
Mẫu chuyển dịch lên	3,5	5
Mẫu chuyển dịch xuống	2,7	3,8
Mẫu chu kỳ	0,54	0,55

Kết quả dự báo của các mẫu khác được tổng hợp trong bảng 1. Tương tự với các mẫu chu kỳ và mẫu bình thường, nhóm thu được kết quả dự đoán tốt với các mẫu có xu hướng tăng và mẫu có xu hướng giảm. Đa phần các số liệu thực luôn nằm trong khoảng CI. Tuy nhiên, mô hình không thể dự đoán

chính xác các mẫu chuyển dịch lên và mẫu chuyển dịch xuống do điểm chuyển dịch. Để dự báo hai mẫu này, nhóm cần có đủ số lượng các điểm chuyển dịch cho giai đoạn đào tạo mô hình hoặc phải tích hợp thêm phương pháp phát hiện điểm bất thường vào mô hình để phát hiện các điểm chuyển dịch.

4.6. Khảo sát khả năng dự báo với các mức nhiễu khác nhau



Hình 4. Khả năng dự báo với các mức độ nhiễu khác nhau.

Để khảo sát khả năng dự báo CCP trong các môi trường nhiễu khác nhau, trong mục này, nhóm tác giả áp dụng mô hình dự báo dựa trên học sâu với LSTM và kỹ thuật loại bỏ ngẫu nhiên MC cho loại mẫu thường với các tham số được thiết lập giống như ở các mục 4.1, 4.2, 4.3, 4.4, tuy nhiên tham số đại diện cho cường độ nhiễu σ_x được thay đổi từ thấp đến cao theo các mức từ 1% cho đến 30%. Kết quả thu được biểu thị trên hình 4. Dựa trên kết quả, mô hình có khả năng dự báo khá tốt khi cường độ nhiễu dưới 10%. Ngược lại, khi cường độ nhiễu quá lớn (vượt quá 10%), mô hình không có khả năng nhận diện nhiễu và tín hiệu thực, nên kết quả dự báo không tốt. Điều này hoàn toàn hợp lý, vì khi độ nhiễu quá cao, không có mô hình nào có thể hoạt động tốt, hơn thế, trong thực tế vận hành thì công việc có độ nhiễu trên 10% là không phổ biến.

5. Kết luận

Bài báo đề xuất một mô hình dự báo học sâu có tính xác suất dựa trên mạng LSTM kết hợp với kỹ thuật loại bỏ ngẫu nhiên MC cho việc dự báo mẫu biểu đồ kiểm soát chất lượng công trình. Các ví dụ số cho thấy mô hình có thể dự đoán được các mẫu biểu đồ kiểm soát khác nhau và nắm bắt một cách chính xác các bất ổn của dự báo. Tuy nhiên, trong thực tế, số liệu biểu đồ kiểm soát thường là tổ hợp của các mẫu cơ bản khác nhau. Do đó, trong tương lai, nhóm tác

giả sẽ tập trung vào việc dự báo tổ hợp CCP. Để cải thiện hiệu năng dự báo, có thể tiếp tục sử dụng và phát triển mạng nơ ron nhân tạo Bayesian (BNN) và các phương pháp phát hiện điểm bất thường (anomaly detection).

Lời cảm ơn

Nghiên cứu này được tài trợ bởi Bộ Giáo dục và Đào tạo thông qua đề tài mã số “B2021-GHA-03”: Nghiên cứu xây dựng mô hình dự báo mức độ an toàn và tuổi thọ của công trình hạ tầng ven biển và hải đảo bằng công nghệ trí tuệ nhân tạo (AI) và dữ liệu giám sát (condition monitoring information).

Tài liệu tham khảo

- [1] W. F. Kear; “Statistical process control in manufacturing practice”. Boca Raton, Florida, USA: CRC Press. 2020.
- [2] D. C. Montgomery. “Introduction to statistical quality control”. NY, USA: John Wiley & Sons. 2020.
- [3] T. Zan, Z. Liu, H. Wang, M. Wang, X. Gao; “Control chart pattern recognition using the convolutional neural network”. Journal of Intelligent Manufacturing. 2020; 31(3):703-716. DOI:10.1007/s10845-019-01473-0.
- [4] W. Hachicha, A. Ghorbel; “A survey of control-chart pattern-recognition literature (1991–2010)

- based on a new conceptual classification scheme”. *Computers Industrial Engineering*. 2012; 63(1):204-222. DOI:10.1016/j.cie.2012.03.002.
- [5] A. Addeh, A. Khormali, N. A. Golilarz; “Control chart pattern recognition using RBF neural network with new training algorithm and practical features”. *ISA transactions*. 2018; 79:202-216. DOI:10.1016/j.isatra.2018.04.020.
- [6] J. Yu, X. Zheng, S. Wang; “A deep autoencoder feature learning method for process pattern recognition”. *Journal of Process Control*. 2019; 79:1-15. DOI:10.1016/j.jprocont.2019.05.002.
- [7] M. Zaman, A. Hassan; “Fuzzy heuristics and decision tree for classification of statistical feature-based control chart patterns”. *Symmetry*. 2021; 13(1):110. DOI:10.3390/sym13010110.
- [8] P. H. Lee, C. C. Torng, C. H. Lin, C. Y. Chou; “Control chart pattern recognition using spectral clustering technique and support vectormachine under gamma distribution”. *Computers & Industrial Engineering*. 2022; 171:108437. DOI:10.1016/j.cie.2022.108437.
- [9] S. Ayvaz, K. Alpay; “Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in realtime”. *Expert Systems with Applications*. 2021;173: 114598. DOI:10.1016/j.eswa.2021.114598.
- [10] O. Serradilla, E. Zugasti, J. Rodriguez, U. Zurutuza; “Deep learning models for predictive maintenance: A survey, comparison, challenges and prospects”. *Applied Intelligence*. 2022; 52: 10934–10964. DOI:10.1007/s10489-021-03004-y.
- [11] D. Powell, M. C. Magnanini, M. Colledani, O. Myklebust; “Advancing zero defect manufacturing: A state-of-the-art perspective and future research directions”. *Computers in Industry*. 2022;136: 103596. DOI:10.1016/j.compind.2021.103596.
- [12] S. Hochreiter, J. Schmidhuber; “Long short-term memory”. *Neural computation*. 1997; 9(8): 1735-1780. DOI:10.1162/neco.1997.9.8.1735.
- [13] A. C. Tsoi; “Recurrent neural network architectures: an overview”; in *Adaptive Processing of Sequences and Data Structures*. Berlin, Heidelberg, Germany: Springer; 1997; pp.1-26.
- [14] R. J. Frank, N. Davey, S. P. Hunt; “Time series prediction and neural networks”. *Journal of intelligent and robotic systems*. 2001; 31:91-103. DOI:10.1023/A:1012074215150.
- [15] Z. Han, J. Zhao, H. Leung, K. F. Ma, W. Wang; “A review of deep learning models for time series prediction”. *IEEE Sensors Journal*. 2019; 21(6):7833-7848. DOI: 10.1109/JSEN.2019.2923982.
- [16] L. Zhu, N. Laptev; “Deep and confident prediction for time series at uber”; in *Proc. 2017 IEEE International Conference on Data Mining Workshops (ICDMW)*; 18-21 November 2017; New Orleans, LA, USA. IEEE; 2017; pp. 103-110.
- [17] B. Mohebbali, A. Tahmassebi, A. Meyer-Baese, A. H. Gandomi; “Probabilistic neural networks: a brief overview of theory, implementation, and application”; in *Handbook of Probabilistic Models*. Amsterdam, Netherlands:Elsevier; 2020; pp. 347-367.
- [18] E. Goan, C. Fookes; “Bayesian Neural Networks: An Introduction and Survey”; in *Case Studies in Applied Bayesian Data Science*. Cham, Germany: Springer; 2020; pp. 45–87.
- [19] L. V. Jospin, H. Laga, F. Boussaid, W. Buntine, M. Bennamoun; “Handson Bayesian neural networks—A tutorial for deep learning users”. *IEEE Computational Intelligence Magazine*. 2022; 17(2):29-48. DOI: 10.1109/MCI.2022.3155327.
- [20] Y. Gal; “Uncertainty in deep learning,” Ph.D. dissertation”. PhD thesis, University of Cambridge. 2016
- [21] Y. Gal, Z. Ghahramani; “Dropout as a bayesian approximation: Representing model uncertainty in deep learning”; in *Proc. the 33rd International Conference on Machine Learning*; 19 - 24 June 2016; NY, USA. Cambridge, Massachusetts, USA: *Journal of Machine Learning Research (JMLR)*, MIT Press; 2016; pp. 1050–1059.

- [22] M. A. Durivage, B. Mehta; “Practical Process Validation”. UK:Quality Press. 2016. 323:203-213. DOI: 10.1016/j.neucom.2018.09.082.
- [23] L. Yu, J. Qu , F. Gao, Y. Tian; “A novel hierarchical algorithm for bearing fault diagnosis based on stacked LSTM”. Shock and Vibration. 2019; 12:1-10. DOI: 10.1155/2019/2756284.
- [24] A. Sagheer, M.Kotb; “Time series forecasting of petroleum production using deep LSTM recurrent networks”. Neurocomputing. 2019;
- [25] I. K. M. Jais, A. R. Ismail, S. Q. Nisa; “Adam optimization algorithm for wide and deep neural network”. Knowledge Engineering and Data Science. 2019; 2(1):41-46. DOI: 10.17977/um018v2i12019p41-46.