

THIẾT KẾ MẠNG HỌC SÂU LONG SHORT-TERM MEMORY (LSTM) ĐỂ DỰ BÁO LƯU LƯỢNG VÀ PHÁT HIỆN BẤT THƯỜNG TRONG MẠNG CẤP NƯỚC SẠCH

Hoàng Văn Thông^{1*}, Nhữ Văn Kiên²

¹Trường Đại học Giao thông vận tải,

²Trường Cao đẳng Thủy lợi Bắc Bộ

TÓM TẮT

Trong bài báo này, chúng tôi thiết kế một mạng học sâu LSTM để dự báo dữ liệu chuỗi thời gian là giá trị lưu lượng của các mạng lưới cấp nước sạch. Dựa trên kết quả dự báo, chúng tôi xây dựng một mô hình cho phép phát hiện sự bất thường của mạng. Mô hình được thử nghiệm trên 3 điểm đo lưu lượng của mạng cấp nước sạch tại thành phố Huế với sai số dự báo thấp và chỉ số NSE cao đạt 0.98. Kết quả dự báo của mô hình được sử dụng để xây dựng mô hình phát hiện bất thường trong mạng dựa trên sai số dự báo và dữ liệu thực. Kết quả thử nghiệm cho thấy phương pháp đề xuất cho kết quả phát hiện chính xác cao, có thể ứng dụng được vào thực tế.

Từ khóa: dự báo; chuỗi thời gian; bất thường; mạng cấp nước; học sâu; LSTM

Ngày nhận bài: 27/11/2020; Ngày hoàn thiện: 30/11/2020; Ngày duyệt đăng: 30/11/2020

DESIGN A DEEP LEARNING LONG SHORT-TERM MEMORY (LSTM) FOR FLOW PREDICTION AND ANOMAL DETECTION IN WATER SUPPLY NETWORK

Hoang Van Thong^{1*}, Nhu Van Kien²

¹University of Transportation and Communications,

²Bac Bo Water Resources College

ABSTRACT

In this paper, we designed an LSTM deep learning network to predict time series data which is the water flow of clean water supply networks. Based on the prediction results, a model was built to detect anomalies. The model was tested on 3 points measuring water flow of water supply network in Hue city with low predictive error and high NSE index of 0.98. Predictive results of the model were used to build anomaly detection model in the network based on predictive errors and real data. Experimental results show that the proposed method gives detection results with high precision, which can be applied in practice.

Keywords: prediction; time series; anomal; water supply network; deep learning; LSTM

Received: 27/11/2020; Revised: 30/11/2020; Published: 30/11/2020

* Corresponding author. Email: thonghv@utc.edu.vn

1. Mở đầu

Theo báo cáo của Hiệp hội cấp nước Việt Nam hàng năm thì tỷ lệ thất thoát nước tính trung bình của các công ty cấp nước trên toàn quốc từ 20% đến 30%. Lượng nước thất thoát lớn sẽ gây lãng phí, thiệt hại về kinh tế của xã hội, làm thất thu cho ngân sách của các công ty cấp nước. Do vậy, vấn đề giảm lượng nước thất thoát, thất thu là một bài toán nan giải của hầu hết các công ty cấp nước không những ở Việt Nam mà còn trên toàn thế giới khi mà hệ thống đường ống được đầu tư lâu năm, chôn sâu trong lòng đất và ngày càng xuống cấp. Một phương pháp đơn giản để phát hiện thất thoát là kiểm toán dựa trên độ chênh lệch giữa số đo đồng hồ tổng và tổng số đo của các đồng hồ của các hộ sử dụng. Việc kiểm toán nước có hạn chế là không được thực hiện theo thời gian thực, nó được thực hiện mỗi tháng một lần, do đó việc phản ứng với sự bất thường của mạng rất chậm. Hiện nay, mạng lưới cấp nước của một số công ty cấp nước sạch ở nước ta đã được gắn các thiết bị giám sát lưu lượng và áp lực tại các điểm đầu vào của các khu vực, các thiết bị này cung cấp cho chúng ta dữ liệu dạng chuỗi thời gian về lưu lượng và áp lực tại điểm lắp đặt theo thời gian thực. Về nguyên tắc, các dữ liệu này hoàn toàn có thể cho chúng ta biết được mạng có sự cố hay không theo thời gian thực, do tính chất sử dụng nước của các khu vực thường theo quy luật thời gian như giờ, thứ trong tuần, ngày lễ, mùa. Tuy nhiên, nguồn dữ liệu này chưa sử dụng để đưa ra các cảnh báo sớm về sự bất thường trong mạng như vỡ đường ống, rò rỉ theo thời gian thực. Trong bài báo này, chúng tôi đề xuất giải pháp phát hiện sự bất thường (anomal) của mạng cấp nước dựa trên dữ liệu lưu lượng thực tế tại các điểm đo và dữ liệu dự báo. Trên cơ sở đó, hệ thống đưa ra cảnh báo giúp người quản lý sớm khắc phục sự cố nhằm giảm thiểu lượng nước bị thất thoát, lãng phí.

Bài toán phân tích và dự báo của chuỗi thời gian đã được nghiên cứu sâu trong hơn 40 năm qua [0]. Cho chuỗi dữ liệu theo thời gian

$\{t_1, t_2, \dots, t_n, \dots\}$, chúng ta cần ước lượng giá trị tại thời điểm i dựa trên các dữ liệu trước đó $x_i = \{t_{i-k}, t_{i-k-1}, \dots, t_{i-1}\}$, ở đây k được gọi là cửa sổ dữ liệu lịch sử. Mục đích của dự báo là tìm ra một hàm $f(x)$ sao cho $\hat{t}_i = f(x_i)$ gần giá trị đúng t_i nhất. Chúng ta cũng có thể dự báo nhiều giá trị trong tương lai $\hat{t}_{i+1}, \dots, \hat{t}_{i+m} = f(x_i)$.

Hiện tại có nhiều hướng tiếp cận giải bài toán này. Các phương pháp dựa trên thống kê như: trung bình trượt tích hợp hồi quy (ARIMA - Autoregressive Integrated Moving Average) [0], một trong những giới hạn của phương pháp này là nó có xu hướng tập trung vào giá trị trung bình của dữ liệu quá khứ; phương pháp véc tơ hỗ trợ hồi quy (SVR- Support Vector Regression) có nhiều thành công trong dự báo chuỗi thời gian, tuy nhiên nó lại thiếu một công cụ có cấu trúc để xác định các tham số chính của mô hình [0]. Gần đây, các mô hình học sâu được áp dụng nhiều cho bài toán dự báo chuỗi thời gian. Các mô hình dựa trên cấu trúc mạng LSTM được áp dụng trong [0], [6]. Kết quả cho thấy mô hình học sâu với mạng LSTM cho kết quả tốt hơn các phương pháp tiếp theo thống kê.


Để giải quyết vấn đề phát hiện bất thường trong mạng cấp nước, chúng tôi thiết kế một mạng học sâu với các nơ ron LSTM để dự báo lưu lượng nước tại mỗi điểm đo. Đề xuất phương pháp xác định bất thường dựa trên độ sai lệch giữa dữ liệu đo được thực tế và dữ liệu dự báo để gán nhãn cho điểm dữ liệu là bất thường hay bình thường (normal). Phương pháp đề xuất được thử nghiệm tại 3 điểm đo lưu lượng với giá trị lưu lượng khác nhau. Kết quả cho thấy phương pháp đề xuất cho kết quả phát hiện bất thường khá tốt, có thể áp dụng vào thực tế.

Phần còn lại của bài báo được tổ chức như sau: cấu trúc của mạng LSTM và thiết kế mạng LSTM dự báo lưu lượng nước được trình bày trong mục 2. Mục 3 thử nghiệm mô hình mạng LSTM dự báo lưu lượng nước. Mục 4 trình bày phương pháp phát hiện bất thường và đánh giá phương pháp trên dữ liệu thực tế. Mục 5 rút ra một số kết luận.

2. Mạng học sâu LSTM

2.1 Cấu trúc của mạng LSTM

LSTM là một loại RNN (Recurrent Neural Network) đặc biệt, có khả năng học các phụ thuộc gần, xa. Mạng LSTM được Hochreiter và Schmidhuber đề xuất năm 1997 trong [4]. Nó được áp dụng rất hiệu quả trong nhiều bài toán và hiện đang được sử dụng rộng rãi. LSTM được thiết kế để tránh vấn đề phụ thuộc lâu dài. Ghi nhớ thông tin trong thời gian dài là hành vi mặc định của mạng. Các mạng nơ ron hồi quy đều có dạng một chuỗi lặp lại các mô-đun của mạng nơ ron. Trong RNN, các mô-đun này có cấu trúc rất đơn giản, chỉ là một lớp *tanh*. LSTMs cũng có cấu trúc dạng chuỗi, nhưng các mô-đun có cấu trúc khác. Thay vì có lớp mạng nơ ron đơn, LSTM có 4 lớp, chúng tương tác với nhau. Hình 1 dưới đây mô tả cấu trúc mạng LSTM.



Hình 1. Mô tả cấu trúc mạng LSTM và cấu trúc của một mô-đun của nó [4]

Ý tưởng cốt lõi của LSTM là trạng thái của các tế bào được mô tả bằng đường thẳng nằm ngang ở trên cùng. Trạng thái tế bào giống như một băng chuyền. Nó chạy thẳng xuyên qua toàn bộ chuỗi, chỉ với một số tương tác tuyến tính nhỏ, nó rất dễ dàng để thông tin trôi theo dòng không thay đổi.

LSTM có khả năng loại bỏ hoặc thêm thông tin vào trạng thái tế bào, được điều chỉnh cẩn thận bởi các cấu trúc được gọi là cổng. Cổng là một cách tùy chọn để thông tin đi qua. Chúng được cấu tạo từ một lớp mạng nơ ron *sigmoid* và một phép toán nhân. Đầu ra của lớp *sigmoid* là các giá trị trong đoạn $[0, 1]$, mô tả mức độ thông qua của từng thành phần. Giá trị bằng 0 có nghĩa là "không có gì thông qua", trong khi giá trị bằng 1 có nghĩa là "để mọi thứ thông qua". Một LSTM có ba cổng *sigmoid* để bảo vệ và kiểm soát trạng thái tế bào.

2.2. Hoạt động của mạng LSTM

Bước đầu tiên trong LSTM là quyết định thông tin nào sẽ bị loại bỏ khỏi trạng thái tế bào, được thực hiện bởi một lớp *sigmoid* được gọi là "lớp cổng quên". Đầu vào của nó là h_{t-1} và x_t , và cho ra một giá trị thuộc đoạn $[0, 1]$ cho mỗi trạng thái C_{t-1} . Nếu giá trị là 1 thì các thông tin được giữ lại hoàn toàn, nếu giá trị là 0 có nghĩa là các thông tin bị loại bỏ hoàn toàn.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Bước tiếp theo là quyết định thông tin mới sẽ được lưu trữ trong trạng thái tế bào. Để thực hiện việc này, chúng phải thực hiện bằng 2 lớp, một lớp *sigmoid* được gọi là "lớp cổng đầu vào" quyết định những giá trị nào sẽ được cập nhật. Sau đó, một lớp *tanh* tạo ra một véc tơ mới, \tilde{C}_t , có thể được thêm vào trạng thái. Tiếp theo, chúng ta kết hợp hai thành phần này để tạo bản cập nhật cho trạng thái.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

Bây giờ, chúng ta cập nhật trạng thái tế bào cũ, C_{t-1} vào trạng thái tế bào mới C_t như sau:


$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

Cuối cùng, tính giá trị đầu ra dựa trên trạng thái tế bào nhưng nó là một phiên bản đã được lọc. Trước tiên, chúng ta thực hiện lớp *sigmoid* để quyết định phần trạng thái tế bào sẽ xuất ra, sau đó đẩy trạng thái tế bào qua *tanh* và nhân nó với đầu ra của cổng *sigmoid*.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh(C_t) \quad (7)$$

2.3. Thiết kế mạng LSTM dự báo lưu lượng nước



Hình 2. Kiến trúc mạng LSTM dự báo lưu lượng nước

Mạng được thiết kế với 2 lớp chính, một lớp LSTM với 64 nơ ron, lớp thứ 2 là lớp (fully connected) Dense với 32 nơ ron như mô tả trong Bảng 1. Sau mỗi lớp là một lớp Dropout

với xác suất là 0,1. Dữ liệu đầu vào được cấu hình thử nghiệm là các véc tơ 12, 24 và 48 chiều, tức là sử dụng cửa sổ có kích thước 12, 24 hoặc 48 điểm dữ liệu lịch sử để dự báo. Trong thử nghiệm, số epoch được đặt là 20,000.

Bảng 1. Mô tả chi tiết cấu trúc mạng

| Layer (type) | Output Shape | Param # |
|---------------------|--------------|---------|
| Lstm (LSTM) | (None, 64) | 16896 |
| Dropout (Dropout) | (None, 64) | 0 |
| Dense (Dense) | (None, 32) | 200 |
| Dropout_1 (Dropout) | (None, 32) | 0 |
| Dense_1 (Dense) | (None, 1) | 33 |

Hàm mất mát sử dụng trong mạng là trung bình phương sai số (Mean Squared Error), phương pháp tối ưu Adam.

3. Thu thập dữ liệu và thử nghiệm

3.1. Thu thập dữ liệu

Bảng 2. Các điểm lấy dữ liệu thử nghiệm

| Mã điểm đo | Điểm đo | Đường kính ống |
|------------|---------------------|----------------|
| F15385 | Bến xe Nguyễn Hoàng | D400 |
| F15405 | Cư Chánh Thủy Bằng | D150 |
| F15351 | Kiệt Công Trắng | D80 |

Chúng tôi tiến hành thu thập dữ liệu lưu lượng tại một số điểm đo của mạng cấp nước của thành phố Huế, các điểm đo mô tả trong Bảng 2.

Giá trị lưu lượng nước tại các điểm đo phụ thuộc vào đường kính của ống dẫn và nhu cầu sử dụng tại khu dân cư. Ở đây, để chứng minh tính hiệu quả của mạng, chúng tôi chọn các đường ống có kích thước khác nhau và tại các khu khác để thử nghiệm và đánh giá. Dữ liệu thu thập từ 0 giờ ngày 01 tháng 01 năm 2018 đến 9 giờ ngày 18 tháng 5 năm 2019, với bước thời gian 15 phút.

3.2. Thử nghiệm xây dựng mô hình

Tập dữ liệu được chia thành 2 tập học và kiểm tra với tỉ lệ 9:1, chín phần dữ liệu đầu để học và một phần dữ liệu cuối để kiểm tra.

Để đánh giá hiệu quả của mô hình dự báo, chúng tôi sử dụng 2 thông số, đó là *RMSE* (Root Mean Squared Error) và *NSE* (Nash

Sutcliffe Efficiency) được xác định theo công thức (8) và (9) dưới đây:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - \hat{t}_i)^2} \quad (8)$$

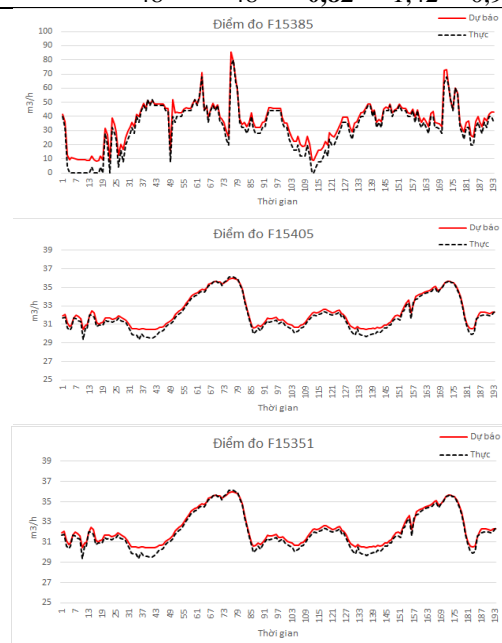
$$NSE = 1 - \frac{\sum_{i=1}^N (t_i - \hat{t}_i)^2}{\sum_{i=1}^N (t_i - \bar{t})^2} \quad (9)$$

Trong đó, t_i , \hat{t}_i , \bar{t} lần lượt là dữ liệu quan sát thực tế, giá trị dự báo và giá trị quan sát thực tế trung bình. Mô hình có hiệu quả tốt nếu *RMSE* nhỏ và *NSE* lớn.

Kết quả thử nghiệm mô hình được tổng hợp trong Bảng 3.

Bảng 3. Kết quả thử nghiệm dự báo với kích thước dữ liệu đầu vào 12, 24, 48

| Mã điểm đo | Input size (WS) | RMSE | | NSE | |
|------------|-----------------|-------|-------------|-------------|--------------|
| | | Train | Test | Train | Test |
| F15385 | 12 | 12 | 4,68 | 2,77 | 0,996 |
| | 24 | 24 | 6,68 | 4,99 | 0,993 |
| | 48 | 48 | 6,85 | 4,75 | 0,992 |
| F15405 | 12 | 12 | 0,88 | 1,33 | 0,793 |
| | 24 | 24 | 0,47 | 1,14 | 0,940 |
| | 48 | 48 | 0,62 | 1,27 | 0,896 |
| F15351 | 12 | 12 | 1,10 | 1,73 | 0,952 |
| | 24 | 24 | 0,84 | 1,27 | 0,972 |
| | 48 | 48 | 0,82 | 1,42 | 0,972 |



Hình 3. Đồ thị giá trị quan sát và dự báo trên 96 điểm dữ liệu cuối của tập kiểm tra của các điểm đo *F15385*, *F15401* và *F15351* với cửa sổ $WS=24$

Từ Bảng 3, chúng ta nhận thấy với kích thước dữ liệu đầu vào $ws = 24$ cho kết quả ổn định và tốt hơn so với kích thước dữ liệu đầu vào $ws = 12$ hoặc 48 . Do đó, chúng tôi chọn kích thước dữ liệu đầu vào 24 để dự báo và xác định bất thường của mạng trong mục 4. Tính hiệu quả của phương pháp có thể thấy khi quan sát đồ thị của dữ liệu thực và dữ liệu dự báo trên tập kiểm tra. Trong Hình 3, chúng tôi vẽ 96 giá trị cuối cùng của tập kiểm tra với kết quả dự báo từ mô hình có $ws = 24$. Chúng ta thấy đồ thị đường dự báo và thực khá đồng dạng và có sai số nhỏ.

4. Phát hiện bất thường

4.1. Phương pháp

Với mỗi đầu vào $x_i = \{t_{i-k}, t_{i-k-1}, \dots, t_{i-1}\}$, $i = \{k, \dots, n\}$, áp dụng mô hình dự báo được xây dựng trong mục 3 để dự đoán giá trị đầu ra \hat{t}_i . Sau đó, tính sai số e_i giữa \hat{t}_i và t_i , các sai số dự báo trên tập huấn luyện được sử dụng như là phân bố Gauss. Các tham số của mô hình Gauss, giá trị trung bình μ (mean), phương sai σ (variance) được tính toán dựa trên ước lượng tối đa hàm khả năng (maximum likelihood estimation – MLE). Để xác định các điểm dữ liệu bất thường trên tập kiểm tra, chúng ta tính giá trị logarit của hàm mật độ xác suất (PDFs) của sai số dự báo với giá trị thực; thiết lập một giá trị tham số ngưỡng τ trên PDFs để phân chia dữ liệu bất thường hoặc không. Để đánh giá mô hình, chúng tôi sử dụng các độ đo Precision và Recall, nó được xác định dựa trên ma trận nhầm lẫn. Precision là tỉ lệ số dữ liệu phân loại được gắn nhãn là lớp đúng bình thường (positive) trên tổng số nhãn được mô hình phân loại là lớp bình thường, trong đó, Recall là tỉ lệ dữ liệu được phân loại là đúng trên số mẫu dữ liệu dự đoán là bình thường và số mẫu dữ liệu bất thường dự đoán sai. Với một mô hình phân loại lý tưởng, cả Precision và Recall đều có giá trị là 1. Tuy nhiên, trong thực tế, Precision và Recall tỷ lệ nghịch với nhau.

$$Precision = \frac{TruePositive}{TruePositive+FalsePositive} \quad (10)$$

$$Recall = \frac{TruePositive}{TruePositive+FalseNegative} \quad (11)$$

4.2. Thử nghiệm

Chúng tôi tiến hành thử nghiệm trên tập dữ liệu tại các điểm đo trong Bảng 1. Tập dữ liệu được chia thành 2 phần: phần thứ nhất chỉ bao gồm dữ liệu không bất thường dùng để xây dựng mô hình dự báo và xác định các tham số của mô hình Gauss, phần thứ 2 để kiểm tra bao gồm cả dữ liệu bất thường và không. Kết quả thử nghiệm được thống kê trong bảng 4.

Bảng 4. Giá trị Precision và Recall của các điểm thử nghiệm

| Mã điểm đo | Precision | Recall |
|------------|-----------|--------|
| F15385 | 0,936 | 0,787 |
| F15405 | 0,943 | 0,832 |
| F15351 | 0,927 | 0,853 |

Từ Bảng 4 cho thấy, mô hình phát hiện bất thường cho kết quả tốt, với độ chính xác cao, có thể áp dụng vào thực tế để trợ giúp người dùng phát hiện sự bất thường của các điểm đo dựa trên dữ liệu lưu lượng của các mạng cấp nước sạch.

5. Kết luận

Dự báo và phát hiện bất thường của dữ liệu chuỗi thời gian là bài toán quan trọng. Ngày nay các thiết bị IoT được ứng dụng trong tất cả các lĩnh vực, nhiều thiết bị thuộc loại data logger, những thiết bị này cung cấp cho người dùng các thông số dữ liệu theo thời gian thực. Dựa trên các dữ liệu này, người dùng giám sát hệ thống. Việc xây dựng các giải pháp cảnh báo tự động khi hệ thống hoạt động không bình thường là rất cần thiết. Trong bài báo này, chúng tôi đã xây dựng được mô hình cảnh báo bất thường trong mạng cấp nước sạch dựa trên dữ liệu lưu lượng. Mô hình dựa trên mạng nơ ron LSTM và phân bố Gauss. Mô hình được tiến hành thử nghiệm trên 3 điểm đo thực tế tại thành phố Huế. Kết quả thử nghiệm cho thấy mô hình cho độ chính xác cao và có thể áp dụng vào thực tế hỗ trợ giám sát mạng lưới cấp nước.

Lời cảm ơn

Nghiên cứu này được tài trợ bởi Trường Đại học Giao thông vận tải trong đề tài mã số T2020-CN-004.

TÀI LIỆU THAM KHẢO/ REFERENCES

- [1]. N. I. Sapankevych, and R. Sankar, "Time Series Prediction Using Support Vector Machines: A Survey," *IEEE Computational Intelligence Magazine*, vol. 4, no. 2, pp. 24-38, 2009.
- [2]. M. Kumar, and M. An, "An Application of Time Series Arima Forecasting Model For Predicting Sugarcane Production In India," *Studies in Business and Economics*, vol. 9, pp. 81-94, 2018.
- [3]. W. -C. Hong, "Application of Seasonal SVR with Chaotic Immune Algorithm in Traffic Flow Forecasting," *Neural Computing and Applications*, vol. 21, no. 3, pp. 583-593, 2012.
- [4]. S. Hochreiter, and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [5]. M. Munir, S. A. Siddiqui, A. Dengel, and S. Ahmed, "DeepAnT: A Deep Learning Approach for Unsupervised Anomaly Detection in Time Series," *IEEE Access*, vol. 7, pp. 1991-2005, 2018, doi: 10.1109/ACCESS.2018.2886457
- [6]. A. Alahi, K. Goel, V. Ramanathan, A. Robicquet, L. Fei-Fei, and S. Savarese, "Social LSTM: Human Trajectory Prediction in Crowded Spaces," in *Proc. 29th IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, June 2016, pp. 961-971.