DỰ BÁO NHU CẦU PHỤ TẢI ĐIỆN NĂNG DÙNG MẠNG NEURAL
ELECTRICITY DEMAND FORECASTING USING NEURAL NETWORK

Đoàn Văn Vững[1], Lê Mỹ Hà[1]
[1] Trường đại học Sư phạm Kỹ thuật TP.HCM

TÓM TẮT

Dự báo nhu cầu phụ tải điện năng đóng vai trò rất quan trọng trong việc quản lý năng lượng một cách hiệu quả, bền vững như quy hoạch, đầu tư phát triển thêm cơ sở hạ tầng và vận hành hệ thống điện. Tính chính xác của dự báo nhu cầu phụ tải điện năng trong tương lai càng phải được đặc biệt chú trọng. Trong nội dung bài báo này, tác giả nghiên cứu một phương pháp dự báo phụ tải mới dựa trên mạng Nơ-ron học sâu (Deep Learning Network), cụ thể là mạng Nơ-ron hồi quy (Recurent neural network - RNN) với mô hình cải tiến là Long Short-Term Memory (LSTM). Cấu trúc mạng được đề xuất gồm có 4 lớp là Sequence Input, LSTM, Fully Connected và Regression Output. Phương pháp đề xuất được thực nghiệm trên dữ liệu lượng điện năng tiêu thụ trong 06 năm từ 2012 đến 2017 của tỉnh Tiền Giang. Kết quả thực nghiệm cho thấy phương pháp dự báo đề xuất trong bài báo phù hợp với dữ liệu thực dùng kiểm tra với sai số trung bình hiệu dụng là 9.6333.

Từ khóa: *Mạng Nơ-ron nhân tạo; Mạng Nơ-ron học sâu; Mạng LSTM; Mạng RNN; Dự báo nhu cầu phụ tải điện năng.*

ABSTRACT

Electricity demand forecasting plays a very important role in energy effectively and sustainably management such as suitable planning, investing in developing more infrastructure and moderate operating the electricity system. Moreover, the accuracy of the load forecasting must be paid special attention. In this paper, we apply a load prediction model based on the Deep Learning Network, namely Long Short-Term Memory (LSTM), an improvement model of Recurrent Neural Network (RNN). The proposed network structure includes 4 layers: Sequence Input, LSTM, Fully Connected và Regression Output. The proposed method was carried out on the data of power consumption in 06 years, from 2017 to 2017, of Tien Giang province. The experiment results show that the proposed model is suitable with Root Mean Square Error (RMSE) is 9.6333.

K***eywords:*** *Neural Network; Deep Learning; Recurent neural network; Long Short-Term Memory networks; Forecasting of electrical load demand.*

1. GIỚI THIỆU

Trong ngành quản lý năng lượng, dự báo nhu cầu phụ tải điện năng có ý nghĩa vô cùng quan trọng vì nó gắn liền và ảnh hưởng trực tiếp đến đời sống sinh hoạt của nhân dân và các ngành kinh tế khác. Ngoài ra, dự báo nhu cầu phụ tải có ý nghĩa quyết định trong việc đảm bảo chế độ làm việc an toàn và tiết kiệm của hệ thống điện, đồng thời có tính chất quyết định trong việc hoạch định chiến lược phát triển hệ thống. Các phương pháp dự báo phụ tải trước đây thường không thể miêu tả đầy đủ và chính xác quá trình thực tế xảy ra vì số lượng cơ sở dữ liệu không đầy đủ và có nhiều sai số hoặc cần phải có nhiều thời gian cho tính toán. Trong thực tế, không có phương trình với những tham số có sẵn mà chỉ biết được giá trị gần đúng hoặc kỳ vọng toán học. Vì thế phải đưa ra một phương trình sẵn có với những tham số chưa được biết, dùng phương pháp gần đúng để tìm ra những tham số này và như vậy độ chính xác sẽ giảm đi rất nhiều. Phương pháp truyền thống được sử dụng có hiệu quả chỉ trong các trường hợp các dữ liệu quan hệ tuyến tính với nhau, nó không thể trình bày rõ ràng các mối quan hệ phi tuyến, phức tạp giữa phụ tải và các tham số liên quan. Để khắc phục nhược điểm của các

phương pháp dự báo phụ tải truyền thống, các nhà khoa học đã ứng dụng kỹ thuật dự báo hiện đại như: fuzzy logic, mạng Nơ-ron, phép phân tích wavelet… Các phương pháp dự báo hiện đại trên ngày càng được quan tâm vì kết quả dự báo khá chính xác. Nếu dự báo quá dư thừa so với nhu cầu sử dụng thì hậu quả là phải huy động nguồn quá lớn, làm tăng vốn đầu tư và có thể gây tổn thất năng lượng. Ngược lại, nếu dự báo phụ tải quá thấp so với nhu cầu sẽ không có đủ năng lượng cung cấp và tất nhiên sẽ dẫn đến việc phải cắt bỏ một số phụ tải mà không có kế hoạch trước gây thiệt hại cho nền kinh tế. Vì vậy, hiện nay việc dự báo nhu cầu phụ tải điện năng đã nhận được sự quan tâm ngày càng cao, tuy nhiên thực tế chứng minh đây cũng là một vấn đề rất khó khăn. Đã có nhiều phương pháp cho bài toán dự báo, từ các phương pháp toán học đến sử dụng các thuật toán heuristic và đặc biệt sử dụng các phương pháp liên quan đến trí tuệ nhân tạo. Việc nghiên cứu, ứng dụng các mô hình, thuật toán dự báo khác nhau cho phép tiếp cận tới việc lựa chọn phương pháp dự báo, đánh giá mức độ chính xác của dự báo. Trong thời gian gần đây, mạng Nơ-ron nhân tạo có nhiều ưu điểm hơn vì là một mô hình rõ ràng, hiệu quả, dễ thực hiện. Có thể nói, dự báo nhu cầu phụ tải là một trong những ứng dụng thành công nhất của mạng Nơ-ron nhân tạo trong hệ thống điện. Chính vì thế, dự báo phụ tải điện năng sử dụng kỹ thuật mạng Nơ-ron nhân tạo được nghiên cứu trong bài báo này.

2. CÁC NGHIÊN CỨU LIÊN QUAN

Dự báo phụ tải ngắn hạn đề cập đến dự báo nhu cầu điện năng trên cơ sở hằng giờ, từ 01 giờ đến một vài ngày sắp đến. Việc phát triển một phương pháp dự báo ngắn hạn mạnh, nhanh và chính xác là cần thiết cho việc quản lý hệ thống điện. Trong nhiều thuật toán và phương pháp đã được đề xuất để thực hiện dự báo phụ tải ngắn hạn thì mạng Nơ-ron nhân tạo (ANN) có nhiều ưu điểm hơn cả vì là một mô hình rõ ràng, dễ thực hiện, chính xác và hiệu quả. Có thể nói, dự báo phụ tải là một trong những ứng dụng thành công nhất của ANN trong hệ thống điện. Chính vì vậy việc nghiên cứu ứng dụng các phương pháp khác nhau của mạng Nơ-ron để dự báo phụ tải điện năng là vấn đề quan trọng cần được xem xét nghiên cứu.

Một số kết quả nghiên cứu về dự báo phụ tải đã được công bố trong nước và ngoài nước. Năm 2012, bài báo: "Short – term load forecasting Using Artificial Neural Network" của nhóm tác giả Muhammad Buhari, Member, IAENG, Sanusi Sani Adamu [1] đã được công bố với mô hình được thiết kế trên phần mềm Matlab R2008b, với công cụ Annealing Neural Network (ANN) toolbox. Việc xây dựng cấu trúc mạng, huấn luyện mạng Nơ-ron và mô phỏng kết quả kiểm tra đều thành công với một mức độ chính xác cao. Một tập hợp các trọng số tối ưu và sau khi huấn luyện mạng với dữ liệu thu được từ các công ty điện lực. Tính chính xác của dự báo đã được chứng minh bằng cách so sánh các kết quả mô phỏng từ mạng với kết quả thu được từ các công ty điện lực. Nhiều cấu trúc mạng đã được huấn luyện và mô phỏng trước khi đến sai số tốt nhất. Một bài báo khác "Deep Learning for Solar Power Forecasting – An Approach Using Autoencoder and LSTM (Long Short-Term Memory) Neural Networks" của các tác giả Andre Gensler, Janosch Henze, Bernhard Sick and Nils Raabe, năm 2016 [2], cũng trình bày về thuật toán Deep Learning cho thấy hiệu suất dự báo cao hơn so với mạng nơron nhân tạo cũng như các mô hình khác, cụ thể bằng cách sử dụng các thuật toán mạng học sâu và mạng nơ-ron nhân tạo khác nhau, chẳng hạn như Deep Belief Networks, AutoEncoder và LSTM, nhóm tác giả đã áp dụng các thuật toán này trong lĩnh vực dự báo năng lượng tái tạo. Trong các thí nghiệm, nhóm tác giả trên đã sử dụng kết hợp các thuật toán này để thực hiện dự báo phụ tải so với phương pháp dùng Multi-Layer Perceptron (MLP) chuẩn và mô hình dự báo vật lý trong dự báo sản lượng năng lượng của 21 nhà máy điện mặt trời. Về nghiên cứu trong nước, bài báo: "Ứng dụng về mạng Nơ-ron để dự báo phụ tải tỉnh Gia Lai" của tác giả Phạm Anh Cường, Phan Văn Hiền cũng đã được công bố năm 2011. Với cấu trúc sử dụng là mạng Nơ-ron truyền thẳng, bao gồm một lớp ra, một lớp ẩn được huấn luyện bằng thuật toán lan truyền ngược, hàm kích hoạt của các đơn vị trong lớp ẩn là hàm

tansig, hàm kích hoạt của các đơn vị ở lớp ra là hàm đồng nhất purelin, số Nơ-ron ở đầu ra là 24 và số Nơ-ron trong lớp ẩn là 23 thì mạng cơ bản đã đáp ứng được yêu cầu của bài toán cụ thể đặt ra là dự báo phụ tải điện tại tỉnh Gia Lai, đạt sai số dự báo 2.46% (sai số cho phép < 5%). Trong các mạng Nơ-ron truyền thống, tất cả các đầu vào và cả đầu ra là độc lập với nhau. Tức là chúng không liên kết thành chuỗi với nhau. Nhưng các mô hình này không phù hợp trong rất nhiều bài toán. Đặc biệt là các bài toán về vấn đề dự báo, dự đoán. Nhận thấy được hạn chế đề cập ở trên, tác giả đề xuất sử dụng mạng Nơ-ron hồi quy để giải quyết vấn đề đó.

3. PHƯƠNG PHÁP DỰ BÁO ĐỀ XUẤT

3.1. Mạng Nơ-ron hồi quy

Mạng Nơ-ron hồi quy (Recurent neural network - RNN) là một dạng học sâu của mạng Nơ-ron nhân tạo, được phát triển vào những năm 1980, RNN cơ bản là một mạng gồm các nút thần kinh giống hệt nhau, mỗi nút kết nối trực tiếp với mọi nút khác, Mỗi nút (neuron) có một kích hoạt thời gian khác nhau có giá trị kích hoạt. Mỗi kết nối có trọng số thực có thể điều chỉnh được. Các nút là các nút đầu vào (nhận dữ liệu từ bên ngoài mạng), các nút đầu ra (kết quả mang lại) hoặc các nút ẩn (điều chỉnh dữ liệu trên đường đi từ đầu vào đến đầu ra) [3] (Hình 1).

Ý tưởng chính của mạng Nơ-ron hồi quy RNN là sử dụng chuỗi các thông tin độc lập với nhau. RNN được gọi là hồi quy (Recurrent) bởi lẽ chúng thực hiện cùng một tác vụ cho tất cả các phần tử của một chuỗi với đầu ra phụ thuộc vào cả các phép tính trước đó. Nói cách khác, RNN có khả năng nhớ các thông tin được tính toán trước đó. Trên lý thuyết, RNN có thể sử dụng được thông tin của một văn bản rất dài, tuy nhiên thực tế thì nó chỉ có thể nhớ được một vài bước trước đó mà thôi. Về cơ bản một mạng RNN có dạng như hình 2. Trong đó, x_t là đầu vào tại bước t, s_t là trạng thái ẩn tại bước t. Nó chính là bộ nhớ của mạng. s_t được tính toán dựa trên cả các trạng thái ẩn phía trước và đầu vào tại bước đó: $s_t = f(U_{x_t} + W_{s_{t-1}})$

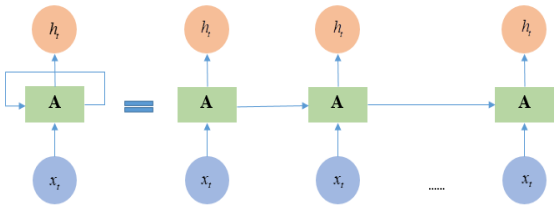

Hình 1. *Mô tả mô hình mạng Nơ-ron hồi quy*

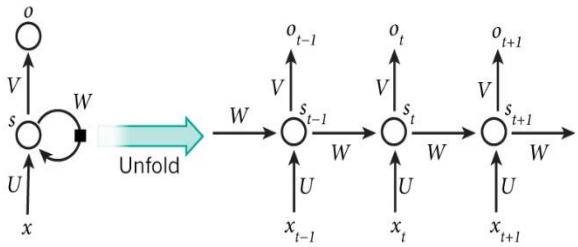

Hình 2. *Mô tả mô hình toán mạng Nơ-ron hồi quy*

Hàm f thường là một hàm phi tuyến tính như tang hyperbolic (tanh) hay hàm tuyến tính ReLu. Để làm phép toán cho phần tử ẩn đầu tiên cần khởi tạo thêm s−1, thường giá trị khởi tạo được gắn bằng 0. o_t là đầu ra tại bước t.

3.2. Mạng Long Short-Term Memory (LSTM Networks)

Huấn luyện mạng RNN cũng tương tự như các mạng Nơ-ron truyền thống, tuy nhiên đạo hàm tại mỗi đầu ra phụ thuộc không chỉ vào các tính toán tại bước đó, mà còn phụ thuộc vào các bước trước đó nữa. Điều này dẫn đến việc phụ thuộc lâu dài của mạng hồi quy. Để khắc phụ được vấn đề này, mạng LSTM đã được ra đời [4]. Long Short-Term Memory Network - thường được gọi là "LSTM" - là một loại mạng RNN đặc biệt, có khả năng học các phụ thuộc dài hạn [4]. Mạng này đã được giới thiệu bởi Hochreiter & Schmidhuber (1997) và đã được tinh chỉnh và phổ biến bởi nhiều người trong công việc ứng dụng sau này. LSTM làm việc rất tốt trên nhiều vấn đề lớn, và hiện đang được sử dụng rộng rãi. LSTM được thiết kế để nhằm tránh vấn đề phụ thuộc lâu dài. Ghi nhớ thông tin trong thời gian dài là ứng dụng thực tế của mạng này mang lại [5]. Tất cả các mạng thần kinh hồi quy đều có dạng chuỗi lặp lại mô-đun của mạng thần kinh. Trong RNNs chuẩn, mô đun lặp lại này sẽ có một cấu trúc rất đơn giản,

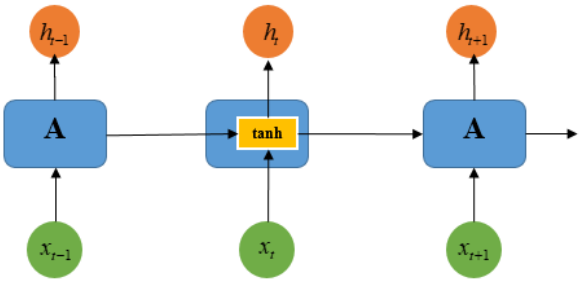

Hình 3. *Mô đun lặp lại trong một tiêu chuẩn RNN chứa một lớp duy nhất.*

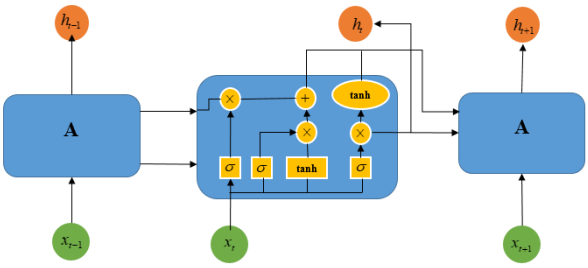

Hình 4. *Mô đun lặp đi lặp lại trong một LSTM chứa bốn lớp tương tác.*

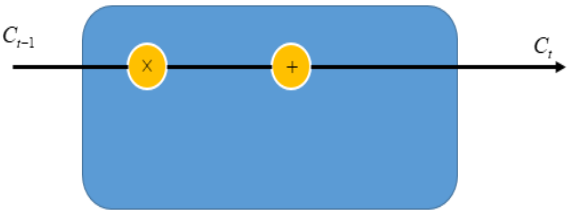

Hình 5. *Trạng thái tế bào.*

chẳng hạn như một lớp duy nhất (hình 3). LSTM cũng có cấu trúc giống như dây chuyền, nhưng mô-đun lặp đi lặp lại có một cấu trúc khác. Thay vì có một lớp mạng thần kinh duy nhất mà có nhiều tương tác một cách rất đặc biệt (Hình 4) [6].

Điều cốt lõi của mạng LSTM là trạng thái tế bào (cell state) - chính đường chạy thông ngang phía trên của sơ đồ hình vẽ. Trạng thái tế bào là một dạng giống như băng truyền. Nó chạy xuyên suốt tất cả các mắt xích (các nút mạng) và chỉ tương tác tuyến tính đôi chút. Vì vậy mà các thông tin có thể dễ dàng truyền đi thông suốt mà không sợ bị thay đổi (Hình 5).

LSTM có khả năng bỏ đi hoặc thêm vào các thông tin cần thiết cho trạng thái tế bào, chúng được điều chỉnh cẩn thận bởi các nhóm được gọi là cổng (hình 6). Các cổng là nơi sàng lọc thông tin đi qua nó, chúng được kết hợp bởi một tầng mạng sigmoid và một phép

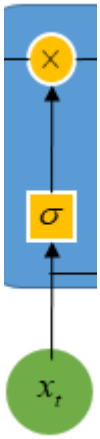

Hình 6. *Cổng tế bào.*

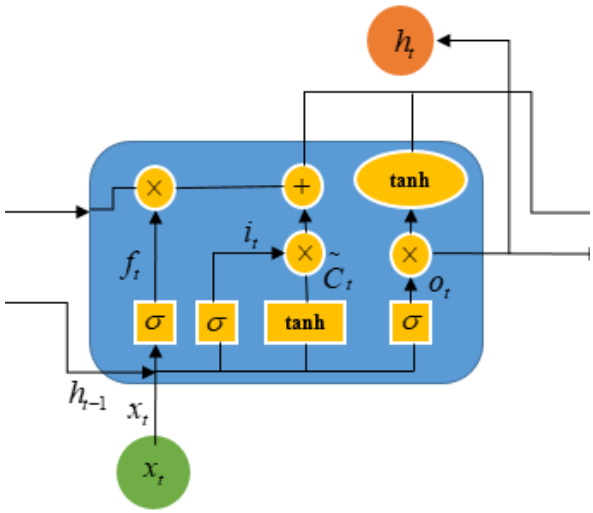

Hình 7. *Tầng cổng quên (forget gate layer).*

nhân. Tầng sigmoid sẽ cho đầu ra là một số trong khoản [0, 1] [0,1], mô tả có bao nhiêu thông tin có thể được thông qua. Khi đầu ra là 00 thì có nghĩa là không cho thông tin nào qua cả, còn khi là 11 thì có nghĩa là cho tất cả các thông tin đi qua nó [4].

3.3. Cơ sở toán học của mạng Long Short-Term Memory (LSTM Networks)

Bước đầu tiên của LSTM là quyết định xem thông tin nào cần bỏ đi từ trạng thái tế bào. Quyết định này được đưa ra bởi tầng sigmoid - gọi là "tầng cổng quên" (forget gate layer) (hình 7). Nó sẽ lấy đầu vào là h_{t-1} và x_t rồi đưa ra kết quả là một số trong khoảng [0,1] cho mỗi số trong trạng thái tế bào C_{t-1}. Đầu ra là 11 thể hiện rằng nó giữ toàn bộ thông tin lại, còn 00 chỉ rằng toàn bộ thông tin sẽ bị bỏ đi [4].

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

Bước tiếp theo là quyết định xem thông tin mới nào sẽ lưu vào trạng thái tế bào. Việc này gồm 2 phần. Đầu tiên là sử dụng một tầng sigmoid được gọi là "tầng cổng vào" (input gate layer) để quyết định giá trị nào sẽ cập nhật. Tiếp theo là một tầng tanh tạo ra một véc-tơ cho giá trị mới $\tilde{C}_t$ nhằm thêm vào cho trạng thái. Trong bước tiếp theo sẽ kết hợp 2 giá trị đó lại để tạo ra một cập nhật cho trạng thái (hình 7) [4].

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

$$\tilde{C}_t = \tanh(W_C.[h_{t-1}, x_t] + b_C) \quad (3)$$

Kế tiếp là lúc cập nhật trạng thái tế bào cũ C_{t-1} thành trạng thái mới C_t (hình 7). Ở các bước trước đó đã quyết định những việc cần làm. Nhân trạng thái cũ với f_t để bỏ đi những thông tin mà quyết định quên lúc trước. Sau đó cộng thêm $i_t * \tilde{C}_t$. Trạng thái mới thu được này phụ thuộc vào việc quyết định cập nhật mỗi giá trị trạng thái ra sao [4].

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

Cuối cùng, quyết định giá trị đầu ra cái mà sẽ dựa vào trạng thái tế bào, nhưng sẽ được tiếp tục sàng lọc. Đầu tiên, chạy một tầng sigmoid để quyết định phần nào của trạng thái tế bào muốn xuất ra. Sau đó, đưa nó trạng thái tế bào qua một hàm tanh để có giá trị nó về khoảng [-1, 1], và nhân nó với đầu ra của cổng sigmoid để được giá trị đầu ra mong muốn (hình 7) [4].

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

4. THỰC NGHIỆM

4.1. Giới thiệu bộ dữ liệu

Bộ dữ liệu lấy từ nguồn tải tiêu thụ điện năng trong 6 năm của tỉnh Tiền Giang từ năm 2012 đến năm 2017, từ bộ dữ liệu này có thể dự báo nhu cầu phụ tải điện năng trong thời gian tiếp theo. Số lượng dữ liệu khoảng 2200 giá trị.

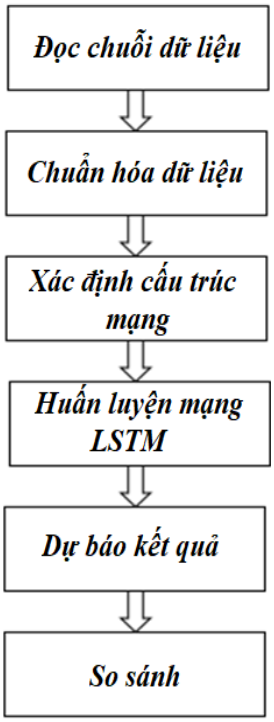

Hình 8. *Sơ đồ khối chung.*

4.2. Sơ đồ khối chung

Các phần chính trong giải thuật (hình 8):

- Đọc chuỗi dữ liệu.
- Chuẩn hóa dữ liệu.
- Xác định cấu trúc mạng LSTM.
- Huấn luyện mạng LSTM.
- Dự báo các bước thời gian trong tương lai.
- So sánh giá trị dự đoán và giá trị kiểm tra.

4.3. Kết quả thực nghiệm từng bước

4.3.1. Đọc chuỗi dữ liệu

Nhập chuỗi dữ liệu là chỉ số năng lượng tái tạo chứa 1 chuỗi thời gian đơn, trong đó các bước thời gian là đơn vị ngày và các giá trị tương ứng với tải tiêu thụ. Dữ liệu này được đưa vào vector hàng (Hình 9). Phân chia dữ liệu để huấn luyện và kiểm tra là dùng 80% chuỗi dữ liệu để huấn luyện và 20% để kiểm tra.

4.3.2. Chuẩn hóa dữ liệu

Để dữ liệu đầu vào mô hình tốt hơn cũng như ngăn chặn việc bị phân kỳ trong quá trình huấn luyện thì việc chuẩn hóa dữ liệu là vô cùng quan trọng. Cụ thể chuẩn hóa dữ liệu huấn luyện về giá trị trung bình bằng không

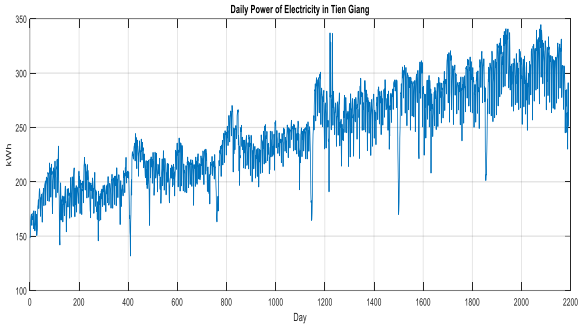

Hình 9. *Dữ liệu phụ tải điện năng tỉnh Tiền Giang giai đoạn 2012-2017.*

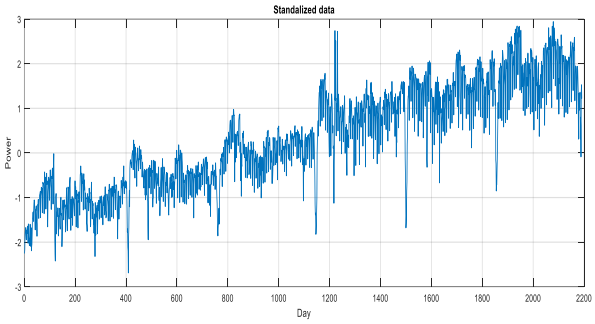

Hình 10. *Dữ liệu đầu vào sau khi chuẩn hóa.*

và phương sai đơn vị. Chuẩn hóa dữ liệu kiểm tra cùng thông số như là dữ liệu huấn luyện (Hình 10).

4.3.3. Huấn luyện mạng LSTM

Cấu trúc mạng được đề xuất gồm có 4 lớp là Sequence Input, LSTM, Fully Connected và Regression Output. Quá trình huấn luyện được giới hạn trong 200 chu kỳ và ngưỡng được đặt là 1, tốc độ học ban đầu là 0.005, tốc độ học này sẽ giảm sau 125 chu kỳ huấn luyện bằng cách nhân hệ số 0.2 (Hình 11).

4.3.4. Kết quả dự báo

Kết quả dự đoán phụ tải điện năng của tỉnh Tiền Giang được thể hiện ở hình 12. Kết quả phụ tải điện sau khi dự báo sẽ được so sánh với giá trị kiểm tra trong tập dữ liệu ban đầu. Từ hình 13 nhận thấy, hai kết quả này bám sát nhau, có nghĩa là kết quả dự báo về phụ tải điện tương đối chính xác với độ sai số hiệu dụng nhỏ, cụ thể RMSE=9.6333.

4.4. So sánh giá trị dự báo và giá trị kiểm tra khi sử dụng mạng Nơ-ron truyền thống (Fully Connected).

Sơ đồ của quá trình huấn luyện cho thấy, kết quả kiểm tra đang có xu hướng bị phân kỳ.

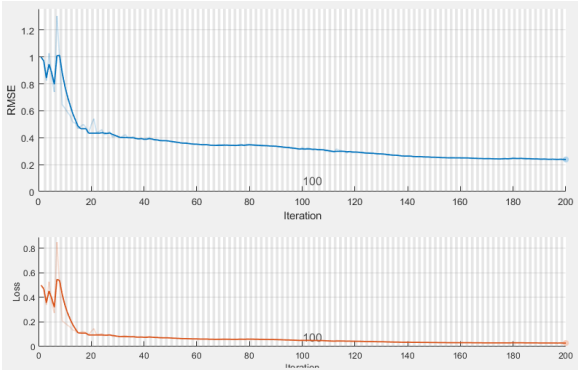

Hình 11. *Quá trình huấn luyện.*

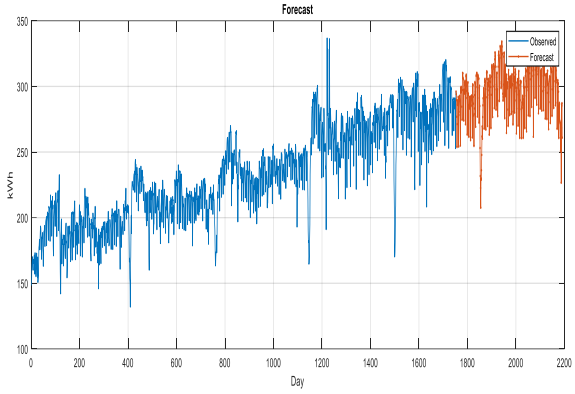

Hình 12. *Kết quả dự báo phụ tải điện năng của tỉnh Tiền Giang.*

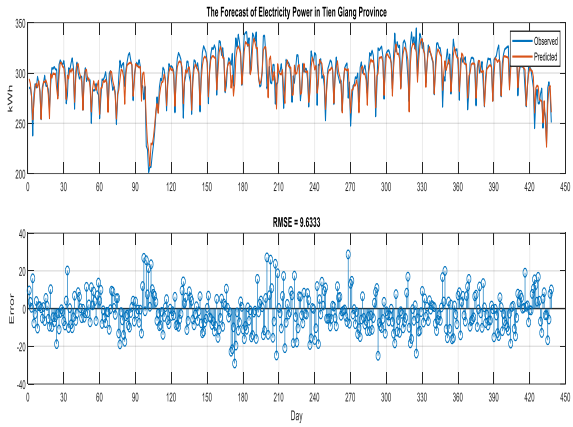

Hình 13. *So sánh kết quả dự báo phụ tải điện năng với giá trị kiểm tra.*

Điều này chứng tỏ kết quả dự báo chỉ đúng ở các giá trị đầu, từ những giá trị sau kết quả dự báo ngày càng có độ sai số lớn, dẫn đến việc dự báo không bền vững theo thời gian. (Hình 14). Từ hình 15, nhận thấy khi sử dụng mạng Nơ-ron truyền thống thì kết quả phụ tải điện sau khi dự báo với giá trị kiểm tra trong tập dữ liệu ban đầu không bám sát nhau. Điều này có là kết quả dự báo về phụ tải điện không có độ chính xác cao.

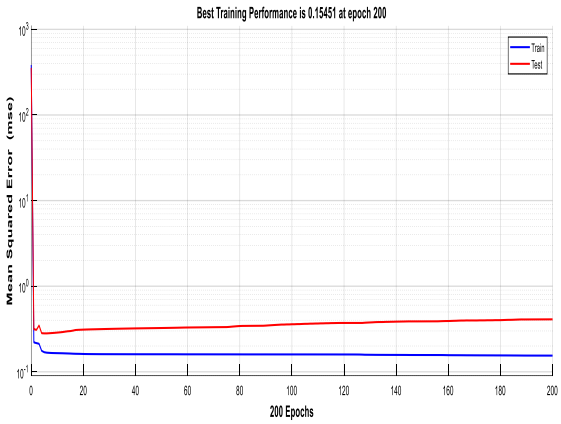

Hình 14. *Quá trình huấn luyện của mạng Nơ-ron truyền thống.*

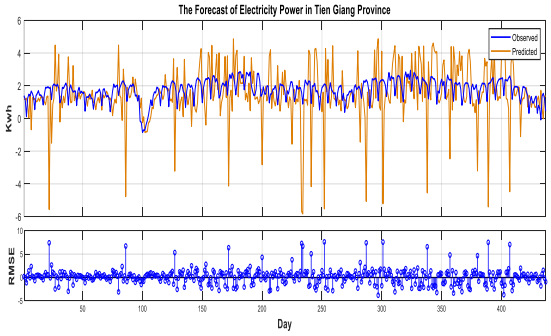

Hình 15. *Kết quả dự báo phụ tải được so sánh với kết quả kiểm tra trong tập dữ liệu ban đầu khi sử dụng mạng Nơ-ron truyền thống.*

5. KẾT LUẬN

Từ các kết quả ở phần 4, tác giả có thể đưa ra các kết luận như sau. Mạng LSTM (Long Short-Term Memory networks) giải quyết các nhược điểm mà mạng truyền thống chưa làm được. Trong bài báo này tác giả đã dự báo nhu cầu phụ tải điện năng trên tập dữ liệu thực. Trong quá trình nghiên cứu tác giả phân tích lý thuyết và kiểm chứng thực nghiệm trên phần mềm. Qua đó thấy được phương pháp mà tác giả đề xuất là dùng mạng LSTM để dự báo có độ chính xác cao hơn so với các phương pháp truyền thống trước đây. Tóm lại kết quả của bài báo đã đưa ra kết quả dự báo khá chính xác về nhu cầu phụ tải điện năng, qua đó có thể áp dụng kết quả nghiên cứu này vào thực tế tại các cơ quan điện lực trên toàn quốc.

Mặc dù kết quả đạt được từ nghiên cứu khá tốt nhưng vẫn còn nhiều vấn đề mà tác giả cần muốn cải thiện. Đầu tiên, tác giả quan tâm đến chạy trên nhiều tập dữ liệu khác nhau để cho kết quả chính xác hơn. Ngoài ra, điều chỉnh cấu trúc mạng để cho kết quả tối ưu hơn cũng là bài toán mà tác giả đang hướng đến.

TÀI LIỆU THAM KHẢO

[1] M. Buhari and S. S. Adamu, "Short-term load forecasting using artificial neural network," in Proceedings of the International MultiConference of Engineers and Computer Scientists, 2012, vol. 1, pp. 806-811.

[2] A. Gensler, J. Henze, B. Sick, and N. Raabe, "Deep Learning for solar power forecasting—An approach using AutoEncoder and LSTM Neural Networks," in Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference on, 2016, pp. 002858-002865: IEEE.

[3] T. Mikolov, M. Karafiát, L. Burget, J. Černocký, and S. Khudanpur, "Recurrent neural network based language model," in Eleventh Annual Conference of the International Speech Communication Association, 2010.

[4] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural computation, vol. 9, no. 8, pp. 1735-1780, 1997.

[5] P. Malhotra, L. Vig, G. Shroff, and P. Agarwal, "Long short term memory networks for anomaly detection in time series," in Proceedings, 2015, p. 89: Presses universitaires de Louvain.

[6] N. Tax, I. Verenich, M. La Rosa, and M. Dumas, "Predictive business process monitoring with LSTM neural networks," in International

Tác giả chịu trách nhiệm bài viết:

Họ tên: Đoàn Văn Vững

Đơn vị: Trường Đại Học Sự Phạm Kỹ Thuật TP.HCM

Điện thoại: 0989365394

Email: vungtg77@yahoo.com.vn

BÀI BÁO KHOA HỌC

THỰC HIỆN CÔNG BỐ THEO QUY CHẾ ĐÀO TẠO THẠC SỸ

Bài báo khoa học của học viên

có xác nhận và đề xuất cho đăng của Giảng viên hướng dẫn

Bản tiếng Việt ©, TRƯỜNG ĐẠI HỌC SƯ PHẠM KỸ THUẬT TP. HỒ CHÍ MINH và TÁC GIẢ

Bản quyền tác phẩm đã được bảo hộ bởi Luật xuất bản và Luật Sở hữu trí tuệ Việt Nam. Nghiêm cấm mọi hình thức xuất bản, sao chụp, phát tán nội dung khi chưa có sự đồng ý của tác giả và Trường Đại học Sư phạm Kỹ thuật TP. Hồ Chí Minh.

ĐỂ CÓ BÀI BÁO KHOA HỌC TỐT, CẦN CHUNG TAY BẢO VỆ TÁC QUYỀN!

Thực hiện theo MTCL & KHTHMTCL Năm học 2018-2019 của Thư viện Trường Đại học Sư phạm Kỹ thuật Tp. Hồ Chí Minh.