

APPLYING SEQ2SEQ-LSTM IN A SHORT-TERM LOAD FORECASTING MODEL FOR THE POWER GRID IN TIEN GIANG

Duong Ngoc Hung^{1,2*}, Nguyen Minh Tam¹, Nguyen Tung Linh³, Nguyen Thanh Hoan⁴, Nguyen Thanh Duy²

¹HCM University of Technology and Education, ²Tien Giang University, ³Electric Power University

⁴Department of Information Technology - Ho Chi Minh Power Corporation (EVNHCMC)

ARTICLE INFO	ABSTRACT
Received: 26/10/2023	Short-term load forecasting is critical for energy suppliers to meet the loads of consumers connected to the grid. This study explores the performance of short-term load demand forecasting models, including CNN-LSTM, Wavenet, and Seq2Seq integrating long short-term memory (LSTM). The Seq2Seq-LSTM prediction model is established by combining the sequence-to-sequence (Seq2Seq) structure with the long-short-term neuron model to improve the prediction accuracy. The study validates the models using demand data from the Tien Giang power system from 2021 to 2022, taking into consideration historical demand, holidays and weather variables as input characteristics. The results show that both CNN-LSTM, Wavenet and Seq2Seq-LSTM models can predict future demand with root mean square error (RMSE) and mean absolute percentage error (MAPE). Therefore, the proposed models are not only a useful tool in making smart decisions and planning for future energy needs, but can also play an important role in minimizing Optimize the use of energy resources, minimize negative environmental impacts, and improve the overall performance of the energy sector.
Revised: 27/11/2023	
Published: 27/11/2023	
KEYWORDS	
Wavenet	
LSTM	
CNN	
Seq2Seq	
Peak load forecasting	

ỨNG DỤNG SEQ2SEQ-LSTM TRONG MÔ HÌNH DỰ BÁO NGẮN HẠN PHỤ TẢI CHO LƯỚI ĐIỆN Ở TIỀN GIANG

Dương Ngọc Hùng^{1,2*}, Nguyễn Minh Tâm¹, Nguyễn Tùng Linh³, Nguyễn Thanh Hoan⁴, Nguyễn Thanh Duy²

¹Trường Đại học Sư phạm Kỹ thuật Thành phố Hồ Chí Minh, ²Trường Đại học Tiền Giang

³Trường Đại học Điện lực, ⁴Công ty Công nghệ thông tin – Tổng Công ty điện lực Thành phố Hồ Chí Minh

THÔNG TIN BÀI BÁO	TÓM TẮT
Ngày nhận bài: 26/10/2023	Dự báo phụ tải ngắn hạn là rất quan trọng đối với các nhà cung cấp năng lượng để đáp ứng tải trọng của người tiêu dùng kết nối với lưới điện. Nghiên cứu này khám phá hiệu suất của các mô hình dự báo ngắn hạn nhu cầu phụ tải, bao gồm CNN-LSTM, Wavenet và Seq2Seq tích hợp long short-term memory (LSTM). Mô hình dự báo Seq2Seq-LSTM được thiết lập bằng cách kết hợp cấu trúc từ chuỗi đến chuỗi (Seq2Seq) với mô hình no-ron dài ngắn hạn để cải thiện độ chính xác dự báo. Nghiên cứu xác thực các mô hình bằng dữ liệu nhu cầu từ hệ thống điện Tiền Giang từ năm 2020 đến 2022, lấy vào cân nhắc nhu cầu lịch sử, các ngày lễ và các biến số thời tiết làm đặc trưng đầu vào. Kết quả cho thấy cả mô hình CNN-LSTM, Wavenet và Seq2Seq-LSTM đều có thể dự đoán nhu cầu tương lai với sai số bình phương trung bình gốc (RMSE) và sai số phần trăm tuyệt đối trung bình (MAPE). Vì vậy, các mô hình đề xuất không chỉ là một công cụ hữu ích trong việc đưa ra quyết định thông minh và lập kế hoạch cho nhu cầu năng lượng trong tương lai, mà còn có thể đóng một vai trò quan trọng trong việc tối ưu hóa sử dụng tài nguyên năng lượng, giảm thiểu tác động tiêu cực đến môi trường, và cải thiện hiệu suất tổng thể của ngành năng lượng.
Ngày hoàn thiện: 27/11/2023	
Ngày đăng: 27/11/2023	
TỪ KHÓA	
Phép biến đổi Wavenet	
LSTM	
CNN	
Mô hình Seq2Seq	
Dự báo phụ tải đỉnh	

DOI: <https://doi.org/10.34238/tnu-jst.9060>

* Corresponding author. Email: 1726001@student.hcmute.edu.vn

1. Giới thiệu

Trong xu hướng phát triển hiện nay, công nghệ ngày càng chiếm lấy một thành phần lớn trong cuộc sống. Và nhu cầu phụ tải điện ngày càng gia tăng nhanh chóng, cùng với sự phát triển của microgrid (MG) [1]. Các mô hình MG dưới dạng một lưới điện quy mô nhỏ, các kỹ thuật và công cụ tiên tiến được đặt ra để vận hành năng lượng tối ưu [2]. Sự quan trọng của việc dự đoán tải người tiêu dùng ngày càng được đánh giá cao. Bài toán dự đoán tải cao điểm được coi là phức tạp hơn so với những bài toán khác. Sự chính xác trong dự đoán ngắn hạn có thể hỗ trợ hoạt động và quản lý hệ thống điện ở khu vực hiệu quả và thuận tiện. Nếu dự đoán cho thấy rằng dung lượng lưu trữ không đủ để đáp ứng tải điện tương lai, công ty điện lực có thể thông báo tình trạng này cho người dùng. Điều này có thể dẫn đến việc người dùng giảm sử dụng năng lượng, không chỉ để tiết kiệm tiền, mà còn để ủng hộ các biện pháp ưu tiên của cơ quan chức năng.

Do tính ưu việt của học sâu, nghiên cứu này xem xét một phương pháp được đề xuất trong [3], một phương pháp cụ thể để dự báo nhu cầu tải ngắn hạn trong một hệ thống microgrid (MG) điển hình là sử dụng một sự kết hợp giữa biến đổi wavelet tĩnh và mạng nơ-ron truyền thẳng, trong đó áp dụng thuật toán tối ưu hóa Harris hawks. Thuật toán tối ưu hóa Harris hawks được áp dụng vào mạng nơ-ron truyền thẳng như một phương pháp huấn luyện thay thế để tối ưu hóa trọng số và cơ sở của các nơ-ron. Xem xét cách tiếp cận khác trong nghiên cứu [4], WaveNet sử dụng phức hợp nhân quả giãn nở và kết nối bỏ qua để sử dụng thông tin dài hạn. Loại kiến trúc ML (Multi Layer) mới lạ này thể hiện những ưu điểm khác biệt liên quan đến các thuật toán thống kê khác.

Hơn nữa, có nhiều phương pháp dự báo đã được đề xuất bởi các nhà nghiên cứu để giải quyết vấn đề dự báo tải. Các phương pháp này có thể được phân loại thành các tiếp cận thống kê, bền vững, học máy và kết hợp [5]. Trong nghiên cứu [6], họ áp dụng một mô hình hồi quy tuyến tính đa biến để dự đoán nhu cầu tải cơ bản hàng giờ. Để xác định cấu trúc thích hợp cho mô hình đề xuất, tác giả sử dụng phương pháp thử và sai số. Một cửa sổ di chuyển dựa trên hồi quy với phương pháp dựa trên kích thước cửa sổ có thể điều chỉnh được đã được trình bày bài báo [7]. Phương pháp đề xuất đã được so sánh với mạng nơ-ron sử dụng thuật toán lan truyền ngược (BPNN) để làm nổi bật hiệu quả của chiến lược cửa sổ di chuyển dựa trên hồi quy. Tương tự, việc dự báo tải phụ được thực hiện trong nghiên cứu [8] cho hệ thống microgrid bằng việc áp dụng phương pháp bền vững. Trong nghiên cứu [9], [10], họ đã đề xuất một mô hình sử dụng bộ lọc Kalman để dự đoán nhu cầu tải ngắn hạn của hộ gia đình. Tác giả đã thực hiện việc so sánh hiệu suất của phương pháp đề xuất với các phương pháp cạnh tranh hiện có. Ngoài ra, có mô hình khác như đường trung bình động tự hồi quy với các biên ngoại sinh (ARMAX) [11], [12], đường trung bình động tích hợp tự hồi quy (ARIMA) [13], ARIMA theo mùa (SARIMA) [14] và đường trung bình động tự hồi quy sửa đổi (ARMA) [15] cũng đã được đề xuất để dự đoán tải ngắn hạn. Tuy nhiên, những phương pháp này gặp hạn chế trong việc xử lý tính phi tuyến và không đáng tin cậy trong dự báo. Những hạn chế này đã hạn chế sự ứng dụng của chúng và tạo ra bất lợi lớn.

Những nhà nghiên cứu đã xem xét các phương pháp tiếp cận máy học và kết hợp như là những công cụ mạnh mẽ để đối phó với tính phi tuyến của dữ liệu tải. Các phương pháp học máy bao gồm sử dụng máy vectơ hỗ trợ (SVM) và Mạng nơ-ron nhân tạo (ANN). Trong các nghiên cứu [16] – [19], dự báo tải ngắn hạn đã được thực hiện bằng cách sử dụng cả SVM và mô hình kết hợp dựa trên SVM, được điều chỉnh theo mùa (SSA-SVM). Để thể hiện hiệu suất vượt trội của SSA-SVM, hiệu suất của nó đã được so sánh với ANN và ANN tích hợp biến đổi wavelet theo mùa. Tương tự, một số phương pháp tiếp cận kết hợp cũng đã được áp dụng để dự báo phụ tải. Bao gồm các phương pháp tối ưu hóa bầy đàn (PSO) kết hợp với SVM [20], thuật toán di truyền (GA) cùng với SVM [21], thuật toán đom đóm (FFA) kết hợp với SVM [22], [23], thuật toán tối ưu hóa châu chấu (GOA) dựa trên SVM [24], thuật toán tối ưu hóa ruồi giấm cải tiến kết hợp với SVM [25], PSO lai và thuật toán di chuyển ngang (GTA) cùng với SVM [26], phân rã chế độ thực nghiệm (EMD) [27], và biến đổi wavelet (WT) kết hợp với PSO-SVM [28]. Máy vectơ hỗ trợ bình phương tối thiểu (LSSVM) cũng đã được sử dụng để dự đoán tải điện, đây là

một biến thể SVM tiên tiến. Trong tài liệu tham khảo [29], các tác giả áp dụng LSSVM và LSSVM kết hợp với PSO cho STLf. Hiệu suất của các phương pháp đề xuất đã được so sánh với các phương pháp tiếp cận thông thường để chứng minh tính hiệu quả của chúng. Một WT lai với tối ưu hóa ruồi giấm (FFO) và thuật toán LSSVM dựa trên cá nhả tắng đã được đề xuất trong [30], [31] cho STLf. Hiệu suất vượt trội của các phương pháp được đề xuất chứng tỏ kết quả của công việc được trình bày.

Nghiên cứu [31] đã đề xuất và đánh giá một phương pháp dự báo kết hợp thuật toán tối ưu hóa tìm kiếm backtracking với mạng trạng thái ẩn hai lớp lặp lại. Nghiên cứu [32] đã phát triển một mô hình dự báo chuỗi thời gian kết hợp phân rã chế độ biến thiên và một mạng nơ-ron kernel ELM autoencoder kết hợp sự pha trộn sâu, từ đó đưa ra một dự báo chính xác về năng lượng gió. Nghiên cứu [33] đã đề xuất một mạng tin cậy phân tán (DDBN) với một mô hình chuyển đổi Markov để tránh việc điều chỉnh thủ công trọng số của các nút lớp ẩn. Nó cho thấy hiệu suất tổng quát của mô hình tốt và tạo ra một giải pháp chính xác về trọng số đầu ra thông qua phương pháp bình phương tối thiểu tổng quát, từ đó tiết kiệm không gian lưu trữ và cải thiện độ chính xác của dự báo. Nghiên cứu [34] đã đề xuất một phương pháp kết hợp sử dụng các mô hình prophet và LSTM để vượt qua giới hạn hội tụ chậm và dự đoán chính xác tải điện.

Việc cải thiện thuật toán dự báo phụ tải ngắn hạn cung cấp nền tảng cho việc điều phối và quản lý điện tinh refined. Tuy nhiên, hệ thống dự báo phụ tải ngắn hạn cho lưới điện yêu cầu chức năng dự báo, phân tích và quản lý phụ tải hoàn hảo. Trong nghiên cứu này, một phương pháp học sâu được sử dụng để cải thiện độ chính xác của dự báo phụ tải điện. Để dự báo phụ tải điện, một mô hình mạng nơ-ron dài ngắn hạn (LSTM) đã được thiết lập. Hơn nữa, chúng tôi đã phát triển một mô hình dự báo từ chuỗi sang chuỗi (Seq2Seq) mới bằng cách điều chỉnh một mạng nơ-ron LSTM cho đầu vào không đều.

- Bằng cách sử dụng mạng nơ-ron LSTM, đã phát triển một mô hình để dự đoán phụ tải điện.

- Dựa trên mô hình LSTM đã đề cập, đã đề xuất một mô hình tối ưu Seq2Seq. Mô hình này giải quyết vấn đề gặp phải bởi mạng nơ-ron hồi quy truyền thống (RNN), không thể xem xét mối quan hệ tuần tự giữa các nhãn đầu ra. Hơn nữa, nó hỗ trợ đầu vào và đầu ra có độ dài biến, từ đó nâng cao khả năng thích ứng của toàn bộ khuôn khổ dự báo.

Dựa trên các tài liệu tham khảo, các phương pháp máy học và kết hợp có một số nhược điểm như khó khăn trong việc lựa chọn tham số và lựa chọn các biến đầu vào không rõ ràng. Do đó, bài báo này đề xuất một phương pháp tiếp cận dự báo phụ tải đỉnh cải tiến bằng cách sử dụng Mô hình tối ưu Seq2Seq kết hợp LSTM. Phương pháp đề xuất đã được so sánh với một số mô hình cạnh tranh khác (bao gồm: ANN, LSTM, CNN-LSTM, Wavenet), để chứng minh hiệu quả của kỹ thuật. Phần còn lại của bài viết này được tổ chức như sau: Phần 2 cung cấp mô tả chi tiết về Seq2Seq kết hợp LSTM, được sử dụng thư viện Tensorflow và thực nghiệm. Các kết quả số, hình ảnh dự báo được cung cấp trong phần 3 và kết luận được trình bày trong phần cuối cùng.


2. Giải thuật đề xuất và thực nghiệm

2.1. Giải thuật đề xuất


2.1.1. Mô hình mạng LSTM

Chuỗi thời gian là một yếu tố quan trọng trong dữ liệu tải điện. Mạng nơ-ron RNN thường mang lại nhiều lợi thế hơn trong việc dự đoán liên quan đến chuỗi thời gian so với mạng nơ-ron truyền thẳng. Tuy nhiên, chúng đối mặt với hai vấn đề chính trong quá trình huấn luyện. Thứ nhất, càng xa về thời điểm hiện tại trong quá trình huấn luyện, tín hiệu gradient càng ít quan trọng. Chúng cũng đối mặt với vấn đề thất bại trong việc nắm bắt khả năng, đó là vấn đề biến mất gradient. Thứ hai, mỗi bước huấn luyện phải tính đạo hàm của hàm kích hoạt. Nếu kết quả của phần này lớn hơn một, việc cập nhật gradient sẽ tăng một cách mũ mà cùng với sự gia tăng số lớp, cuối cùng sẽ xảy ra sự bùng nổ gradient.

Bài báo này đề xuất một mô hình dự báo tải dựa trên mạng nơ-ron LSTM để khắc phục nhược điểm của RNN; mạng nơ-ron LSTM là một phiên bản cải tiến của RNN. Mạng RNN có hình thức kết nối của một mô-đun RNN; mô-đun lặp này có cấu trúc rất đơn giản, như được thể hiện trong Hình 1. Mỗi mô-đun của mạng RNN chứa một lớp tanh. Cấu trúc mạng LSTM tương tự như mạng RNN, ngoại trừ mô-đun lặp lại, như được thể hiện trong Hình 2. Khác với mạng nơ-ron đơn lớp của RNN, mạng nơ-ron LSTM có bốn lớp tương tác khác nhau.




Hình 1. Mô hình mạng nơ-ron RNN



Hình 2. Mô hình mạng nơ-ron LSTM

Mô hình mạng nơ-ron LSTM có bốn phần: phần đầu vào và đầu ra, và phần quên và cập nhật, như được thể hiện trong Hình 3. Trong Hình 3, x_t biểu thị đầu vào tại thời điểm t , h_t biểu thị trạng thái ẩn tại thời điểm t và c_t biểu thị trạng thái ô tại thời điểm t . σ biểu thị hàm sigmoid logistic trả về một giá trị xác suất nằm trong khoảng từ không đến một, chỉ ra khả năng truyền tín hiệu. Giá trị 0 cho thấy tín hiệu không thể truyền qua, và 1 cho thấy tất cả các tín hiệu được phép truyền qua.



Hình 3. Cấu trúc của một ô trong mạng nơ-ron LSTM: (A) Cổng quên, (B) Cổng đầu vào, (C) Phần cập nhật trạng thái, (D) Cổng đầu ra

Mỗi ô trong mạng LSTM có một cấu trúc phức tạp, được điều khiển bởi ba cổng: cổng quên, cổng đầu vào và cổng đầu ra. Ô điều khiển thông tin trong mạng bằng cách sử dụng ba cổng này

để loại bỏ hoặc thêm thông tin vào trạng thái $\hat{o}_t$, tức là “bộ nhớ”. Cổng quên xác định mức độ quên, như được thể hiện trong Hình 3A. f_t biểu thị công tắc điều khiển cổng của cổng quên, điều khiển số lượng trạng thái $\hat{o}$ trước đó bị quên. Tương tự như bộ nhớ của con người, cổng quên có thể thể hiện chức năng quên thông tin không quan trọng trong khi giữ lại thông tin quan trọng.

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

Hình 3B miêu tả cổng đầu vào, nơi nhận thông tin mới từ đầu vào ngoại vi và lựa chọn nhớ thông tin tại trạng thái hiện tại và dữ liệu trong trạng thái ẩn trước đó. Điều này tạo ra một vector mới để chứa dữ liệu, vector này có thể được cập nhật. Trong cổng đầu vào, lớp tanh xác định giá trị ứng cử viên của nội dung được cập nhật và lớp sigmoid xác định nội dung được cập nhật. Giá trị xác suất nằm trong khoảng từ 0 đến 1.

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

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

Bước tiếp theo liên quan đến việc cập nhật trạng thái $\hat{o}$, như được thể hiện trong Hình 3C. Quá trình có thể như sau. Đầu tiên, c_{t-1} của thời điểm trước được cập nhật thành c_t , trong đó c_{t-1} được nhân với f_t . Sau đó, thông tin không quan trọng được quên đi và thông tin quan trọng được giữ lại. Cuối cùng, thông tin còn lại trong đầu vào hiện tại được giữ lại để thu được trạng thái $\hat{o}$ mới nhất. Bước này thay đổi dựa trên mức độ cập nhật của từng trạng thái.

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (4)$$

Lớp sigmoid trong cổng đầu ra xác định đầu ra từ trạng thái $\hat{o}$ hiện tại, như được thể hiện trong Hình 3D. Quá trình này được thể hiện bằng cách sử dụng hàm tanh. Đầu ra của lớp sigmoid sau đó được nhân với giá trị đã được xử lý nằm trong khoảng từ -1 đến 1 để thu được đầu ra. Cuối cùng, cổng đầu ra chuyển trạng thái $\hat{o}_t$ và đầu ra h_t đã thu được sang $\hat{o}$ tiếp theo.

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

$$h_t = o_t \cdot \tanh(c_t - 1) \quad (6)$$


Trong đó, W_f , W_i , W_c và W_o là ma trận trọng số của cổng quên, cổng đầu vào, trạng thái $\hat{o}$ và cổng đầu ra tương ứng; b_f , b_i , b_c và b_o là các vector bias tương ứng.

Mô hình mạng nơ-ron LSTM truyền thống giải quyết vấn đề dự đoán n bước bằng cách thêm một lớp dày khi đưa ra đầu ra h_t . Điều này ánh xạ trạng thái ẩn thành một vector n chiều, từ đó đáp ứng định dạng dữ liệu của vấn đề. Các n bước được dự đoán hoàn toàn độc lập tại điểm này. Do đó, sự phụ thuộc chuỗi giữa các nhãn đầu ra không được xem xét khi sử dụng mạng nơ-ron LSTM cho dự đoán. Hơn nữa, mạng nơ-ron LSTM không thể hỗ trợ đầu vào có độ dài biến đổi. Theo cơ bản, nếu một cảm biến bất ngờ gặp sự cố trong quá trình giám sát, dẫn đến một phần mất dữ liệu dự đoán, mạng nơ-ron LSTM có thể không hoàn thiện quá trình huấn luyện. Những hạn chế này có thể được khắc phục bằng cách sử dụng mô hình dự báo tải điện dựa trên LSTM để xuất, sử dụng phương pháp chuỗi-qua-chuỗi (sequence-to-sequence).

2.1.2. Mô hình dự báo Seq2Seq-LSTM

Trong nghiên cứu này, một khung viện thống kê Seq2Seq-LSTM được thiết kế và một mạng nơ-ron LSTM được triển khai cho bộ mã hóa và giải mã. Nó bao gồm hai thành phần chính: bộ mã hóa và bộ giải mã. Bộ mã hóa nhận một chuỗi có độ dài biến đổi và chuyển đổi nó thành một trạng thái được mã hóa trong một định dạng cố định bằng cách sử dụng một mạng nơ-ron LSTM. Bộ giải mã cũng bao gồm một mạng nơ-ron LSTM, nó ánh xạ trạng thái được mã hóa trong định dạng cố định thành một chuỗi có độ dài biến đổi. Đây được gọi là kiến trúc mã hóa - giải mã, như

được thể hiện trong Hình 4. Cấu trúc này có thể khắc phục vấn đề gặp phải trong quá trình huấn luyện, khi không thể thực hiện huấn luyện do thiếu dữ liệu đầu vào.




Hình 4. Encoder-Decoder architecture

Trong quá trình mã hóa, bộ mã hóa trước tiên mã hóa dữ liệu chuỗi có độ dài biến đổi thành một vector trung gian có độ dài cố định. Vector trạng thái trung gian có thể được coi là một biểu diễn có độ dài cố định của chuỗi đầu vào, thường được gọi là vector nền. Trong quá trình giải mã, bộ giải mã giải mã một vector trung gian có độ dài cố định thành đầu ra dự đoán. Điều này cho phép một chuỗi đầu vào có bất kỳ độ dài nào được ánh xạ thành một chuỗi đầu ra có bất kỳ độ dài nào.

Hình 5 miêu tả khung viên LSTM-Seq2Seq được đề xuất để dự đoán tải điện. Xác định một chuỗi đầu vào $x = (x_1, x_2, \dots, x_n)$ và mã hóa nó bằng cách sử dụng một LSTM đa tầng. Sau khi được nhúng, mảng đầu vào x được đưa vào tầng đầu tiên của LSTM đa tầng, và các trạng thái ẩn $h = \{h_1, h_2, \dots, h_n\}$ được đầu ra bởi tầng này được sử dụng làm đầu vào cho LSTM ở tầng phía trên. Do đó, biểu diễn mỗi tầng bằng một số mũ l ($l = 1, 2, \dots, k$) dẫn đến biểu thức sau cho các trạng thái ẩn trong tầng tương ứng.

$$h_n^l = \text{EncoderLSTM}^l(x_n, h_{n-1}^l) \quad (7)$$



Hình 5. Khung viên mô hình LSTM-Seq2Seq

Việc sử dụng LSTM nhiều lớp cũng yêu cầu đầu vào ở trạng thái ẩn ban đầu trên mỗi lớp h_0^l và đầu ra của một vector trạng thái trên mỗi lớp z^l . Bài viết này chỉ đơn giản xem cn như một loại trạng thái ẩn khác. Tương tự như h_0^l , c_0^l sẽ được khởi tạo thành một tensor toàn số 0. Ngoài ra, vector trạng thái trung gian hiện là trạng thái ẩn cuối cùng và trạng thái ô cuối cùng, tức là $z^l = (h_0^l, c_0^l)$

Chúng tôi thu được những điều sau bằng cách mở rộng các phương trình đa lớp của mình sang LSTM:

$$(h_n^l, c_n^l) = \text{EncoderLSTM}^l(x_n, (h_{n-1}^l, c_{n-1}^l)) \quad (8)$$

Tiếp theo, chúng tôi xây dựng bộ giải mã, đó cũng là LSTM nhiều lớp. Lớp “Decoder” thực hiện một bước giải mã duy nhất cho mỗi bước thời gian, tức là nó xuất ra một mã thông báo duy

nhất. (s_{m-1}^l, c_{m-1}^l) , s_m , c_m tương ứng là trạng thái lớp ẩn và trạng thái ô cuối cùng của bộ giải mã. Và cung cấp nó cho LSTM cùng với mã thông báo nhúng hiện tại để tạo trạng thái ô và ẩn mới (s_m^l, c_m^l) . Các lớp tiếp theo sẽ sử dụng trạng thái ẩn của lớp bên dưới chúng s_m^{l-1} cũng như các trạng thái ẩn và ô trước đó từ lớp của chúng (s_{m-1}^l, c_{m-1}^l) . Điều này cung cấp các phương trình gần giống với các phương trình trong bộ mã hóa.


$$s_m = \text{DecoderLSTM}(y_m, s_{m-1}) \quad (9)$$

$$(s_m^l, c_m^l) = \text{DecoderLSTM}^l(y_m, (s_{m-1}^l, c_{m-1}^l)) \quad (10)$$

2.2. Thực nghiệm

2.2.1. Tập dữ liệu

Để thực hiện mô phỏng cho phương pháp đề xuất, tập dữ liệu được sử dụng là từ việc dự báo tải điện tại Tiền Giang. Dữ liệu phụ tải điện toàn Tiền Giang từ 01/01/2021 đến 25/07/2022. Dữ liệu được lấy mẫu chu kỳ 60 phút, 24 mẫu hằng ngày. Hình 6 là dữ liệu phụ tải điện của 3 tuần ở Tiền Giang từ ngày 11/01/2021 đến 31/01/2021, thể hiện quá trình tăng giảm của phụ tải. Phụ tải thường giảm vào các ngày thứ 7, Chủ Nhật và tăng vào các ngày làm việc còn lại.



Hình 6. Dữ liệu phụ tải điện trong 3 tuần ở Tiền Giang

Bảng 1. Bộ giá trị bit gán cho các chỉ số trong chuỗi phụ tải


Chỉ số	Phân phối vị trí bit	Mô tả
Dữ liệu phụ tải	0	Giá trị tuyệt đối của phụ tải
Chỉ số giờ (Hour)	1-24	Biến mã hóa của giờ hiện tại trong một ngày (24 giờ)
Chỉ số giờ (Hour)	25-31	Biến mã hóa của loại ngày hiện tại trong tuần
Chỉ số ngày trong tháng (Day)	32-62	Biến mã hóa của ngày hiện tại trong tháng (31 ngày)
Chỉ số tuần (Week)	63-115	Biến mã hóa của tuần hiện tại trong năm (53 tuần)
Chỉ số tháng (Month)	116-127	Biến mã hóa của tháng hiện tại trong năm (12 tháng)
Chỉ số Quý (Quarter)	128-131	Biến mã hóa của quý hiện tại trong năm (4 quý)
Chỉ số ngày lễ (Holiday)	132	Biến nhị phân cho biết ngày hiện tại có là ngày nghỉ hay không

Để giải quyết vấn đề dự đoán tải điện, ngoài việc xem xét tính chu kỳ của nhu cầu, các yếu tố khác ảnh hưởng đến tiêu thụ điện được cân nhắc, bao gồm điều kiện thời tiết như nhiệt độ ngoài trời, độ ẩm, tỷ lệ ánh sáng mặt trời, tốc độ và cường độ gió trong ngày; cũng như các yếu tố thời gian như các dịp lễ hội và yếu tố về chỉ số kinh tế. Tất cả những yếu tố này đóng vai trò quan trọng.


trọng trong việc dự đoán tải điện một cách chính xác. Tuy nhiên, việc thu thập các yếu tố bên ngoài kể trên rất phức tạp, số liệu thu thập thường được biểu hiện dưới dạng chuỗi thời gian liên tục và tuần hoàn trong ngày. Qua đó, nghiên cứu này sẽ thực hiện đánh giá dữ liệu theo mốc thời gian, các mã hóa thời gian theo ngày, tuần, tháng, ngày lễ; và dữ liệu nhiệt độ ngoài trời ở Tiền Giang trong thời gian tương ứng.

Dữ liệu nhiệt độ được thể hiện như biểu đồ trong Hình 7, bao gồm: phụ tải điện (kWh, màu xanh lam, đường chấm tròn), nhiệt độ ngoài trời tại Tiền Giang theo các mốc thời gian tương ứng ($^{\circ}\text{C}$, màu đỏ, đường hình sao). Dựa vào Hình 7 có thể thấy đỉnh của phụ tải các ngày trong tuần thường trùng với đỉnh của nhiệt độ, riêng ngày Chủ Nhật, phụ tải và nhiệt độ thường đối lập nhau do đây là ngày nghỉ trong tuần.

Hình 8 thể hiện sai số huấn luyện của mô hình LSTM giảm qua các lần lặp (epochs) trong quá trình huấn luyện nhưng phải tăng chỉ số epochs có khả năng gây tiêu tốn quá nhiều tài nguyên.



Hình 7. Dữ liệu phụ tải điện và nhiệt độ trong 1 tuần ở Tiền Giang



Hình 8. Sai số huấn luyện mô hình LSTM qua số lần lặp

2.2.2. Các chỉ số đánh giá

Để đánh giá hiệu suất dự đoán của mô hình T-GCN, chúng tôi sử dụng năm chỉ số để đánh giá sự khác biệt giữa thông tin lưu lượng truy cập thực Y_t , $\hat{Y}_t$ và dự đoán, bao gồm:

- Root Mean Squared Error (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_t - \hat{Y}_t)^2} \quad (11)$$

- Mean Absolute Error (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_t - \hat{Y}_t| \quad (12)$$

- Accuracy:

$$Accuracy = 1 - \frac{\|Y - \hat{Y}\|_F}{\|Y\|_F} \quad (13)$$

- Coefficient of Determination (R2):

$$R^2 = 1 - \frac{\sum_{i=1} (Y_t - \hat{Y}_t)^2}{\sum_{i=1} (Y_t - \bar{Y})^2} \quad (14)$$

- Explained Variance Score (Var):

$$var = 1 - \frac{Var\{Y - \hat{Y}\}}{Var\{Y\}} \quad (15)$$

Cụ thể, RMSE và MAE được sử dụng để đo lường sai số dự đoán: giá trị càng nhỏ thì hiệu quả dự đoán càng tốt. Độ chính xác được sử dụng để phát hiện độ chính xác của dự đoán: giá trị càng cao thì hiệu quả dự đoán càng tốt. R2 và Var tính toán hệ số tương quan, đo lường khả năng của kết quả dự đoán trong việc đại diện cho dữ liệu thực tế: giá trị càng lớn thì hiệu quả dự đoán càng tốt.

3. Kết quả và thảo luận

3.1. Kết quả đánh giá sai số

Bảng 2 hiển thị hiệu suất của các mô hình đề cập ở trên. Mô hình đề xuất hoạt động tốt hơn các mô hình khác ở hầu hết các tiêu chí, trong đó hệ số RSME và MAPE thể hiện rõ sự ưu việt của phương pháp được đề xuất. Trong đó, mô hình được đề xuất cho các số liệu thấp hơn rất nhiều so với các phương pháp được so sánh (ít nhất là % so với phương pháp tiếp theo).


Dựa trên kết quả hiển thị trong Bảng 2, mô hình sử dụng ANN đã cho kết quả sai số cao nhất. Mô hình LSTM và phiên bản tích hợp CNN-LSTM đã cải thiện sai số MAPE lần lượt là 4,96% và 2,08%. Sự cải thiện đáng kể xuất hiện khi áp dụng mô hình Seq2Seq-LSTM, cụ thể, mô hình Wavenet đã giảm MAPE xuống dưới mức đáng kể, chỉ còn 1,66. Tuy nhiên, mô hình Wavenet vẫn có một giá trị RMSE cơ bản tương đối cao, là 298,93. Giải thuật đề xuất Seq2Seq -LSTM, kết quả cải thiện rõ rệt với MAPE là 1,03% và RMSE là 200,15. Hiện nay, điện lực Tiền Giang đang sử dụng phương pháp so sánh đối chiếu để dự báo hệ thống phụ tải điện. Kết quả có chỉ số RSME trong khoảng 1400-1600 và MAPE trong khoảng 5%-8%. Điều này cho thấy rằng phương pháp đề xuất sai số bé, hiệu suất mô hình cao. Hình 9 là sơ đồ mô hình Seq2Seg-LSTM khai báo các lớp ngõ vào và ngõ ra của bộ mã hoá (Encoder) và bộ giải mã (Decoder) kết hợp với mô hình LSTM và cuối cùng là lớp Dense đưa ra kết quả dự báo.

Bảng 2. Kết quả dự báo

Model	RMSE	MAPE (%)
ANN	1509,5	6,34
LSTM	730,87	4,96
CNN-LSTM	359,18	2,08
Wavenet	298,93	1,66
Seq2Seq -LSTM	200,15	1,03

3.2. Kết quả đồ thị dự báo


Kết quả dự báo thể hiện qua đồ thị được thể hiện trong Hình 10. Mỗi hình hiển thị dữ liệu thực tế (đường nét đứt) và dữ liệu dự báo (đường hình sao). Phương pháp được đề xuất (Seq2Seq -LSTM) cho thấy sự chính xác tốt hơn khi thể hiện trên đồ thị, kết quả dự báo và dữ liệu thực tế gần như trùng khớp nhau. Các phương pháp khác có sai số lớn, đồ thị cho thấy sai lệch giữa 2 dữ liệu lớn. Hình 11 cho thấy rằng Seq2Seq -LSTM có dự đoán hợp lý cho dữ liệu nhu cầu phụ tải hàng ngày.



Hình 9. Sơ đồ mô hình Seq2Seq-LSTM



Hình 10. Sai số huấn luyện của các mô hình



Hình 11. Biểu đồ thể hiện giá trị thực tế với phương pháp kết hợp mạng Seq2Seq-LSTM được đề xuất

4. Kết luận

Có thể thấy từ các kết quả nêu trên, khi sử dụng mô hình Seq2Seq -LSTM, hiệu năng của mạng được phát triển, với các thông số MAPE và RMSE vượt trội (bảng 2). Tuy nhiên, một

nhược điểm hiện tại của nghiên cứu đó là thuật toán khi sử dụng tốn rất nhiều tài nguyên tính toán cũng như tốn nhiều thời gian hơn các phương pháp được so sánh. Trong tương lai, chúng tôi sẽ tập trung hướng nghiên cứu vào mở rộng thuật toán để có thể cùng lúc xử lý tối ưu hoá nhiều trị số cũng như giảm thiểu sự hao tổn tài nguyên tính toán của phương pháp, trong khi vẫn giữ nguyên hoặc cải tiến hiệu năng của chương trình.

TÀI LIỆU THAM KHẢO/ REFERENCES

- [1] Y. Ghadi, N. Ahmad, M. Adnan, and M. Ali, "Load Forecasting Techniques for Power System: Research Challenges and Survey," *IEEE Access*, vol. 10, pp. 71054-71090, 2022.
- [2] M. Fan, X. Zhang, H. Yin, Y. Hu, Q. Yang, and L. Fan, "Short-term Load Forecasting for Distribution Network Using Decomposition with Ensemble prediction," *2019 Chinese Automation Congress (CAC)*, Hangzhou, China, 2019, pp. 152-157.
- [3] J. Zhu, H. Dong, W. Zheng, Y. Huang, S. Li, and L. Xi, "Review and prospect of data-driven techniques for load forecasting in integrated energy systems," *Applied Energy*, vol. 321, 2022, Art. no. 119269.
- [4] F. D. Rueda and J. D. Suárez, "Alejandro del Real Torres. Short-Term Load Forecasting Using Encoder-Decoder WaveNet: Application to the French Grid," *Energies*, vol. 14, 2021, Art. no. 2524, doi: 1996-1073/14/9/2524.
- [5] D. Niu, Y. Wu, and D. D. Wang, "Power load forecasting using support vector machine and ant colony optimization," *Expert Syst. Appl.*, vol. 37, pp. 2531-2539, 2010.
- [6] Y. -H. Guo, J. -M. Zheng, G. -F. Fan, and W.-C. Hong, "Application of the Weighted K-Nearest Neighbor Algorithm for Short-Term Load Forecasting," *Energies*, vol. 12, 2019, Art. no. 916.
- [7] Y. Dong, W.-C. Hong, and Z. Zhang, "A hybrid seasonal mechanism with a chaotic cuckoo search algorithm with a support vector regression model for electric load forecasting," *Energies*, vol. 11, 2018, Art. no. 1009.
- [8] R. Zhang, Y. Xu, Z. Y. Dong, K. Meng, and K. P. Wong, "Short-term load forecasting of Australian National Electricity Market by an ensemble model of extreme learning machine," *IET Gener. Transm. Distrib.*, vol. 7, pp. 391-397, 2013.
- [9] M. Ghofrani, A. Ghayekhloo, M. Ghayekhloo, and A. Arabali, "A hybrid short-term load forecasting with a new input selection framework," *Energy*, vol. 81, pp. 777-786, 2015.
- [10] W. Kong, Y. Jia, D. J. Hill, Z. Y. Dong, Y. Xu, and Y. Zhang, "Short-term residential load forecasting based on LSTM recurrent neural network," *IEEE Trans Smart Grid*, vol. 10, pp. 841-851, 2017.
- [11] C. Tian, C. Zhang, J. Ma, and P. Zhan, "A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network," *Energies*, vol. 11, 2018, Art. no. 3493.
- [12] L. Han, Y. Li, B. Yong, Y. Peng, Q. Zhou, and L. Shu, "Enhanced deep networks for short-term and medium-term load forecasting," *IEEE Access*, vol. 7, pp. 4045-4055, 2018.
- [13] K. Park, E. Hwang, and S. Yoon, "Hybrid load forecasting for mixed-use complex based on the characteristic load decomposition by pilot signals," *IEEE Access*, vol. 7, pp. 12297-12306, 2019.
- [14] C. Ming-Wei, C. Bo-Juen, L. Chih-Jen, "Load forecasting using support vector Machines: a study on EUNITE competition 2001," *IEEE Trans Power Syst.*, vol. 19, no. 4, 2004, Art. no. 1821e30.
- [15] J. Che and J. Wang, "Short-term load forecasting using a kernel-based support vector regression combination model," *Appl. Energy*, vol. 132, 2014, Art. no. 602e9.
- [16] W.-C. Hong, "Electric load forecasting by support vector model," *Appl. Math Model*, vol. 33, no. 5, 2009, Art. no. 2444e54.
- [17] E. Ceperic, A. Baric, and V. Ceperic, "A strategy for short-term load forecasting by support vector regression machines," *IEEE Trans Power Syst*, vol. 28, no. 4, 2013, Art. no. 4356e64.
- [18] A. Selakov, L. Milovic, S. Mellon, D. Cvijetinovic, and D. Bekut, "Hybrid PSOeSVM method for short-term load forecasting during periods with significant temperature variations in city of Burbank," *Appl. Soft Comput.*, vol. 16, 2014, Art. no. 80e8.
- [19] W. Sun, "A novel hybrid GA based SVM short term load forecasting model," *The Second International Symposium on Knowledge Acquisition and Modeling*, vol. 2, 2009, Art. no. 227e9.

-
- [20] A. Kavousi-Fard, F. Marzbani, and H. Samet, "A new hybrid modified firefly algorithm and support vector regression model for accurate short-term load forecasting," *Expert Syst. Appl.*, vol. 41, no. 13, 2014, Art. no. 6047e56.
- [21] M. Barman and N. B. D. Choudhury, "Season specific approach for short-term load forecasting based on hybrid FA-SVM and similarity concept," *Energy*, vol. 174, 2019, Art. no. 886e96.
- [22] M. Barman, S. Sutradhar, and N. B. D. Choudhury, "A regional hybrid Goa-SVM model based on similar day approach for short-term load forecasting in Assam, India," *Energy*, vol. 145, 2018, Art. no. 710e20.
- [23] H. Lu, T. Iseley, and M. Azimi, "Short-term load forecasting of urban gas using a hybrid model based on improved fruit fly optimization algorithm and support vector machine," *Energy Rep.*, vol. 5, 2019, Art. no. 666e77.
- [24] Y. Zhang, E. Muljadi, H. Jiang, J. J. Zhang, and D. W. Gao, "A short-term and high-resolution distribution system load forecasting approach using support vector regression with hybrid parameters optimization," *IEEE Transactions on Smart Grid*, vol. 9, no. 4, 2018, Art. no. 3341e50.
- [25] X. Wang and Y. Wang, "A hybrid model of EMD and PSO-SVR for short-term load forecasting in residential quarters," *Journal of Mathematical Problems in Engineering*, vol. 2016, 2016, Art. no. 9895639.
- [26] Q. Chen, X. Zhang, Y. Wu, and X. Chen, "Forecasting system based on wavelet transform and PSO-SVM. 2nd international conference on anti-counterfeiting," *2nd International Conference on Anti-counterfeiting, Security and Identification*, 2008, pp. 305-309.
- [27] S. Qiang and Y. Pu, "Short-term power load forecasting based on support vector machine and particle swarm optimization," *J. Algorithm Comput. Technol.*, vol. 13, pp. 1-8, 2018.
- [28] M. Ye and W. Sun, "Short-term load forecasting based on wavelet transform and least squares support vector machine optimized by fruit fly optimization algorithm," *Journal of Electrical and Computer Engineering*, vol. 2015, 2015, Art. no. 862185.
- [29] J.-P. Liu and C.-L. Li, "The short-term power load forecasting based on sperm whale algorithm and wavelet least square support vector machine with DWT-IR for feature selection," *Sustainability*, vol. 9, no. 7, 2017, Art. no. 1188.
- [30] L. Peng, S.-X. Lv, L. Wang, and Z. -Y. Wang, "Effective electricity load forecasting using enhanced double-reservoir echo state network," *Eng. Appl. Artif. Intell.*, vol. 99, 2021, Art. no. 104132, doi: 10.1016/j.engappai.2020.104132.
- [31] V. K. Rayi, S. Mishra, J. Naik, and P. Dash, "Adaptive vmd based optimized deep learning mixed kernel elm autoencoder for single and multistep wind power forecasting," *Energy*, vol. 244, 2022, Art. no. 122585, doi: 10.1016/j.energy.2021.122585.
- [32] Y. Dong, Z. Dong, T. Zhao, Z. Li, and Z. Ding, "Short term load forecasting with markovian switching distributed deep belief networks," *Int. J. Electr. Power & Energy Syst.*, vol. 130, 2021, Art. no. 106942. doi: 10.1016/j.ijepes.2021.106942.
- [33] T. Bashir, C. Haoyong, M. F. Tahir, and Z. Liqiang, "Short term electricity load forecasting using hybrid prophet-lstm model optimized by bpnn," *Energy Rep.*, vol. 8, 2022, pp. 1678-1686, doi: 10.1016/j.egyr.2021.12.067
- [34] I. S. Jahan, V. Snasel, and S. Misak, "Intelligent systems for power load forecasting: A study review," *Energies*, vol. 13, 2020, Art. no. 6105, doi:10.3390/en13226105.