

ỨNG DỤNG MÔ HÌNH KẾT HỢP GCN-WAVENET TRONG DỰ BÁO TẢI NGẮN HẠN CHO HỆ THỐNG LƯỚI ĐIỆN NHỎ

THE APPLICATION OF HYBRID GCN-WAVENET MODEL IN SHORT-TERM LOAD FORECASTING FOR MICROGRID SYSTEM

Nguyễn Thanh Hoan^{1*}, Lê Duy Phúc¹, Trương Việt Anh², Nguyễn Hữu Vinh¹,
Trương Đình Nhơn², Lê Kim Hùng³

¹Tổng công ty Điện lực Tp. Hồ Chí Minh

²Trường Đại học Sư phạm Kỹ thuật Tp. Hồ Chí Minh

³Trường Đại học Bách khoa - Đại học Đà Nẵng

*Tác giả liên hệ: hoanguyen1609@gmail.com

(Nhận bài: 22/8/2022; Chấp nhận đăng: 05/10/2022)

Tóm tắt - Dự báo phụ tải điện là một vấn đề quan trọng trong quản lý năng lượng lưới điện nhỏ (Microgrid - MG). Dự báo phụ tải với việc xem xét nhiều yếu tố tác động để nâng cao độ chính xác và đáp ứng cho những biến động của các yếu tố đó là vấn đề đang được quan tâm trong MG. Bài báo này đề xuất một phương pháp tích hợp mới để dự báo phụ tải ngắn hạn (STLF); Xem xét sử dụng cả chuỗi dữ liệu dài và ngắn của phụ tải và một số yếu tố như công suất đỉnh, nhiệt độ,... để dự báo nhu cầu tải hàng giờ của MG. Nhóm tác giả xem xét một mô hình dự đoán với nhiều yếu tố, nghiên cứu này đã tích hợp Mạng tích chập đồ thị (Graph Convolutional Network - GCN) vào các nút của mạng Wavenet. Mô hình dự báo được so sánh với các mô hình dự báo trước đó. Kết quả cho thấy, mô hình đề xuất của nhóm tác giả vượt trội hơn các mô hình dựa trên học sâu khác về RMSE và MAPE.

Từ khóa - Mạng tích chập đồ thị (GCN); Wavenet; phụ tải ngắn hạn (STLF); Mạng nơ ron tích chập truyền thống (CNN)

1. Giới thiệu

Hiện nay, nhu cầu phụ tải điện ngày càng gia tăng nhanh chóng, cùng với sự phát triển của lưới điện nhỏ (MG) [1]. Các mô hình MG dưới dạng lưới điện quy mô nhỏ, các mô hình kỹ thuật và công cụ tiên tiến được đề xuất nhằm vận hành tối ưu năng lượng [2]. Tầm quan trọng của việc dự báo nhu cầu phụ tải của người tiêu dùng càng được quan tâm. Bài toán dự báo phụ tải ngắn hạn (STLF) được đánh giá là phức tạp so với các bài toán khác. Kết quả dự báo ngắn hạn chính xác sẽ hỗ trợ các công tác vận hành và khai thác hệ thống điện được hiệu quả, thuận lợi. Nếu dự báo cho biết dung lượng điện được lưu trữ không đủ để hỗ trợ cho nhu cầu phụ tải trong tương lai, thì công ty điện lực có thể thông báo tình trạng này cho người dùng, qua đó giúp họ có kế hoạch giảm mức sử dụng điện, vì người dùng không chỉ muốn trả thêm tiền cho năng lượng thông thường mà còn muốn được các cơ quan chức năng có các chính sách ưu đãi.

Do tính ưu việt của học sâu, nghiên cứu này xem xét một phương pháp được đề xuất trong [3], cụ thể là một cách tiếp cận kết hợp để dự báo ngắn hạn nhu cầu tải trong một mạng lưới điện nhỏ (MG) điển hình, là sự kết hợp của phép biến đổi gói wavelet tĩnh và mạng nơ-ron truyền thẳng dựa trên giải thuật tối ưu hóa Harris Hawks. Tối ưu hóa Harris Hawks được áp dụng cho mạng nơ-ron truyền thẳng như một thuật

Abstract - Load forecasting is an important issue in Microgrid Grid (MG) energy management. Load forecasting with consideration of many influencing factors to improve the accuracy and response for the fluctuations of those factors is a concerning matter in MG. This paper proposes a new integrated method for short-term load forecasting (STLF); And consider using both long and short data series of loads and several factors such as peak load, temperature, etc. to forecast hourly load demand of MG. We consider a predictive model with many factors, in which there is an integration of the Graph Convolutional Network (GCN) into the nodes of the Wavenet network. The forecasting model is compared with the previous forecasting ones. The results show that, our proposed model is more superior than other deep learning-based ones in both RMSE and MAPE.

Key words - Graph Convolutional Network (GCN); Wavenet; Short-Term Load Forecasting (STLF); Convolutional Neural Network (CNN)

toán huấn luyện thay thế để tối ưu hóa trọng số và cơ sở của nơ-ron. Xem xét cách tiếp cận khác trong nghiên cứu [4], WaveNet sử dụng mạng nơ-ron tích chập nhân quả giãn và bỏ qua các kết nối công kích hoạt trong mô hình LSTM để tăng tốc độ hội tụ và tránh tình trạng học quá mức. Loại kiến trúc học máy mới này thể hiện những ưu điểm khác nhau liên quan đến các thuật toán thống kê khác.

Ngoài ra, nhiều phương pháp dự báo đã được các nhà nghiên cứu đề xuất để giải quyết vấn đề dự báo phụ tải. Các phương pháp tiếp cận này được phân loại là các phương pháp tiếp cận như thống kê, học tăng cường, học máy và kết hợp [5]. Trong nghiên cứu [6], một mô hình hồi quy tuyến tính đa biến đã được áp dụng để dự đoán nhu cầu tải cơ bản hàng giờ. Phương pháp thứ được các tác giả sử dụng để xác định các cấu trúc phù hợp của mô hình đề xuất. Mặt khác, cách tiếp cận về mặt thống kê để đánh giá sai số áp dụng cho lọc dữ liệu đầu vào theo mô hình phân phối chuẩn được áp dụng trong nghiên cứu [7], dữ liệu sau khi được lọc sẽ dùng để dự báo cho phụ tải lưới điện ở Tp. Hồ Chí Minh. Nghiên cứu được mở rộng với các nghiên cứu khác gồm [8]. Trong nghiên cứu [9-10], một mô hình dựa trên bộ lọc Kalman đã được đề xuất để dự báo nhu cầu phụ tải trong ngắn hạn của hộ gia đình. Các tác giả cũng so sánh hiệu suất của phương pháp đề xuất với các phương pháp cạnh tranh hiện có. Các mô hình khác như

¹ Ho Chi Minh City Power Corporation (Nguyen Thanh Hoan, Le Duy Phuc, Nguyen Huu Vinh)

² Ho Chi Minh City University of Technology and Education (Truong Viet Anh, Truong Dinh Nhon)

³ The University of Danang - University of Science and Technology (Le Kim Hung)

đường trung bình động tự hồi quy với các biến 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 được đề xuất để dự báo phụ tải ngắn hạn. Tuy nhiên, các phương pháp này không đủ khả năng để xử lý các đặc tính phi tuyến tính của tải và không chính xác. Những yếu tố này hạn chế ứng dụng của chúng và là những bất lợi lớn.

Các phương pháp tiếp cận máy học và kết hợp được các nhà nghiên cứu coi là những kỹ thuật mạnh mẽ để xử lý các đặc tính phi tuyến tính của tải. Các phương pháp tiếp cận học máy bao gồm máy hỗ trợ vectơ (SVM) và mạng nơ-ron nhân tạo (ANN). Trong các nghiên cứu [16-19], STLFL được thực hiện bằng cách áp dụng cả SVM và mô hình kết hợp dựa trên SVM được điều chỉnh theo mùa (SSA-SVM). Hiệu suất của SSA-SVM được so sánh với ANN và ANN dựa trên wavelet tích hợp theo mùa để cho thấy hiệu suất vượt trội của SSA-SVM. Tương tự, một số phương pháp tiếp cận kết hợp cũng đã được áp dụng để dự báo phụ tải. Chúng bao gồm tối ưu hóa bầy đàn (PSO) dựa trên SVM [20], thuật toán di truyền (GA) với SVM [21], thuật toán đom đóm (FFA) SVM [22,23], thuật toán tối ưu hóa châu chấu (GOA) dựa trên SVM [24], cải tiến thuật toán tối ưu hóa ruồi giấm dựa trên SVM [25], dựa trên PSO lai và thuật toán di chuyển ngang (GTA) SVM [26], phân rã chế độ thực nghiệm (EMD) [27] và biến đổi wavelet (WT) [28] với PSO-SVM. Máy hỗ trợ vectơ bình phương tối thiểu (LSSVM) là một loại SVM cải tiến cũng đã được áp dụng để dự báo phụ tải. Trong nghiên cứu [29], các tác giả sử dụng LSSVM và LSSVM với PSO cho STLFL. Các phương pháp đề xuất được so sánh với các cách tiếp cận thông thường để chứng minh tính hiệu quả của các phương pháp đề xuất. Một WT lai với tối ưu hóa ruồi giấm (FFO) và thuật toán LSSVM dựa trên cá nược đã được đề xuất trong nghiên cứu [30,31] cho STLFL. Hiệu suất vượt trội của các phương pháp được đề xuất chứng tỏ kết quả của công việc được trình bày.

Mạng tích chập đồ thị là các khối xây dựng để học dữ liệu có cấu trúc đồ thị [32]. Chúng được áp dụng rộng rãi trong các lĩnh vực như nút nhúng [33], phân loại nút [34], phân loại đồ thị [35], dự đoán liên kết [36] và phân cụm nút [37]. Có hai xu hướng chính của mạng tích chập đồ thị, phương pháp tiếp cận dựa trên quang phổ và phương pháp tiếp cận dựa trên không gian. Nhóm tác giả cũng xem xét cách tiếp cận áp dụng mô hình Graph – Wavenet vào dự báo trong tài liệu [38].

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, nhằm thực hiện đánh giá tác động của nhiều yếu tố lên phụ tải, bài báo này đề xuất một phương pháp tiếp cận STLFL cải tiến bằng cách sử dụng tích hợp GCN vào các nút của mạng Wavenet. Phương pháp đề xuất đã được so sánh với một số mô hình cạnh tranh khác chỉ thực hiện dựa trên một yếu tố là phụ tải (bao gồm: ANN, LSTM, CNN-LSTM, Wavenet), để chứng minh hiệu quả của kỹ thuật.

2. Giải thuật đề xuất

2.1. Xác định vấn đề

Trong bài báo này, mục tiêu dự báo là dự báo phụ tải theo ngày dựa vào dữ liệu phụ tải lịch sử, công suất đỉnh và nhiệt độ thuộc khu vực Tp. Hồ Chí Minh.

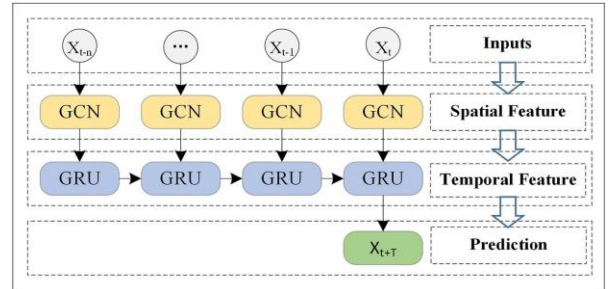
Định nghĩa 1: Mạng lưới các loại dữ liệu theo thời gian (ngày) G . Nhóm tác giả sử dụng đồ thị không trọng số $G=(V,E)$ để mô tả cấu trúc topology của mạng lưới dữ liệu theo các điểm thời gian trong năm và nhóm tác giả coi mỗi điểm thời gian là một nút. Trong đó, V là tập hợp các nút điểm thời gian, $V=\{v_1, v_2, \dots, v_N\}$, N là số nút và E là tập các cạnh. Ma trận kề A được sử dụng để biểu diễn kết nối giữa các loại dữ liệu, $A \in \mathbb{R}^{N \times N}$. Ma trận kề chỉ chứa các phần tử của 0 và 1. Phần tử là 0 nếu không có liên kết giữa các điểm thời gian và 1 biểu thị là có liên kết.

Định nghĩa 2: Ma trận đặc trưng $X^{N \times P}$. Nhóm tác giả coi thông tin dữ liệu trên mạng lưới điểm thời gian là đặc trưng thuộc tính của nút trong mạng, được biểu thị bằng $X \in \mathbb{R}^{N \times P}$. Trong đó, P đại diện cho số đặc trưng thuộc tính nút (độ dài của chuỗi thời gian lịch sử) và $X_t \in \mathbb{R}^{N \times i}$ được sử dụng để biểu thị tốc độ trên mỗi con đường tại thời điểm i . Một lần nữa, các đặc trưng thuộc tính nút có thể là bất kỳ thông tin dữ liệu nào như phụ tải, công suất đỉnh theo ngày, nhiệt độ, thời tiết.

Vì vậy, bài toán dự báo phụ tải với mô hình không gian-thời gian có thể được coi là học hàm ánh xạ f trên cơ sở cấu trúc liên kết mạng đường bộ G và ma trận đặc trưng X và sau đó tính toán thông tin phụ tải trong T thời điểm tiếp theo, như thể hiện trong phương trình (1):

$$[X_{t+1}, \dots, X_{t+T}] = f(G; (X_{t-n}, \dots, X_{t-1}, X_t)) \quad (1)$$

Trong đó, n là độ dài của chuỗi thời gian lịch sử và T là độ dài của chuỗi thời gian cần được dự đoán.



Hình 1. Mô hình tổng quan Mạng chuyển đổi đồ thị và mô hình Gated Recurrent Units

2.2. Lớp tích chập đồ thị

Có được sự phụ thuộc không gian phức tạp là một vấn đề then chốt trong dự báo phụ tải. Mạng nơ-ron tích chập truyền thống (CNN) có thể thu được các đặc trưng không gian cục bộ, nhưng nó chỉ có thể được sử dụng trong không gian Euclid. Gần đây, việc tổng hợp CNN thành mạng tích chập đồ thị (GCN), có thể xử lý dữ liệu có cấu trúc đồ thị tùy ý, đã nhận được sự quan tâm rộng rãi. Tích chập đồ thị là một tiến trình cần thiết để trích xuất các tính năng của một nút dựa trên thông tin cấu trúc của nó. Ưu điểm của phương pháp này là một lớp tổng hợp, bộ lọc của nó được nội bộ hóa trong không gian và nó hỗ trợ các đầu vào đa chiều. Gọi $\tilde{A} \in \mathbb{R}^{N \times N}$ biểu thị ma trận chuẩn hóa với các vòng lặp, $X \in \mathbb{R}^{N \times D}$ biểu thị tín hiệu đầu vào, $Z \in \mathbb{R}^{N \times M}$ biểu thị đầu ra, và $W \in \mathbb{R}^{D \times M}$ biểu thị ma trận tham số mô hình [34] và trong [38, 39] đã đề xuất một lớp tích chập khuếch tán chứng tỏ có hiệu quả trong mô hình không gian-thời gian. Họ đã mô hình hóa quá trình khuếch tán của tín hiệu đồ thị với K bước hữu hạn. Nhóm tác giả tổng quát hóa lớp tích chập

khuyến tán thành dạng công thức (2), kết quả là,


$$Z = \sum_{k=0}^K P^k XW_k \quad (2)$$

Trong đó, P_k biểu diễn chuỗi lũy thừa của ma trận chuyển tiếp. Trong trường hợp đồ thị vô hướng, $P = A/\text{rowsum}(A)$. Trong trường hợp đồ thị có hướng, quá trình khuyến tán có hai hướng, hướng tới và hướng lùi, trong đó ma trận chuyển tiếp $P_f = A/\text{rowsum}(A)$ và ma trận chuyển tiếp ngược $P_b = A^T/\text{rowsum}(A^T)$. Với ma trận chuyển tiếp tiến và lùi, lớp tích chập của đồ thị khuyến tán được viết dưới dạng

$$Z = \sum_{k=0}^K P_f^k XW_{k1} + P_b^k XW_{k2} \quad (3)$$

2.3. Lớp tích chập thời gian

Có được sự phụ thuộc vào thời gian là một vấn đề quan trọng khác trong dự báo phụ tải. Hiện tại, mô hình mạng nơ ron được sử dụng rộng rãi nhất để xử lý dữ liệu tuần tự là mạng nơ ron tuần hoàn (RNN). Tuy nhiên, do những khiếm khuyết như suy giảm gradient và bùng nổ gradient, mạng nơ ron tuần hoàn truyền thống có những hạn chế đối với dự đoán dài hạn [40]. Mô hình LSTM [41] và mô hình GRU [42] là các biến thể của mạng nơ ron tuần hoàn và đã được chứng minh là có thể giải quyết các vấn đề trên. Các nguyên tắc cơ bản của LSTM và GRU gần giống nhau [43] tất cả đều sử dụng cơ chế gated (cổng) để ghi nhớ càng nhiều thông tin lâu dài càng tốt và hiệu quả như nhau cho các nhiệm vụ khác nhau. Tuy nhiên, do cấu trúc phức tạp nên LSTM có thời gian huấn luyện lâu hơn trong khi mô hình GRU có cấu trúc tương đối đơn giản, ít tham số hơn, khả năng huấn luyện nhanh hơn. Do đó, nghiên cứu này đã chọn mô hình GRU để thu được sự phụ thuộc theo thời gian từ dữ liệu phụ tải.



Hình 2. Kiến trúc của mô hình Gated Recurrent Unit

Như trong Hình 2, h_{t-1} biểu thị trạng thái ẩn tại thời điểm $t-1$; x_t là thông tin dữ liệu vào tại thời điểm t ; r_t là cổng thiết lập lại, được sử dụng để kiểm soát mức độ bỏ qua thông tin trạng thái tại thời điểm trước đó; u_t là cổng cập nhật, được sử dụng để kiểm soát mức độ mà thông tin trạng thái tại thời điểm trước đó được đưa vào trạng thái hiện tại; c_t là nội dung bộ nhớ được lưu trữ tại thời điểm t ; và h_t là trạng thái đầu ra tại thời điểm t . GRU nhận được trạng thái phụ tải tại thời điểm t bằng cách lấy trạng thái ẩn tại thời điểm $t-1$ và thông tin phụ tải hiện tại làm đầu vào. Trong khi nắm bắt thông tin tại thời điểm hiện tại, mô hình vẫn giữ được xu hướng thay đổi của thông tin lịch sử và có khả năng nắm bắt phụ thuộc thời gian.

2.4. Mạng chuyển đổi đồ thị thời gian

Để nắm bắt đồng thời sự phụ thuộc không gian và thời gian từ dữ liệu phụ tải, nhóm tác giả đề xuất mô hình mạng tích chập đồ thị thời gian (T-GCN) dựa trên mạng tích chập

đồ thị và các đơn vị định kỳ định mức. Như trong Hình 3, bên trái là quá trình dự đoán phụ tải theo không gian-thời gian, bên phải là cấu trúc cụ thể của một ô T-GCN. Quy trình tính toán cụ thể như hình bên dưới. $f(A, X_t)$ đại diện cho quá trình tích chập đồ thị; W và b đại diện cho trọng số và độ lệch trong quá trình huấn luyện.


$$u_t = \sigma(W_u [f(A, X_t), h_{t-1}] + b_u) \quad (4)$$

$$r_t = \sigma(W_r [f(A, X_t), h_{t-1}] + b_r) \quad (5)$$

$$c_t = \tanh(W_c [f(A, X_t), (r_t * h_{t-1})] + b_c) \quad (6)$$

$$h_t = u_t * h_{t-1} + (1 - u_t) * c_t \quad (7)$$

Tóm lại, mô hình T-GCN có thể xử lý với sự phụ thuộc không gian phức tạp và thời gian biến động. Một mặt, mạng tích chập đồ thị được sử dụng để nắm bắt cấu trúc tô pô của mạng lưới đường đồ thị để thu được sự phụ thuộc vào không gian. Mặt khác, đơn vị định kỳ được sử dụng để nắm bắt sự biến đổi động của thông tin phụ tải trên các điểm thời gian trong năm để có được sự phụ thuộc theo thời gian và cuối cùng thực hiện các nhiệm vụ dự báo phụ tải.



Hình 3. Phần bên phải đại diện cho kiến trúc cụ thể của một đơn vị T-GCN và GC đại diện cho tích chập của đồ thị

2.5. Mạng Wavenet

Mô hình thay thế vì chỉ ánh xạ dữ liệu đầu vào x thành đầu ra hàm $H(x)$ là \hat{y} , ánh xạ kích bản từ khối dư trước đó $f(x, \{W_i\})$ với W_i là trọng số đã học và độ lệch so với khối dư được xem xét. Do đó, đầu ra của khối dư có thể được biểu thị bằng:

$$H(x) = f(x, \{W_i\}) + x \quad (8)$$

Hơn nữa, vì sử dụng phần dư xếp chồng lên nhau, đầu ra của phần dư có thể được biểu diễn dưới dạng:

$$x_K = x_0 + \sum_{i=1}^K f(x_{i-1}, W_{i-1}) \quad (9)$$

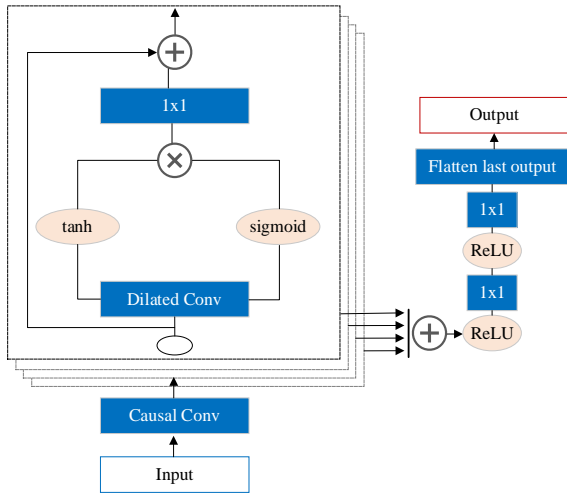
x_K là đầu ra của khối dư K , x_0 là đầu vào của mạng dư và $f(x_{i-1}, W_{i-1})$ là kết quả đầu ra và trọng số tương ứng của các khối dư trước đó.

Ngoài ra, bỏ qua kết nối và cổng kích hoạt được áp dụng cho mạng để tăng tốc độ hội tụ và tránh học quá mức. Quá trình kết nối dự phòng và bỏ qua cổng kích hoạt được thể hiện trong Hình 4.

Các cổng kích hoạt được lấy cảm hứng từ lớp LSTM, với tanh and sigmoid (σ) hoạt động như bộ lọc đã học và cổng đã học, tương ứng. Việc sử dụng các kích hoạt có kiểm soát đã được chứng minh là hoạt động tốt hơn so với việc sử dụng các kích hoạt ReLU trong dữ liệu chuỗi thời gian [4]. Đầu ra của tích chập giãn nở với các kích hoạt định mức có thể được biểu thị như sau:

$$z = \tanh(\omega_f, k * x) \odot \sigma(\omega_g, k * x) \quad (10)$$

Trong đó, w_f và w_g lần lượt là bộ lọc đã học và cổng đã học.

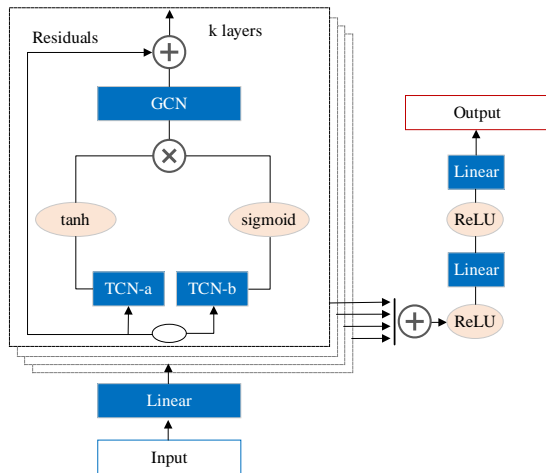


Hình 4. Tổng quan về khối tích chập và chức năng cổng kích hoạt

2.6. Tích hợp GCN-Wavenet

Dữ liệu đầu vào được xử lý qua phần trên cùng, nơi thông tin đã học được từ các bước trước đó, trong trường hợp này là các hyperparameter đã được xử lý qua thuật toán GCN. Thông tin này được đưa qua ba cổng chính, lần lượt là cổng quên, cổng đầu vào và cổng đầu ra, để quyết định trạng thái của trạng thái nạp vào hay xoá đi của trạng thái ẩn. Sau khi định cấu hình cấu trúc của Mạng GCN-Wavenet, tập hợp trọng số của GCN-Wavenet sẽ được điều chỉnh bởi một thuật toán huấn luyện để giảm thiểu lỗi. Sự đại diện của tác nhân tìm kiếm và việc lựa chọn thích hợp hàm mục tiêu là những yếu tố quan trọng.

2.6.1. Mô hình đề xuất



Hình 5. Mô hình tích hợp GCN để tính toán tối ưu hóa cho mạng GCN-Wavenet

Nhóm tác giả trình bày khung của Graph WaveNet trong Hình 5. Nó bao gồm các lớp không gian-thời gian xếp chồng lên nhau và một lớp đầu ra. Lớp không gian-thời gian được xây dựng bởi lớp tích chập đồ thị (GCN) và lớp tích chập thời gian (Gated TCN) bao gồm hai lớp chập thời gian song song (TCN-a và TCN-b). Bằng cách xếp chồng nhiều lớp không gian-thời gian, Graph WaveNet có thể xử lý các phụ thuộc không gian ở các mức thời gian khác nhau.

Ví dụ: ở lớp dưới cùng, GCN nhận thông tin thời gian ngắn hạn trong khi ở lớp trên cùng xử lý thông tin thời gian dài hạn. Các đầu vào \mathbf{h} cho một lớp tích chập đồ thị ba chiều với kích thước $[N, C, L]$, trong đó N là số nút, và C là kích thước ẩn, L là độ dài chuỗi. Nhóm tác giả áp dụng lớp tích chập đồ thị cho mỗi $\mathbf{h}[:, :, i] \in \mathbb{R}^{N \times C}$.


Mục tiêu đào tạo của Graph WaveNet, cho ra $\hat{X}^{(t+1):(t+T)}$ tổng thể mà không phải tạo ra $\hat{X}^{(t)}$ một cách đệ quy thông qua T bước, được xác định bởi:

$$L(\hat{X}^{(t+1):(t+T)}; \Theta) = \frac{1}{TND} \sum_{t=1}^{t=T} \sum_{j=1}^{j=N} \sum_{k=1}^{k=D} |\hat{X}_{jk}^{(t+i)} - X_{jk}^{(t+i)}| \quad (11)$$

Các tham số này được đưa vào cho mạng training với 70% dataset và mạng testing với 30% dataset.

2.6.2. Tập dữ liệu

Để thực hiện mô phỏng cho phương pháp được đề xuất, bộ dữ liệu được dùng là từ một khu vực phụ tải điện ở TP. Hồ Chí Minh.



Hình 6. Dữ liệu phụ tải điện và nhiệt độ trong 1 tuần ở tp. Hồ Chí Minh

Để giải quyết bài toán dự đoán phụ tải, các yếu tố ảnh hưởng đến tiêu thụ điện năng khi được đưa vào xem xét ngoài tính chu kỳ của nhu cầu còn có yếu tố về mặt thời tiết như độ bức xạ mặt trời, tốc độ và cường độ gió trong ngày; các yếu tố về thời gian như các dịp lễ hội hay chỉ các yếu tố về chỉ số kinh tế sẽ đóng vai trò quan trọng trong việc dự báo tải trọng 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. Do đó, trong nghiên cứu này thực hiện đánh giá dữ liệu theo mốc thời gian.

Dữ liệu thô trước khi được đưa vào phương pháp đề xuất sẽ được xử lý, bao gồm các bước như kiểm tra và thay thế các giá trị rỗng dựa trên thông tin về các giá trị xung quanh, tách tập dữ liệu thành phần dữ liệu huấn luyện và dữ liệu kiểm chứng cũng như chuẩn hoá dữ liệu đầu vào. Trong công việc này, các tác nhân tìm kiếm GCN được mã hóa dưới dạng vector thuộc khoảng $[-1, 1]$; quá trình chuẩn hoá dữ liệu, phương trình nền tảng được dùng là:

$$z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (12)$$

$x = x_1, \dots, x_n$ và z_i là dữ liệu chuẩn hóa thứ i .

3. Kết quả và thảo luận

3.1. Đánh giá hiệu suất mô hình

Để đánh giá hiệu suất mô hình, nhóm tác giả so sánh mô hình này với các mô hình dựa trên học sâu trước đó hoạt động rất tốt trong trường hợp STLF. Những mô hình đó được tham khảo từ [16] mô hình 1 sử dụng mạng ANN thuần túy, (Mô hình 2), sử dụng LSTM xếp chồng và [10] (Mô hình 3) kết hợp lớp CNN và LSTM; mô hình 4 sử dụng mạng Wavenet [4]. Cấu hình của mỗi mô hình so sánh

giống hệt với các bài báo đã xuất bản.

Trong giai đoạn thử nghiệm, tất cả các mô hình được đánh giá với ba số liệu khác biệt thường được sử dụng, sai số bình phương trung bình gốc (RMSE) và sai số phần trăm tuyệt đối trung bình (MAPE). MAPE giống hệt MAP nhưng nó sử dụng tỷ lệ giữa sự khác biệt với tài thực tế trong khi RMSE là một số liệu khác có xu hướng có giá trị cao hơn so với các số liệu khác. Giá trị cao hơn là kết quả của các chỉ số, hiệu suất của mô hình càng kém. Các chỉ số đó được định nghĩa như sau:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (13)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (14)$$

3.2. Dự báo phụ tải

Bảng dưới đây 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).

Bảng 1. Kết quả dự báo

Model	RMSE	MAPE (%)	Thời gian (giây)
ANN	1509,5	6,34	216
LSTM	730,87	4,96	335
CNN-LSTM	359,18	2,08	478
Wavenet	326,47	1,85	884
GCN-Wavenet	236,90	1,34	1158


Các thuật toán được thử nghiệm trên môi trường máy PC với cấu hình cơ bản (CPU 8 core, 16GB RAM, không có card đồ họa); và ngôn ngữ sử dụng là Python (với bộ thư viện tensorflow, sklearn, keras, stellargraph). Các phương pháp thực nghiệm được ghi nhận thời gian thực hiện tương ứng như ở Bảng 1.

Theo kết quả thể hiện ở Bảng 1, mô hình dự báo sử dụng ANN cho kết quả sai số cao nhất. Mô hình LSTM và dạng tích hợp CNN-LSTM cho sai số MAPE cải thiện hơn lần lượt là 4,96% và 2,08%. Kết quả khi áp dụng mô hình Wavenet có sự cải thiện rõ rệt. Cụ thể là mô hình Wavenet cơ bản thì MAPE đã giảm xuống dưới 2 là 1,85. Nhưng Wavenet cơ bản vẫn còn khá cao với RMSE là 326,47. Giải thuật đề xuất GCN-Wavenet, kết quả cải thiện rõ rệt với MAPE là 1,34% và RMSE là 236,90.


Hơn nữa, kết quả dự báo thể hiện qua đồ thị được thể hiện ở các Hình 7-11. Mỗi hình hiển thị dữ liệu thực tế (màu xanh) và dữ liệu dự báo (màu đỏ). Phương pháp được đề xuất (GCN-Wavenet) 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.

4. Kết luận


Có thể thấy, từ các kết quả nêu trên, khi sử dụng thuật toán GCN cho mạng GCN-Wavenet, hiệu năng của mạng được phát triển đáng kể, với các thông số MAPE và RMSE vượt trội (Bảng 1). Tuy nhiên, một nhược điểm hiện tại của nghiên cứu đó là thuật toán khi sử dụng tốn rất nhiều tài




Hình 7. Đồ thị thể hiện giá trị thực tế với phương pháp được đề xuất kết hợp mạng GCN-Wavenet




Hình 8. Đồ thị thể hiện giá trị thực tế với phương pháp được đề xuất kết hợp mạng Wavenet



Hình 9. Đồ thị thể hiện giá trị thực tế với phương pháp mạng Neuron nhân tạo (ANN)



Hình 10. Đồ thị thể hiện giá trị thực tế với phương pháp mạng CNN-LSTM



Hình 11. Đồ thị thể hiện giá trị thực tế và phương pháp mạng LSTM

nguyên tính toán cũng như tốn nhiều thời gian hơn các phương pháp được so sánh. Đồng thời, việc áp dụng mô hình phân tích đồ thị – thời gian với các yếu tố tác động cần chọn lọc nhiều, chưa thể hiện được hết các tương quan mong muốn. Trong tương lai, nghiên cứu 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

- [1] Yu K, Ai Q, Wang S, Ni J, Lv T, “Analysis and optimization of droop controller for microgrid system based on small-signal dynamic model”, *IEEE Transactions on Smart Grid*, 2016, 7(2), 1-11.
- [2] Tayab UB, Humayun QM, “Enhanced droop controller for operating parallel-connected distributed-generation inverters in a microgrid”, *J Renew Sustain Energy*, 2018,10(4), 045303.
- [3] Usman Bashir Tayab, Ali Zia, Fuwen Yang, Junwei Lu, “Muhammad Kashif. Short-term load forecasting for microgrid energy management system using hybrid HHO-FNN model with best-basis stationary wavelet packet transform”, *Journal Elsevier Energy*, 2020, DOI 10.1016/j.energy.2020.117857.
- [4] Fernando Dorado Rueda; Jaime Durán Suárez; Alejandro del Real Torres, “Short-Term Load Forecasting Using Encoder-Decoder WaveNet: Application to the French Grid”, *Energies*, 2021, 14, 2524. DOI: 1996-1073/14/9/2524.
- [5] L. Phúc Duy, B. Dương Minh, P. Duy Anh; N. Hoan Thanh; B. Hoài Đức; N. Tùng Minh; N. Khôi Minh; Đ. Minh Ngọc; N. Dũng Việt, “Applying statistical analysis for assessing the reliability of input data to improve the quality of short-term load forecasting for a Ho Chi Minh City distribution network”, *Science & Technology Development Journal - Engineering and Technology*, 2 (4), 2020, 223-239.
- [6] Niu, D.; Wang, Y.; Wu, D.D, “Power load forecasting using support vector machine and ant colony optimization”, *Expert Syst. Appl*, 2010, 37, 2531–2539.
- [7] Bui, Duong Minh, Le, Phuc Duy, Cao, Minh Tien, Pham, Trang Thi, Pham, Duy Anh, “Accuracy improvement of various short-term load forecasting models by a novel and unified statistical data-filtering method”, *International Journal of Green Energy*, 17 (7), 2020, 382-406.
- [8] Bui, D.M., Le, P.D., Cao, T.M. et al., “A Statistical Data-Filtering Method Proposed for Short-Term Load Forecasting Models”, *Journal of Electrical Engineering & Technology*, 2020.
- [9] Zhang, R.; Dong, Z.Y.; Xu, Y.; Meng, K.; Wong, K.P, “Short-term load forecasting of Australian National Electricity Market by an ensemble model of extreme learning machine”, *IET Gener. Transm. Distrib*, 2013, 7, 391–397.
- [10] Ghofrani, M.; Ghayekhloo, M.; Arabali, A.; Ghayekhloo, A, “A hybrid short-term load forecasting with a new input selection framework”, *Energy*, 2015, 81, 777–786.
- [11] Kong, W.; Dong, Z.Y.; Jia, Y.; Hill, D.J.; Xu, Y.; Zhang, Y. Short-term residential load forecasting based on LSTM recurrent neural network. *IEEE Trans. Smart Grid* 2017, 10, 841–851.
- [12] Park, K.; Yoon, S.; Hwang, E, “Hybrid load forecasting for mixed-use complex based on the characteristic load decomposition by pilot signals”, *IEEE Access*, 2019, 7, 12297–12306.
- [13] Tian, C.; Ma, J.; Zhang, C.; Zhan, P., “A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network”, *Energies*, 2018, 11, 3493.
- [14] Han, L.; Peng, Y.; Li, Y.; Yong, B.; Zhou, Q.; Shu, L., “Enhanced deep networks for short-term and medium-term load forecasting”, *IEEE Access*, 2018, 7, 4045–4055.
- [15] Bo-Juen C, Ming-Wei C, Chih-Jen L, “Load forecasting using support vector Machines: a study on EUNITE competition 2001”, *IEEE Trans Power Syst*, 2004, 19(4):1821e30.
- [16] Che J, Wang J., “Short-term load forecasting using a kernel-based support vector regression combination model”, *Appl Energy*, 2014;132:602e9.
- [17] Hong W-C., “Electric load forecasting by support vector model”, *Appl Math Model* 2009;33(5):2444e54.
- [18] Ceperic E, Ceperic V, Baric A, “A strategy for short-term load forecasting by support vector regression machines”, *IEEE Trans Power Syst*, 2013, 28(4): 4356e64.
- [19] Selakov A, Cvjetinovic D, Milovic L, Mellon S, Bekut D., “Hybrid PSOeSVM method for short-term load forecasting during periods with significant temperature variations in city of Burbank”, *Appl Soft Comput*, 2014, 16: 03/01/2014 80e8.
- [20] Sun W., “A novel hybrid GA based SVM short term load forecasting model”. *2009 second international symposium on knowledge acquisition and modeling*, vol. 2; 2009. p. 227e9.
- [21] Kavousi-Fard A, Samet H, Marzbani F., “A new hybrid modified firefly algorithm and support vector regression model for accurate short-term load forecasting”, *Expert Syst Appl* 2014, 41(13):6047e56. /10/01/2014.
- [22] Barman M, Dev Choudhury NB., “Season specific approach for short-term load forecasting based on hybrid FA-SVM and similarity concept”, *Energy*, 2019, 174: /05/ 01/2019 886e96.
- [23] Barman M, Dev Choudhury NB, Sutradhar S., “A regional hybrid Goa-SVM model based on similar day approach for short-term load forecasting in Assam, India”, *Energy*, 2018, 145: /02/15/2018 710e20.
- [24] Lu H, Azimi M, Iseley T., “Short-term load forecasting of urban gas using a hybrid model based on improved fruit fly optimization algorithm and support vector machine”, *Energy Rep*, 2019, 5:666e77.
- [25] Jiang H, Zhang Y, Muljadi E, Zhang JJ, Gao DW., “A short-term and high-resolution distribution system load forecasting approach using support vector regression with hybrid parameters optimization”, *IEEE Transactions on Smart Grid*, 2018, 9(4):3341e50.
- [26] Wang X, Wang Y., “A hybrid model of EMD and PSO-SVR for short-term load forecasting in residential quarters”, *Journal of Mathematical Problems in Engineering*, 2016, 2016:1e10.
- [27] Qiang S, Pu Y., “Short-term power load forecasting based on support vector machine and particle swarm optimization”, *J Algorithm Comput Technol*, 2018, 13.
- [28] Chen Q, Wu Y, Zhang X, Chen X., “Forecasting system based on wavelet transform and PSO-SVM”, *2nd international conference on anti-counterfeiting. Security and Identification*, 2008., p. 305e9. 2008.
- [29] Sun W, Ye M., “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*, 2015, 2015:1e10.
- [30] Liu J-p, Li C-l., “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*, 2017, 9(7):1188.
- [31] Santhadevi D; Janet B., “DLSTM-HHO: Enhanced Deep Learning Framework for Malware Detection at the Edge of the IoT System”, *Research Square*, 2021, DOI: 10.21203/rs.3.rs-713566/v1
- [32] Zonghan Wu, Shirui Pan, Fengwen Chen, Guodong Long, Chengqi Zhang, and Philip S Yu, “A comprehensive survey on graph neural networks”, *arXiv preprint arXiv*, 2019, 1901.00596.
- [33] Shirui Pan, Ruiqi Hu, Sai-fu Fung, Guodong Long, Jing Jiang, and Chengqi Zhang, “Learning graph embedding with adversarial training methods”, *In IJCAI*, 2018.
- [34] Thomas N Kipf and Max Welling, “Semi-supervised classification with graph convolutional networks”, *In ICLR*, 2017.
- [35] Zhitao Ying, Jiaxuan You, Christopher Morris, Xiang Ren, Will Hamilton, and Jure Leskovec, “Hierarchical graph representation learning with differentiable pooling”, *In NIPS*, 2018, 4800–4810.
- [36] Muhan Zhang and Yixin Chen, “Link prediction based on graph neural networks”, *In NIPS*, 2018, 5165–5175.
- [37] Chun Wang, Shirui Pan, Guodong Long, Xingquan Zhu, and Jing Jiang, “Mgae: Marginalized graph autoencoder for graph clustering”, *In CIKM ACM*, 2017, 889–898.
- [38] Zonghan Wu, Shirui Pan, Guodong Long, and Jing Jiang, “Graph WaveNet for Deep Spatial-Temporal Joint Modeling”, *Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence (IJCAI-19)*, 2020, 1907-1913.
- [39] Yaguang Li, Rose Yu, Cyrus Shahabi, and Yan Liu, “Diffusion convolutional recurrent neural network: Data-driven traffic forecasting”, *In ICLR*, 2018.
- [40] A. J. Smola and B. Scholkopf, “A tutorial on support vector regression”, *Statistics and Computing*, 2004, 14(3), 199–222.
- [41] H. Yin, S. C. Wong, J. Xu, and C. K. Wong, “Urban traffic flow prediction using a fuzzy-neural approach”, *Transportation Research Part C*, 2002, 10(2), 85–98.
- [42] D. Silver, A. Huang, C. J. Maddison, A. Guez, L. Sifre, G. V. D. Drissi, J. Schrittwieser, I. Antonoglou, V. Panneershelvam, and M. Lanctot, “Mastering the game of go with deep neural networks and tree search”, *Nature*, 2016, 529(7587), 484–489.
- [43] D. Silver, J. Schrittwieser, K. Simonyan, I. Antonoglou, A. Huang, A. Guez, T. Hubert, L. Baker, M. Lai, and A. Bolton, “Mastering the game of go without human knowledge”, *Nature*, 2017, 550(7676), 354–359.