

**BỘ GIÁO DỤC VÀ ĐÀO TẠO
TRƯỜNG ĐẠI HỌC SƯ PHẠM KỸ THUẬT TP.HCM**

DƯƠNG NGỌC HÙNG

DỰ BÁO PHỤ TẢI HỆ THỐNG ĐIỆN

Chuyên ngành: KỸ THUẬT ĐIỆN

Mã số chuyên ngành: 62520202

TÓM TẮT LUẬN ÁN TIẾN SĨ

TP. HỒ CHÍ MINH – NĂM 2024

**Công trình được hoàn thành tại Trường Đại học
Su phạm Kỹ thuật Tp. HCM**

Người hướng dẫn khoa học 1: PGS. TS. NGUYỄN MINH
TÂM

Người hướng dẫn khoa học 2: PGS. TS. PHAN THI
THANH BÌNH

Phản biện 1:

Phản biện 2:

Phản biện 3:

Luận án sẽ được bảo vệ trước Hội đồng đánh giá luận án
Cấp Cơ sở họp tại Trường Đại học Su phạm Kỹ thuật Tp.HCM
vào ngày tháng năm

DANH MỤC CÔNG TRÌNH ĐÃ CÔNG BỐ

1. **Hung Duong Ngoc**, Hoan Nguyen Thanh, and Tam Nguyen Minh, “Short term load forecast using deep learning,” 2019 Innov. Power Adv. Comput. Technol. i-PACT 2019, Mar. 2019, doi: 10.1109/I-PACT44901.2019.8960036.
2. **Dương Ngọc Hùng**, Nguyễn Tùng Linh, Nguyễn Thanh Hoan, Nguyễn Minh Tâm. “Mô hình kết hợp HHO-GCN-LSTM ứng dụng trong dự báo đồ thị phụ tải cho lưới điện nhỏ,” *Tạp chí Khoa học và Công nghệ Đại học Công Nghiệp Hà Nội*, vol. 58, no. 4, pp. 8-15, 2022, [Online]. Available: <https://jst-hauai.vn/media/30/uffile-upload-no-title30857.pdf>.
3. **Dương Ngọc Hùng**, Nguyễn Tùng Linh, and Nguyễn Minh Tâm, “So sánh thuật toán tối ưu của mạng wavenet trong bài toán dự báo phụ tải điện - Compare the optimal algorithms for wavenet applications in load forecasting”, *Tạp chí Khoa học và công nghệ đại học Thái Nguyên*, Tập 228, Số 07 (2023), 37-45, doi: <https://doi.org/10.34238/tnu-jst.6956>.
4. **Duong Ngoc Hung**, Nguyen Minh Tam, Nguyen Thanh Hoan. and Tran Thanh Phong. “Application of Seasonal Trend Decomposition using Loess and Long Short- Term Memory in Peak Load Forecasting Model in Tien Giang”. *Engineering, Technology & Applied Science Research*. 13, 5 (Oct. 2023), 11628–11634. DOI:<https://doi.org/10.48084/etasr.6181>.
5. **Ngoc Hung Duong**, Minh Tam Nguyen, Tung Linh Nguyen, Thanh Hoan Nguyen, and Thanh Duy Nguyen. “Applying seq2seq-lstm in a short-term load forecasting model for the power grid in Tien Giang”. *TNU Journal of Science and Technology*, 228(14), 290–301. <https://doi.org/10.34238/tnu-jst.9060>
6. **Ngoc Hung Duong**, Minh Tam Nguyen, Tung Linh Nguyen, Thanh Hoan Nguyen, and Thanh Duy Nguyen. “Application of combining data preprocessing with wavelet filtering for GCN-LSTM network with HHO optimization algorithm in load forecasting mode”. *TNU Journal of Science and Technology*, vol. 229, no. 06, pp. 160–169, 2024, <https://doi.org/10.34238/tnu-jst.9875>

MỞ ĐẦU

1. Lý do chọn đề tài

Trong thời đại cách mạng khoa học kỹ thuật 4.0, sự tăng mạnh của sản lượng điện tiêu thụ do sự phát triển của các khu công nghiệp và dân cư đặt ra một thách thức quan trọng cho việc quản lý và vận hành hệ thống điện. Dự báo phụ tải, đặc biệt là dự báo Pmax, trở thành yếu tố quyết định để tránh dư thừa hoặc thiếu hụt nguồn điện, ảnh hưởng đến an toàn cung cấp và kinh tế. Nghiên cứu này chọn lựa một mô hình kết hợp các phương pháp mới trong phương pháp học sâu để cải thiện độ chính xác của dự báo phụ tải, nhằm mục tiêu cải thiện hiệu quả và kinh tế trong vận hành hệ thống điện, đặc biệt là trong hệ thống điện Tiền Giang.

2. Đối tượng và phạm vi nghiên cứu

- Nghiên cứu lý thuyết DBPT đỉnh và ĐTPT dựa trên mạng học sâu.
- Nghiên cứu các giải thuật LSTM; CNN-LSTM; Wavenet; GCN-GRU; FF-DNN và R-DNN; Seq2Seq-LSTM. Bộ lọc wavelet tiền xử lý số liệu ngõ vào kết hợp giải thuật tối ưu hoá bộ trọng số HHO-GCN-LSTM, để dự báo công suất đỉnh Pmax và ĐTPT.
- Thực hiện thử nghiệm mô hình dự báo và đối sánh với kết quả mô hình dự báo khác cũng như các công trình đã công bố, đồng thời áp dụng DBPT đỉnh và ĐTPT cho lưới điện Tiền Giang.

3. Mục tiêu và nhiệm vụ nghiên cứu

- Nhận xét các yếu tố có liên quan đến phụ tải điện.
- Dự báo công suất đỉnh và đồ thị phụ tải 24 giờ tới, áp dụng cho khu vực cụ thể trong nghiên cứu sử dụng số liệu lưới điện thuộc khu vực Tiền Giang.
- Ứng dụng mô hình dự báo công suất đỉnh LSTM, Wavenet, CNN-LSTM, GCN-GRU.

- Ứng dụng mô hình dự báo ĐTPT: LSTM, Wavenet, CNN-LSTM, FF-DNN kết hợp R-DNN, Seq2Seq-LSTM, HHO-GCN-LSTM và áp dụng bộ lọc Wavelet vào tiền xử lý dữ liệu.

4. Phương pháp nghiên cứu

- Nghiên cứu lý thuyết: Tìm hiểu, đánh giá và kiến nghị giải thuật dự báo để giải quyết các yêu cầu của bài toán dự báo. Dùng phần mềm PyCharm, ngôn ngữ python và thực hiện dự báo công suất đỉnh và ĐTPT cho ngày tiếp theo.

5. Điểm mới của luận án

Xây dựng được các mô hình học sâu mới để dự báo công suất đỉnh: GCN-GRU (T-GCN). Mô hình dự báo, mô hình kết hợp tích chập đồ thị thời gian GCN-GRU cho kết quả dự báo tốt nhất.

Xây dựng được các mô hình khác nhau trong mạng học sâu để dự báo đồ thị phụ tải: HHO-GCN-LSTM, kiến trúc mô hình FF-DNN và R-DNN, Seq2Seq-LSTM, phép biến đổi Wavelet kết hợp với giải thuật HHO-GCN-LSTM. Nghiên cứu sinh đã đề xuất được mô hình tối ưu trong dự báo đồ thị phụ tải, sử dụng phép biến đổi Wavelet tiền xử lý dữ liệu cho đầu vào, nhằm nâng cao độ tin cậy nguồn dữ liệu đầu vào, cung cấp cho mô hình HHO-GCN-LSTM.

Kết quả phân tích dữ liệu và dự báo cho phụ tải đỉnh, đồ thị phụ tải. Áp dụng thực tế cho lưới điện Tiền Giang. Đánh giá tổng quan và có phương pháp so sánh luận chứng giữa các mô hình dự báo áp dụng cho dự báo đồ thị phụ tải, dự báo đỉnh với tập dữ liệu Tiền Giang.

6. Giá trị thực tiễn của luận án

- Kết quả dự báo phụ tải đỉnh là một yếu tố quan trọng được đặt ra trong quá trình lập kế hoạch quản lý và điều tiết nguồn điện. Sự chính xác trong

việc dự báo tải đỉnh là điều cần thiết để quản lý năng lượng điện một cách hiệu quả.

- Kết quả dự báo đồ thị phụ tải ngày chính xác trong thời gian ngắn đặc biệt quan trọng để quản lý năng lượng điện một cách hiệu quả cho lưới điện. Kết quả chính xác từ việc dự báo đồ thị tải phụ trong ngắn hạn sẽ hỗ trợ hoạt động vận hành và khai thác hệ thống điện trong khu vực một cách hiệu quả và thuận tiện.

- Bài toán bám sát với thực tiễn và mang tính ứng dụng cao vào trong công tác điều độ và vận hành HTĐ ở Việt Nam nói chung và lưới điện Tiền Giang nói riêng.

7. Bố cục của luận án

Chương 1: Tổng quan

Chương 2: Cơ sở lý thuyết

Chương 3: Dự báo phụ tải đỉnh

Chương 4: Dự báo đồ thị phụ tải

Chương 5: Kết luận

CHƯƠNG 1. TỔNG QUAN

1.1. Giới thiệu

Dự báo công suất đỉnh (Pmax) là việc dự đoán nhu cầu công suất cực đại trong một khoảng thời gian, đòi hỏi độ chính xác cao để đảm bảo kiểm soát năng lượng hiệu quả. Khác với dự báo sản lượng điện, dự báo Pmax tập trung vào thời điểm tải cao nhất nhằm tính toán dự trữ công suất và điều tiết nguồn. Đây là một vấn đề quan trọng vì nó ảnh hưởng trực tiếp đến kế hoạch sản xuất, điều tiết, dự phòng và an ninh năng lượng. Vì vậy, các phương pháp dự báo phụ tải đỉnh được giảng dạy trong các trường đại học ngành điện và liên tục nghiên cứu để phù hợp với tình hình kinh tế hiện tại.

Đồ thị phụ tải điện (ĐTPT) biểu thị sự biến thiên của công suất hoặc sản lượng điện theo thời gian, giúp điện lực theo dõi và phân tích xu hướng tiêu thụ. Dự báo ĐTPT là quá trình dự đoán nhu cầu điện năng trong tương lai, xác định mức tiêu thụ tại các thời điểm cụ thể, giúp lập kế hoạch vận hành, phân phối nguồn điện an toàn và ổn định lưới điện. Dự báo ĐTPT ngắn hạn, một bài toán phức tạp và quan trọng, hỗ trợ dự đoán lưu trữ năng lượng từ các nguồn tái tạo. Kết quả dự báo chính xác giúp điện lực quản lý, vận hành hệ thống điện (HTĐ) hiệu quả và kịp thời thông báo điều chỉnh sử dụng điện khi cần thiết.

1.2. Tình hình nghiên cứu trong nước

Trong nước, dự báo phụ tải ngắn hạn (STLF) đã thu hút sự quan tâm đáng kể từ ngành điện, các trường đại học, và viện nghiên cứu. Cơ quan điều độ quốc gia đã bắt đầu triển khai các chương trình dự báo phụ tải điện và nghiên cứu áp dụng mô hình hồi quy. Tuy nhiên, tại các công ty điện, STLF vẫn chủ yếu dựa vào phương pháp chuyên gia và kinh nghiệm của các kỹ sư điều độ, dẫn đến rủi ro và độ chính xác cao.

1.3. Tình hình nghiên cứu ngoài nước

Xét đến nghiên cứu [7, 9], Wavenet sử dụng phép tích chập nhân quả và các kết nối để tận dụng trích xuất thông tin dài. Loại ML mang lại nhiều lợi thế so với các thuật toán thống kê khác. Các nhà nghiên cứu đã đề xuất nhiều phương pháp dự báo khác nhau để giải quyết vấn đề DBPT. Một hệ thống DBPT điện kết hợp máy vectơ hỗ trợ (SVM) và tối ưu hóa đàn kiến để xử lý dữ liệu lớn và loại bỏ thông tin dư thừa. Phương pháp này cải thiện độ chính xác của STLF so với SVM đơn và mạng nơ-ron truyền ngược.

Tương tự, DBPT [24] cho MG dùng thuật toán K-NN để có độ chính xác hơn và so sánh với mô hình mạng lan truyền ngược và mô hình trung bình động tự hồi quy. Trong [25,26] bộ lọc Kalman đã được đề xuất STLF, nhằm khắc phục nhiễu loạn không xác định trong phân tuyến tính của hệ thống. Thực hiện đối chiếu hiệu suất của phương pháp này với các công trình trước đó, nhằm đánh giá tính hiệu quả và độ chính xác của mô hình đề xuất. Mô hình ARIMA[3, 30], ARMAX [27], và SARIMA[29] đã dùng tính chất đường trung bình động tự hồi quy với các yếu tố ngoại suy theo mùa trong STLF.

Các phương pháp truyền thống không thể xử lý hiệu quả các đặc tính không tuyến tính, dẫn đến độ chuẩn xác thấp và hạn chế ứng dụng. Ngược lại, các kỹ thuật học máy và mô hình kết hợp. Trong [32-35] mô hình SVM và kết hợp giữa SSA-SVM, điều chỉnh theo mùa cũng được ứng dụng trong STLF mang lại kết quả khả quan hơn.

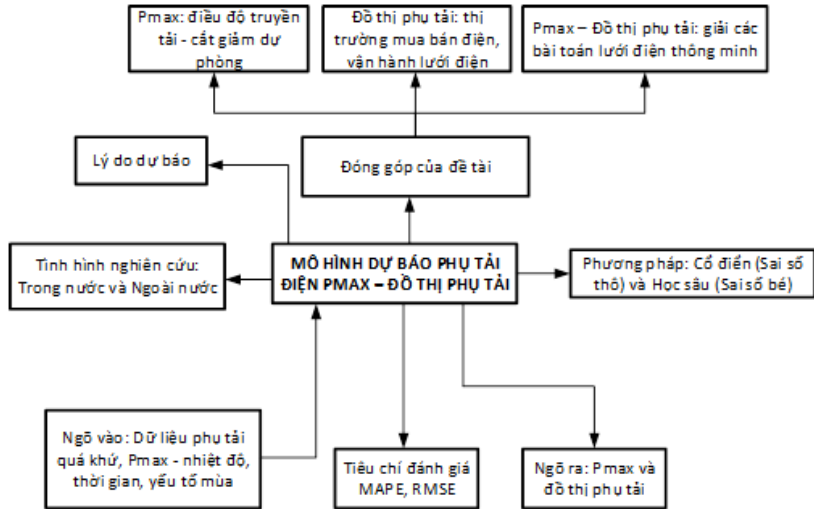
1.4. Kết luận

Các yếu tố chính ảnh hưởng đến phụ tải trong ngày là nhiệt độ môi trường và đặc thù của ngày. Dự báo công suất đỉnh Pmax và đồ thị phụ tải cần dựa vào dữ liệu quá khứ và áp dụng các thuật toán để xác định mối quan hệ giữa phụ tải và các yếu tố này. Luận án này giải quyết bài toán dự báo Pmax và ĐTPT qua các mô hình được đề xuất.

CHƯƠNG 2. CƠ SỞ LÝ THUYẾT

2.1. Tổng quan dự báo phụ tải điện

Phụ tải điện: Các thiết bị tiêu thụ điện được kết nối vào lưới điện. Mà nó tiêu thụ năng lượng điện và biến năng lượng điện thành một dạng năng lượng khác (ánh sáng, cơ năng hoặc nhiệt điện). Các thiết bị này sẽ tiêu thụ năng lượng điện dưới dạng dòng điện theo đơn vị thời gian. Đơn vị đo của PTĐ là [MW].



Hình 2.1: Sơ đồ phân tích về “Dự báo phụ tải điện”

Dự báo nhu cầu PTĐ hệ thống điện phân phối là dự báo cho toàn bộ phụ tải điện được cung cấp điện từ hệ thống điện phân phối, trừ các phụ tải có nguồn cung cấp điện riêng, là cơ sở để lập kế hoạch đầu tư phát triển lưới điện phân phối hàng năm, kế hoạch vận hành hệ thống điện phân phối, kế hoạch vận hành hệ thống điện quốc gia và kế hoạch vận hành thị trường điện, ngoài ra dự đoán khối lượng phụ tải của một hệ thống điện hoặc một khu vực cụ thể trong tương lai gần, thường trong khoảng thời gian từ một giờ đến một tuần. Quá trình này dựa trên việc phân tích các yếu tố tác động như thời tiết, ngày lễ, mô hình tiêu thụ điện và các biến số khác để ước tính mức năng lượng mà hệ thống hoặc khu

vực cần cung cấp. Nó là yếu tố tham chiếu quan trọng cho điều phối nguồn cung cấp điện, đảm bảo hoạt động hiệu quả của HTĐ.

Để thực hiện DBPT được nêu trong đề tài này, nghiên cứu sinh thực hiện các bước tìm hiểu từ tổng quan đến xác định lý do, mục tiêu, dữ liệu ngõ vào, dữ liệu ngõ ra, các phương pháp triển khai, qua đó xác định các chỉ tiêu đánh giá, kết quả và đóng góp của đề tài. Các vấn đề được thể hiện theo sơ đồ như hình 2.1.

2.2. Mô hình áp dụng phép biến đổi Wavelet vào lọc dữ liệu cho dự báo phụ tải

Mục đích của bộ lọc Wavelet: dựa vào khả năng phân tích, chuyển đổi dữ liệu từ miền thời gian sang miền tần số và ngược lại. Việc chuyển đổi sử dụng các bộ Wavelet giúp phân tích dữ liệu ở các tần số khác nhau, qua đó áp dụng các hệ số lọc lên các thành phần tần số khác nhau giúp giảm bớt nhiễu mà vẫn giữ được thông tin quan trọng, đặc trưng dữ liệu.

Để thực hiện dự báo, đề tài xem xét phương pháp để thực hiện lọc tiền xử lý dữ liệu bao gồm các bước sau:

Bước 1: dữ liệu đầu vào thô

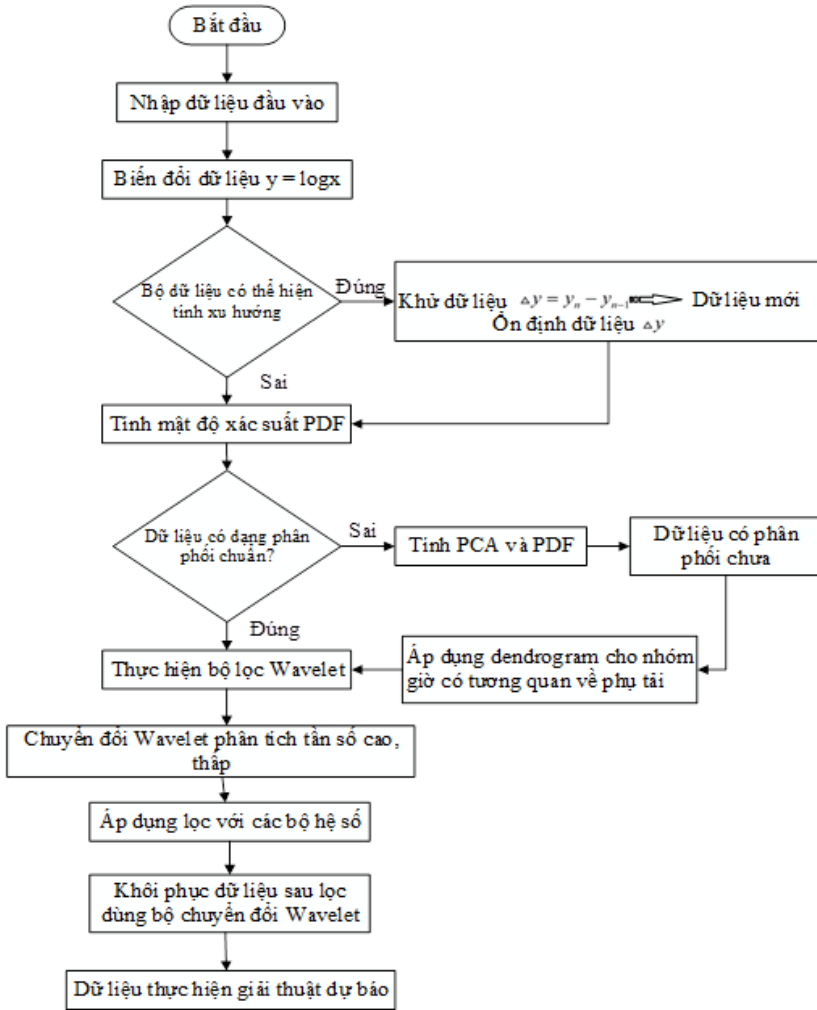
Bước 2: thực hiện biến đổi dữ liệu dùng hàm logarit $y = \log(x)$ (giảm bậc dữ liệu)

Bước 3: vẽ đồ thị kiểm tra dữ liệu có tính xu hướng không

- Nếu có thì thực hiện khử dữ liệu bằng công thức tính

$$\Delta y = y_n - y_{n-1} \Rightarrow \text{dữ liệu ổn định } \Delta y$$

Bước 4: tính mật độ xác suất PDF cho ΔY



Hình 2.2: Lưu đồ giải thuật bộ lọc Wavelet

Loại biến ngẫu nhiên quan trọng nhất là biến ngẫu nhiên Chuẩn (còn gọi là Gauss), được tham số hóa bởi trung bình (μ) và phương sai (σ^2). Thường, nó được viết là trung bình và độ lệch chuẩn (σ). Nếu X là một biến chuẩn,

ký hiệu $X \sim N(\mu, \sigma^2)$. Biến chuẩn quan trọng vì nhiều lý do: nó được tạo ra từ tổng của các biến ngẫu nhiên độc lập và do đó thường xuất hiện trong tự nhiên. Mặc dù nhiều hiện tượng trong thế giới thực không tuân theo phân phối chuẩn, nhưng các nhà khoa học dữ liệu và khoa học máy tính vẫn thường mô hình hóa chúng bằng phân phối Chuẩn. Điều này là vì quyết định mô hình hóa theo phân phối Chuẩn là phương án bảo thủ nhất để phản ánh một biến ngẫu nhiên, khi chỉ biết giá trị kỳ vọng (trung bình) và phương sai (độ phân tán).

Hàm mật độ xác suất (PDF) (Vẽ ra đồ thị, Kiểm tra đồ thị có dạng phân phối chuẩn không (Gauss)) cho một biến Chuẩn $X \sim N(\mu, \sigma^2)$:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

(2.15)

Trong đó:

- π là giá trị của Pi
- e là hằng số logarithm
- $\frac{1}{\sqrt{2\pi}}$ là hằng số chuẩn

Lưu ý: x trong số mũ của hàm PDF. Khi x bằng trung bình (μ) thì e được nâng lên lũy thừa 0 và PDF đạt giá trị cực đại.

Theo định nghĩa, một biến Chuẩn kỳ vọng có $E[X] = \mu$ và phương sai $Var(X) = \sigma^2$.

Nếu kiểm tra đồ thị dữ liệu không có dạng phân phối Chuẩn, tính PCA. Phân tích thành phần chính PCA là một kỹ thuật thống kê được sử dụng để giảm số chiều của tập dữ liệu lớn bằng cách biến đổi nó thành một tập hợp các biến

mới, được gọi là các thành phần chính. Các thành phần chính này được sắp xếp sao cho thành phần đầu tiên có phương sai lớn nhất, thành phần thứ hai có phương sai lớn thứ hai, và cứ thế tiếp tục.

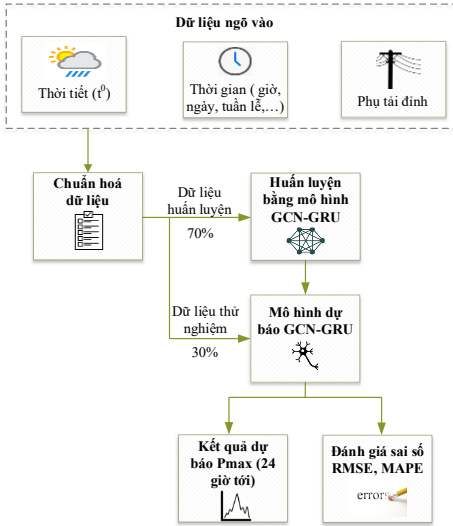
2.3. Kết luận

Chương 2 của nghiên cứu đã tập trung vào việc trình bày một loạt các khía cạnh quan trọng trong lĩnh vực DBPT điện. Giới thiệu khái quát DBPT, tầm quan trọng và đóng góp của nó trong HTĐ.

Nghiên cứu đi sâu vào các mô hình mạng học sâu CNN, Wavenet, LSTM, GRU cho việc xử lý chuỗi thời gian, khả năng xử lý phụ thuộc dài hạn và lưu trữ thông tin lâu dài GCN có khả năng trích xuất đặc tính đồ thị từ nguồn dữ liệu, đặc biệt hiệu quả cho xử lý loại dữ liệu có cấu trúc dạng lưới. Ngoài ra, thuật toán chim ưng HHO nhằm rút ngắn thời gian quá trình cập nhật trọng số, trong quá trình huấn luyện mạng.


CHƯƠNG 3. DỰ BÁO PHỤ TẢI ĐỈNH

3.1. Mô hình dự báo Pmax



Phân tích các yếu tố có tác động đến dự báo phụ tải đỉnh cho thấy số liệu phụ tải đỉnh quá khứ, nhiệt độ và yếu tố mùa đều có tác động đáng kể. Tại miền Nam nói chung hay khu vực Tiền Giang nói riêng, có hai mùa rõ rệt là mùa mưa và mùa khô (thể hiện trong bảng 3.3). Dựa trên tình hình nghiên cứu trong và ngoài nước về dự báo công suất đỉnh cùng với lý thuyết mạng học sâu, nghiên cứu sinh đã đề xuất mô hình kết hợp GCN-GRU (T-GCN).

Hình 3.1: Sơ đồ tổng quan mô hình dự báo Pmax



Hình 3.4: Quy trình thực hiện dữ liệu cho dự báo phụ tải đỉnh

3.2. Phương pháp luận dự báo Pmax theo GCN-GRU

Qua đánh giá các nghiên cứu gần đây, mô hình GCN-GRU thể hiện sự liên kết giữa các yếu tố dữ liệu theo không gian và thời gian. Các yếu tố ảnh hưởng vào dữ liệu phụ tải đỉnh như Phụ tải đỉnh (Pmax), nhiệt độ (T^0) được thiết lập dưới dạng ma trận theo mô hình GCN để khai thác khả năng phân tích sự phụ thuộc các yếu tố tại 3 điểm phụ tải đỉnh trong ngày dựa trên cách phân tích

không gian. Đồng thời, GRU được sử dụng để kết hợp các yếu tố thời gian t theo ngày. Các bộ dữ liệu N ngày được đưa vào N bộ GCN, sau đó được đưa vào chuỗi mô hình với N GRU. Dựa vào đó, mô hình khai thác được các ưu điểm từ khả năng nhớ ngắn hạn của phương pháp GRU cho ngõ ra dự báo phụ tải đỉnh cuối cùng. Kết quả dự báo phụ tải đỉnh áp dụng mô hình GCN-GRU cho thấy khả thi khi xem xét khai thác đồng thời nhiều yếu tố ảnh hưởng (theo không gian) và đặc trưng của dữ liệu dạng chuỗi (theo thời gian).

3.2.1. Phân tích dữ liệu phụ thuộc vào không gian

Theo Định nghĩa biểu diễn dữ liệu theo không gian và Định nghĩa biểu diễn chuỗi dữ liệu theo thời gian trong mục lý thuyết mô hình GCN:

$$X_t = G = (V, E) \quad (3.1)$$

Trong đó: G là ma trận thể hiện quan hệ Pmax - Công suất đỉnh hoặc A - sản lượng và nhiệt độ T tại thời điểm t , thể hiện tính chất không gian

$$G_t = \begin{bmatrix} P_{\max 1} & T_1^0 \\ P_{\max 2} & T_2^0 \\ P_{\max 3} & T_3^0 \end{bmatrix} \quad (3.2)$$

$E = (P_{\max} - T^0)$ - tập hợp các cạnh tại 1 thời điểm, ví dụ: $P_{\max 1} - T_1^0$

$V = \{E_1, E_2, E_3\}$ tập hợp các nút thời gian thuộc G_t , ngày thứ t .

3.2.2. Phân tích dữ liệu phụ thuộc theo thời gian

Theo Theo Định nghĩa biểu diễn dữ liệu theo không gian và Định nghĩa biểu diễn chuỗi dữ liệu theo thời gian trong mục lý thuyết mô hình GCN:

$$X^{NxP} = \{X_t\}_{Dngay} = \{G(V, E)\}_{Dngay} \quad (3.3)$$

Trong đó: X là ma trận đặc trưng, P là đại diện số đặc điểm.

3.2.3. Mô hình dự báo dùng GCN-GRU

Theo phân tích trong mục 2.8 và 3.2.2, nghiên cứu sinh đề xuất mô hình GCN-GRU để dự báo công suất đỉnh. Mô hình này sử dụng GCN để trích xuất các đặc điểm từ dữ liệu có tính chất đồ thị (mạng) và GRU để xử lý sự phụ thuộc theo thời gian. Các bước thực hiện như sau:

- Bước 1: Trích xuất đặc trưng từ đồ thị GCN: sử dụng GCN để trích xuất đặc trưng từ đồ thị (để nhận ra mẫu tổng thể). Điều này có thể bao gồm việc áp dụng lớp GCN để lấy thông tin đặc trưng từ các đỉnh và cạnh của đồ thị.


- Bước 2: Chuẩn bị dữ liệu đầu vào cho GRU: biểu diễn đặc trưng từ GCN dưới dạng chuỗi thời gian để có thể đưa vào mô hình GRU. Mỗi thời điểm trong chuỗi thời gian tương ứng với một bước thời gian.

- Bước 3: Xây dựng mô hình GRU: Tạo một mô hình GRU, trong đó đầu vào sẽ là chuỗi thời gian từ bước 2. Các tham số của GRU có thể cần được điều chỉnh tùy thuộc vào nhiệm vụ cụ thể (dùng để trích xuất mối quan hệ giữa các bước thời gian).

- Bước 4: Huấn luyện mô hình: sử dụng dữ liệu huấn luyện để điều chỉnh các trọng số của mô hình GRU thông qua quá trình lan truyền ngược và tối ưu hoá.

- Bước 5: Kiểm tra và đánh giá: sử dụng dữ liệu kiểm thử để đánh giá hiệu suất của mô hình và điều chỉnh nếu cần thiết. Quá trình này có thể đòi hỏi sự điều chỉnh và tối ưu hoá chi tiết. Tùy thuộc vào bài toán cụ thể, đồng thời có thể cần thêm các lớp hoặc cải thiện khác để đáp ứng yêu cầu của mô hình thời gian.

Hình 3.5 minh họa, bên trái là mô hình GCN và bên phải là cấu trúc cụ thể của một ô GRU. Nhờ vào công thức từ (2.9) đến (2.12) GCN-GRU trích xuất được các đặc điểm không gian và thời gian của nguồn dữ liệu, phục vụ việc giải quyết được dự báo phụ tải đỉnh.



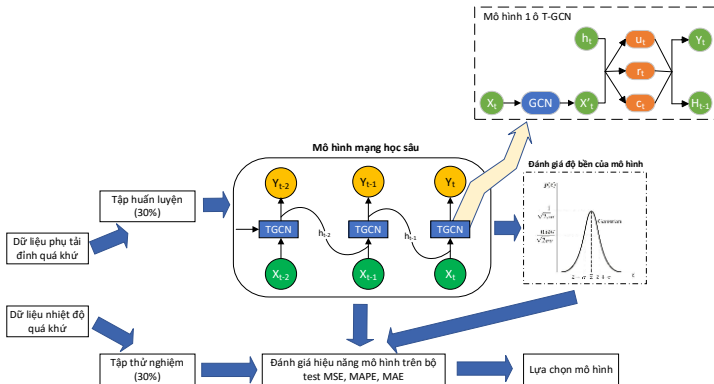
Hình 3.5: Kiến trúc chi tiết của một đơn vị GCN-GRU [54]

3.3. Áp dụng dự báo Pmax Tiền Giang

3.3.1. Dữ liệu phụ tải đỉnh Tiền Giang

Mô hình dự báo Pmax được đề xuất T-GCN, sử dụng các bộ dữ liệu sau làm đầu vào: dữ liệu trong quá khứ. Dữ liệu thu thập được 24 giá trị Pmax tương ứng với nhiệt độ Tmax mỗi ngày, trong tập dữ liệu có 1434 ngày tương ứng 34416 mẫu Pmax quá khứ từ 01/01/2020 đến 04/12/2023. Dự báo công suất đỉnh ngày tới mô hình kết hợp GCN – LSTM, bộ dữ liệu thu thập từ Công ty điện lực Tiền Giang. Dữ liệu tải đỉnh trong Phụ lục 3.

3.3.2. Mô hình dự báo GCN-GRU cho Tiền Giang



Hình 3.6: Mô hình giải thuật đề xuất dự báo phụ tải đỉnh GCN-GRU

Quá trình thực hiện DBPT đỉnh, nguồn dữ liệu lịch sử được thu thập, chuẩn bị do dự báo bao gồm: dữ liệu Pmax, dữ liệu nhiệt độ tại Tiền Giang. Dữ liệu đầu vào được chuẩn hóa thành khoảng $[-1,1]$. Ngoài ra, 70% dữ liệu được sử dụng làm tập huấn luyện và 30% còn lại được sử dụng làm tập thử nghiệm chạy dự báo. Dữ liệu được xử lý vào ma trận đầu vào gồm dữ liệu Pmax, T^0 quá khứ và code thời gian. Tập dữ liệu huấn luyện được đưa vào mạng học sâu T-GCN để huấn luyện. Ngõ ra của các lớp mạng T-GCN, và lớp cuối cùng kết hợp sử dụng hàm Gaussian để tạo nhiễu. Kết quả được kết hợp dùng hàm Gaussian được so sánh với dữ liệu sau khi huấn luyện từ mạng T-GCN bằng các chỉ tiêu đánh giá RMSE và MAPE, mục đích nhằm đánh giá tính hiệu quả của mô hình dự báo dưới tác động nhiễu Gaussian. Kết quả sau khi huấn luyện sẽ đánh giá chọn mô hình dự báo cho sai số tốt nhất Kết quả dự báo phụ tải đỉnh.

Bảng 3.1: Kết quả dự báo theo các phương pháp khác nhau


Model	RMSE	MAPE (%)
LSTM	20,4574	4,6159
CNN-LSTM	55,344	4,0972
Wavenet	5,2657	0,8749
GCN-GRU	20,86917	0,2983

Theo kết quả so sánh tổng thể giữa các phương pháp dự báo, phương pháp LSTM cho kết quả sai số ở mức cao nhất (RMSE: 20,4574, MAPE: 4,6159), và phương pháp CNN-LSTM có sự cải thiện ở MAPE nhưng RMSE tăng cao là 55,344. Phương pháp Wavenet cho kết quả tốt với RMSE: 5,2657 và MAPE: 0,8749. Đối với phương pháp được đề xuất – GCN-GRU cho kết quả MAPE tốt vượt bậc: 0,2983. Nhưng GCN-GRU còn cho RMSE chưa tốt ở 20,86917. Khác biệt lớn giữa RMSE và MAPE được đánh giá do còn tồn tại các điểm sai số lớn ở phương pháp GCN-GRU nên khi tính MAPE theo phần trăm đạt rất tốt, nhưng

chưa tương quan với kết quả RMSE. Đây là điểm cần xem xét để phát triển nghiên cứu, cải thiện các mô hình dự báo sau này.

3.3.3. Đánh giá kết quả dự báo

Qua hình 3.10, cho thấy phương pháp GCN-GRU cho kết quả dự báo bám tốt hơn Wavenet với dữ liệu thực tế, tuy nhiên có tồn tại một số điểm đỉnh tại các ngày (24/01/2023 và 25/01/2023) có sai số nhiều hơn so với thực tế. Do đó,



kết quả tính ở bảng 3.4 thể hiện sai số MAPE: 0,2983 là rất tốt, nhưng RMSE: 20,86917. Qua đó, điều này cần xem xét để cải thiện trong các nghiên cứu sau này.

Hình 3.10: Kết quả dự báo phụ tải đỉnh dùng GCN-GRU

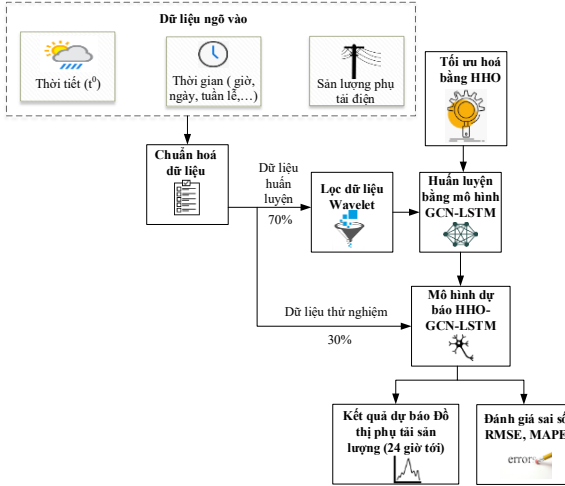
3.4. Kết luận

Qua bảng kết quả 3.5, mô hình kiến nghị GCN-GRU đạt RMSE =20,86917, MAPE=0,2983% hiệu suất của mô hình vượt trội có độ chính xác cao so với các mô hình khác: LSTM, CNN-LSTM hoặc Wavenet. Kết quả này minh họa mô hình GCN-GRU, độ chính xác được cải thiện đáng kể, về MAPE và RMSE. Nó thực hiện dự báo công suất đỉnh tốt hơn so với LSTM, CNN-LSTM, Wavenet. Ngoài ra, GCN-GRU có hiệu năng vượt trội so với mô hình trong nghiên cứu [56]. Tuy nhiên, sự khác biệt không nhiều so với Wavenet. Trong mô hình lai GCN-GRU, trong đó LSTM được chuyển đổi thành GRU để xử lý chuỗi thời gian bộ nhớ dài, tương tự như Wavenet sự khác biệt là ở chỗ đó GCN được kết hợp thay vì Wavelet nhằm nâng cao độ tin cậy của nguồn dữ liệu quá khứ thu thập được. Bài toán dự báo công suất đỉnh Pmax đã được nghiên cứu, thực hiện và công bố trong công trình số [4].

CHƯƠNG 4. DỰ BÁO ĐỒ THỊ PHỤ TẢI


4.1. Mô hình dự báo đồ thị phụ tải

xDự báo đồ thị phụ tải điện ngày được quan tâm nhiều trong lĩnh vực vận hành và giám sát năng lượng của MG nói chung hay lưới điện Tiền Giang nói riêng. Mô hình đề nghị trong luận án kết hợp Wavelet-HHO-GCN-LSTM. Dựa



vào các yếu tố ảnh hưởng đến phụ tải điện lưới điện Tiền Giang đã được phân tích trong mục 1.4.3, phương pháp đề xuất sử dụng chuỗi dữ liệu phụ tải điện, cụ thể là sản lượng điện (MWh) và nhiệt độ theo thời gian và ảnh hưởng của yếu tố của yếu tố mùa.

Hình 4.1: Sơ đồ tổng quan mô hình dự báo đồ thị phụ tải



Hình 4.2: Phương pháp sử dụng dữ liệu cho dự báo đồ thị phụ tải

Dựa vào phương trình (2.13) – mục 2.6 và phương trình (2.19) - mục 2.8 của luận án, nghiên cứu sinh đã thực hiện triển khai bài toán dự báo đồ thị phụ tải X_{t+T} , cho ngày tới, trong mô hình dự báo này, $T=7$ – dự báo cho 7 ngày tiếp theo. Phương trình (2.19) được viết lại:

$$[X_{t+1}, \dots, X_{t+T}] = f(G, (X'_{t-n}, \dots, X'_{t-1})) \quad (4.1)$$

Trong đó: - $X_t = G_t = \begin{bmatrix} A_1 & T_1^0 \\ \vdots & \vdots \\ A_{24} & T_{24}^0 \end{bmatrix}$ là ma trận dữ liệu phụ tải (A - sản lượng)

và nhiệt độ T^0 của thời điểm hiện tại t

- $X'_t = f(X_t)$: dữ liệu sau khi xử lý lọc dùng Bộ lọc Wavelet

- $X'_{t-n}, \dots, X'_{t-1}$: bộ dữ liệu phụ tải, T^0 của n ngày trước thời điểm hiện tại t

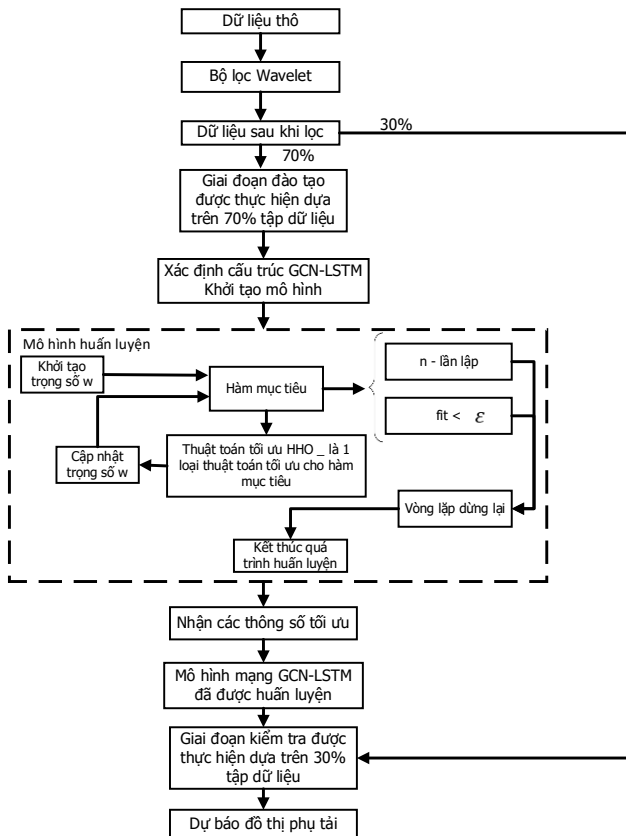
- n : số ngày dữ liệu lịch sử được chọn dùng cho dự báo 7 ngày tiếp theo, thường dùng 1-3 tháng.

4.2. Mô hình đề xuất dự báo đô thị phụ tải sử dụng mô hình bộ lọc Wavelet - HHO-GCN-LSTM

Dữ liệu thô bao gồm dữ liệu sản lượng điện được thu thập tại Tiền Giang sau khi qua bộ lọc và dữ liệu nhiệt độ được đưa vào mạng huấn luyện sử dụng mô hình HHO-GCN-LSTM. Qua hình 4.13, để thực hiện giai đoạn huấn luyện mạng theo mô hình HHO-GCN-LSTM cụ thể theo các bước thực hiện sau:

Bước 1: Trước tiên, chương trình thực hiện khởi tạo cấu trúc các lớp mạng GCN-LSTM. Mỗi phần tử GCN-LSTM được xây dựng như hình 4.13:

Bước 2: Quá trình huấn luyện được thực hiện các vòng lặp tính toán để cập nhật các tham số của mô hình mạng GCN-LSTM. Trong nghiên cứu này, việc tính toán để đạt hội tụ các tham số trong mỗi lần lặp được sử dụng HHO. Quá trình này được thể hiện tượng trưng trong biểu đồ hình 4.13.



Bước 3: Mô hình mạng GCN-LSTM đã được huấn luyện sẽ được đưa vào dữ liệu để thực hiện dự báo thực nghiệm. Kết quả dự báo đồ thị phụ tải được tính toán sai số với dữ liệu thực tế theo các phương trình RMSE và MAPE để đánh giá mô hình.

Hình 4.13: Giải thuật đề xuất tích hợp Bộ lọc Wavelet – HHO – GCN – LSTM

Tương tự cho quá trình thực nghiệm đã thực hiện ở DBPT đình, quá trình thực hiện dự báo đồ thị phụ tải cũng thực hiện đánh giá mô hình dự báo với các khoản thời gian theo ngày, cuối tuần, tuần, Nguồn dữ liệu lịch sử được thu thập, chuẩn bị do dự báo bao gồm: dữ liệu sản lượng điện, dữ liệu nhiệt độ tại Tiền Giang. Kết quả được đánh giá lại theo các bảng dưới đây theo % sai số từng thời điểm. Qua đó có thể đánh giá chính xác hiệu quả của mô hình dự báo trên thực tế.

Kết quả chạy dự báo cho dữ liệu đầu vào kể từ ngày 06/02/2022 Chủ nhật đến hết ngày 20/06/2022 Thứ 2: 135 ngày.

4.3. Kết quả dự báo đồ thị phụ tải

4.3.1. Kết quả dự báo tổng thể

Bảng 4.7: Kết quả dự báo

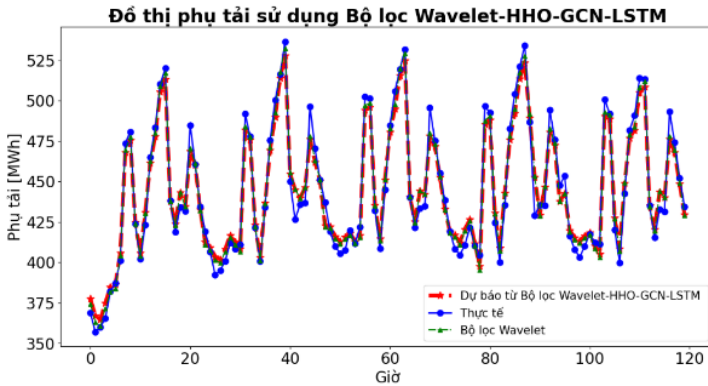
Model	RMSE	MAPE (%)
LSTM	20,4574	4,6159
CNN-LSTM	29,8788	3,75
Wavenet	5,2657	0,8749
FF-DNN và R-DNN	3,087	0,56
Seq2Seq -LSTM	3,527	0,55
HHO-GCN-LSTM	2,521	0,58
Bộ lọc Wavelet-HHO-GCN-LSTM (T7)	3,2636	0,73
Bộ lọc Wavelet -HHO-GCN-LSTM (CN)	4,56	1,21
Bộ lọc Wavelet -HHO-GCN-LSTM (T2-T6)	2,834	0,54

Theo kết quả thể hiện ở Bảng 4.7, mô hình dự báo sử dụng LSTM cho kết quả sai số cao nhất (RMSE: 20,4574; MAPE: 4,6159). Mô hình CNN-LSTM có sai số MAPE đạt giá trị là 3,75%, nhưng RMSE không tốt 29,8788%. Đề tài cũng thực hiện dự báo đồ thị phụ tải sử dụng mô hình FF-DNN và R-DNN trên dữ liệu Tiền Giang để đánh giá sai số so với các phương pháp dự báo được đề xuất sau đó. Kết quả cho thấy mô hình FF-DNN, R-DNN cũng cho kết quả tốt với MAPE 1,52% mặc dù dữ liệu thử nghiệm không đầy đủ như khi thử nghiệm trên bộ dữ liệu Tiền Giang.

Kết quả mô hình dự báo Wavenet có MAPE là 0,8749% nhỏ hơn 1%, kết quả tốt. Tuy nhiên, giá trị RMSE là 5,2657 đại lượng này còn khá cao. Phương pháp đề xuất HHO-GCN kết quả vượt trội với MAPE là 0,58% và RMSE là 2,521. Đồng thời, mô hình sử dụng bộ lọc Wavelet cho mô hình HHO-GCN-LSTM ở kết quả Ngày trong tuần (T2-T6), T7, CN thì sai số ngày T7, CN không

tốt, còn Ngày trong tuần cho thấy cải thiện hơn. Vì vậy, bộ lọc Wavelet là cần thiết để đánh giá dữ liệu ngõ vào.

4.3.2. Phân tích kết quả dự báo



Hình 4.22: Kết quả dự báo Bộ lọc Wavelet-HHO-GCN-LSTM từ ngày 06/03/2023 – 10/03/2023

Dựa vào hình 4.20, có thể thấy rằng phương pháp HHO-GCN-LSTM cho kết quả dự báo khá tốt khi áp dụng vào dữ liệu thực tế. Tuy nhiên, xuất hiện các sai số lớn hơn tại đáy phụ tải của các ngày, dẫn đến việc tính toán kết quả RMSE với mức độ sai lệch cao hơn.

Đồ thị phụ tải dự báo bằng phương pháp Wavelet-HHO-GCN-LSTM có sai số lớn hơn phương pháp HHO-GCN-LSTM tại các điểm đỉnh của đồ thị, qua đó cho thấy, việc áp dụng lọc nhiễu dữ liệu Wavelet sẽ tác động nhiều đến các điểm đỉnh theo nguyên tắc áp dụng hệ số lọc lên miền tần số. Do đó, khi áp dụng lọc Wavelet cần thử nghiệm bộ hệ số phù hợp với đặc trưng của dữ liệu để đảm bảo kết quả cải thiện hơn so với không lọc.

4.4. Kết luận

Trong chương này, nghiên cứu sinh đã thực hiện ba mô hình kiến nghị cho bài toán dự báo phụ tải và áp dụng số liệu của lưới điện Tiền Giang. Mô hình

một FF-DNN và R-DNN, mô hình 2 là Seq2Seq-LSTM được thực hiện đánh giá với dữ liệu Tiền Giang kết quả dự báo khá tốt. Mô hình 3 được kiến nghị trong nghiên cứu là mô hình kết hợp Wavelet-HHO-GCN-LSTM. Mô hình này được thiết kế tận dụng lợi thế việc lọc nhiễu và phân tích tín hiệu với Wavelet cho các nhóm dữ liệu được phân tách bằng các phương pháp đánh giá PCA, Dendrogram và tính mật độ phân bố xác suất. cùng với khả năng tối ưu hoá của thuật toán HHO là một hàm tối ưu bộ trọng số cho các lớp mạng GCN-LSTM, tính ưu việt của GCN-LSTM trong việc mô hình hoá dữ liệu phức tạp.

Trong phần kết quả thực nghiệm, so sánh chi tiết giữa mô hình đề xuất và các mô hình dự báo đồ thị phụ tải điện khác. Kết quả cho thấy mô hình Wavelet-HHO-GCN-LSTM vượt trội hơn hẳn về độ chính xác, với giá trị RMSE và MAPE thấp hơn đáng kể ở đại lượng MAPE và RMSE (Bảng 4.5) so với các mô hình được so sánh: LSTM, CNN-LSTM và Wavenet, chứng tỏ khả năng dự báo tải điện một cách chính xác và đáng tin cậy.

Tuy nhiên, mạng HHO-GCN-LSTM khi sử dụng tốn rất cần nhiều tài nguyên khi tính toán, cũng như mất nhiều thời gian trong quá trình dự báo so với các mô hình khác. Nghiên cứu sinh sẽ tiếp tục tập trung hướng nghiên cứu vào việc khai thác thuật toán một cách tốt hơn, mà không cần tốn nhiều tài nguyên tính toán. Bài toán dự báo ĐTPT đã được công bố trong công trình số [1-3], và [5-6]

CHƯƠNG 5. KẾT LUẬN

5.1. Kết luận

Luận án “Dự báo phụ tải hệ thống điện” đề nghị xây dựng hai bài toán áp dụng như sau:

Bài toán 1: Xây dựng mô hình mạng kết hợp mạng tích chập đồ thị với đơn vị cổng hồi quy GCN-GRU, dự báo công suất đỉnh cho khu vực lưới điện tỉnh Tiền Giang. Ngõ vào của mô hình dự báo là Pmax/giờ, nhiệt độ/giờ và nhân tố tác động theo mùa. Kết quả của giải thuật có sai số bé, cụ thể RMSE = 20,86917, MAPE = 0,2983 và được đối sánh thể hiện trong bảng 5.1.

Bảng 5.1: Kết quả dự báo

Model	RMSE	MAPE (%)
LSTM	20,4574	4,6159
CNN-LSTM	55,344	4,0972
Wavenet	5,2657	0,8749
GCN-GRU	20,86917	0,2983

Ngoài ra tác giả đã so sánh kết quả dự báo với số liệu thực tế được thể hiện trong bảng 5.1.

Kết quả dự báo của mô hình cũng được so sánh với công trình nghiên cứu [57]. Mô hình này đạt được sai số nhỏ hơn so với nghiên cứu được tham khảo. Và đã được công bố trong công trình.

Sau khi huấn luyện mô hình trên dữ liệu đào tạo và sử dụng một hàm đánh giá, mô hình đã đạt được kết quả vượt trội với RMSE = 241,17 và MAPE (%) = 1,32 so với các mô hình khác như LSTM, GCN-LSTM, hoặc Wavenet. Điều này chứng tỏ mô hình GCN-GRU có hiệu suất cao và đáp ứng được yêu cầu.

Bài toán 2: Xây dựng mô hình mạng kết hợp, bộ lọc Wavelet – thuật toán tối ưu HHO - mạng tích chập đồ thị với bộ nhớ dài hạn/ngắn hạn Bộ lọc

Wavelet-HHO-GCN-LSTM, dự báo ĐTPT cho khu vực tỉnh Tiền Giang. Ngõ vào của mô hình dự báo là sản lượng/giờ, nhiệt độ/giờ và yếu tố liên quan đến mùa. Kết quả của giải thuật có sai số bé, cụ thể RMSE =2,834, MAPE =0,54 được so sánh với các công trình khác thể hiện trong bảng 5.2.

Bảng 5.2: Kết quả dự báo

Model	RMSE	MAPE (%)
LSTM	20,4574	4,6159
CNN-LSTM	29,8788	3,75
Wavenet	5,2657	0,8749
FF-DNN và R-DNN	3,087	0,56
Seq2Seq -LSTM	3,527	0,55
HHO-GCN-LSTM	2,521	0,58
Bộ lọc Wavelet-HHO-GCN-LSTM (T7)	3,2636	0,73
Bộ lọc Wavelet -HHO-GCN-LSTM (CN)	4,56	1,21
Bộ lọc Wavelet -HHO-GCN-LSTM (T2-T6)	2,834	0,54

Kết quả dự báo của mô hình cũng được so sánh với công trình nghiên cứu đã liên quan [43] theo mục 4.5.3.

Đề tài đã so sánh mô hình Wavelet-HHO-GCN-LSTM với các mô hình học sâu trước đây như FF-DNN, R-DNN và Seq2Seq-LSTM trên dữ liệu Tiền Giang. Mô hình này kết hợp các ưu điểm của phương pháp lọc nhiễu bằng Wavelet, tối ưu hóa bằng HHO, và khả năng mô hình hóa dữ liệu phức tạp của GCN-LSTM. Kết quả thực nghiệm cho thấy Wavelet-HHO-GCN-LSTM có độ chính xác vượt trội, với RMSE và MAPE thấp hơn đáng kể so với các mô hình như LSTM, CNN-LSTM và Wavenet, khẳng định khả năng dự báo phụ tải điện chính xác và đáng tin cậy.

5.2. Hướng nghiên cứu phát triển tiếp theo

Luận án đã phân tích các yếu tố ảnh hưởng đến phụ tải và đã xây dựng được 2 mô hình dự báo công suất đỉnh và dự báo đồ thị phụ tải ngày. Tuy nhiên, luận án vẫn còn một số hạn chế, chưa xem xét các điều kiện ngõ vào: độ ẩm và bức xạ mặt trời, dân số, GDP, các thông tin phụ tải: trời, dung, cảm, lưới điện phân phối, định mức. Sự điều chỉnh các tham số: con người/người vận hành, chu kỳ, độ hội tụ, sai số, trọng số, theo kinh nghiệm. Ngoài ra dữ liệu tải biến động, thay đổi lưới điện phân phối cũng chưa được xem xét.

Trong đề tài, bài toán dự báo đồ thị phụ tải được áp dụng mô hình (Wavelet lọc áp dụng cho HHO-GCN-LSTM) cải tiến bổ sung so với mô hình áp dụng cho dự báo công suất đỉnh trước đó (GCN-LSTM). Cũng như, mô hình Wavelet lọc áp dụng cho HHO-GCN-LSTM cải thiện hơn so với phương pháp học sâu (FF-DNN và R-DNN) – mô hình này cần dữ liệu đầy đủ phức tạp hơn so với đề xuất hiện nay. Mô hình Wavelet lọc áp dụng cho HHO-GCN-LSTM cũng cho kết quả sai sót khả quan hơn mô hình Seq2Seq-LSTM, nhưng cũng nên xem xét ưu điểm của các mô hình khác nhau, như mô hình Seq2Seq-LSTM sẽ tốt với các nguồn dữ liệu bất định. Để đánh giá mức độ hiệu quả của mô hình Wavelet - HHO-GCN-LSTM đối với dự báo công suất đỉnh, nghiên cứu sinh xem xét phân tích trong nghiên cứu tiếp theo. Về lý thuyết, phương pháp lọc Wavelet có tác động điều chỉnh nhiều đối với các điểm dữ liệu công suất đỉnh, qua đó có thể làm tăng hay giảm sai số dự báo đáng kể. Cũng như thuật toán tối ưu hóa HHO vào mô hình dự báo công suất đỉnh cần được đánh giá tiếp theo.

Hướng đến áp dụng các mô hình dự báo vào phục vụ thực tế cho lưới điện Tiền Giang.

TÀI LIỆU THAM KHẢO

- [1] N. Amral, C. S. Ozveren, D. King; “Short term load forecasting using Multiple Linear Regression”. *2007 42nd International Universities Power Engineering Conference*, pp. 1192-1198, 07 March 2008, doi: 10.1109/UPEC.2007.4469121.
- [2] Khorsheed, E. “Energy load forecasting: Bayesian and exponential smoothing hybrid methodology”, *International Journal of Energy Sector Management*, vol. 15 No. 2, pp. 294-308, 2021, doi: 10.1108/ijesm-06-2019-0005.
- [3] Khashei M, Bijari M. “A novel hybridization of artificial neural networks and ARIMA models for time series forecasting,” *Applied Soft Computing*, vol. 11, no. 2, pp. 2664-2675, March 2011, doi: 10.1016/j.asoc.2010.10.015.
- [4] John O’Donnell, Wencong Su. “A Stochastic Load Forecasting Approach to Prevent Transformer Failures and Power Quality Issues Amid the Evolving Electrical Demands Facing Utilities,” *Energies*, vol. 16, no. 21, p. 7251, 2023, <https://doi.org/10.3390/en16217251>.
- [5] 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,” *Energy*, vol. 203, p. 117857, 15 July 2020, doi: 10.1016/j.energy.2020.117857.
- [6] 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* vol. 7, no. 2, pp. 1-11, 2016, doi: 10.1109/TSG.2015.2501316.
- [7] Borovykh, A.; Bohte, S.; Oosterlee, C. “Conditional Time Series Forecasting with Convolutional Neural Networks,”. arXiv 2018 , arXiv:1703.04691.
- [8] Hung Duong-Ngoc, Hoan Nguyen-Thanh, Tam Nguyen-Minh. “Short term load forecast using deep learning,”. *2019 Innovations in Power and Advanced Computing Technologies (i-PACT)*, pp. 1-5, 2019, doi: 10.1109/i-PACT44901.2019.8960036.
- [9] Fernando Dorado Rueda; Jaime Durán Suárez; Alejandro del Real Torres. “Short-Term Load Forecasting Using Encoder-Decoder Wave Net: Application to the French Grid,” *Energies*, vol. 14, no. 9, p. 2524, 2021, doi: 1996-1073/14/9/2524.

- [10] Bộ Công thương, *Thông tư số 19/2017/TT-BCT Quy định nội dung, phương pháp và trình tự nghiên cứu phụ tải điện*, Hà Nội, 2017.
- [11] Lê Duy Phúc, Bùi Minh Dương, Phạm Anh Duy, Nguyễn Thanh Hoan, ..., “Ứng dụng phân tích thống kê để đánh giá độ tin cậy của nguồn dữ liệu đầu vào nhằm nâng cao chất lượng dự báo phụ tải điện ngắn hạn trên lưới điện TP.HCM,” *Tạp chí Phát triển Khoa học và Công nghệ – Kỹ thuật và Công nghệ Đại học Quốc gia Tp HCM*, vol. 2, no. 4, pp. 223-239, 2019, doi: 10.32508/stdjet.v2i4.614.
- [12] Bùi Công Cường, Nguyễn Doãn Phước, “Hệ mờ, mạng nơron và ứng dụng,” *Nhà xuất bản khoa học và kỹ thuật*, 2001.
- [13] Bùi Xuân Toại, Trương Gia Việt (Biên dịch), “Trí tuệ nhân tạo – Các cấu trúc và chiến lược giải quyết vấn đề,” *Nhà xuất bản Thống kê*, 2000.
- [14] Đặng Ngọc Dinh, Nguyễn Hữu Khải, Trần Bách, “Hệ thống điện”, *Nhà xuất bản Đại học và trung học chuyên nghiệp*, tập 1, 1981.
- [15] Nguyễn Đình Thúc, “Lập trình tiến hóa,” *Nhà xuất bản Giáo dục* 2002.
- [16] Chu, Nghĩa, “Ứng dụng mạng Nơron nhân tạo dự báo phụ tải ngắn hạn Hệ thống điện miền Bắc,” *Luận văn thạc sỹ khoa học ngành Công nghệ thông tin, Trường Đại học Công nghệ, Đại học Quốc gia Hà Nội*, 2007.
- [17] Phạm Anh Cường, Phan Văn Hiền, “Ứng dụng mạng nơron để dự báo phụ tải điện tỉnh Gia Lai,” *Tạp chí phát triển KH&CN*, số 2, tr. 43, 2011.
- [18] Trần Thị Hoàng Oanh, Trần Hoàng Lĩnh, Đồng Sĩ Thiên Châu, Nguyễn Kỳ Tài, “Ứng dụng mạng nơron song tuyến trong bài toán dự báo phụ tải điện”, *Tạp chí phát triển KH&CN*, vol. 10, no. 11, 2007.
- [19] Trần Kỳ Phúc, “Nghiên cứu ứng dụng mạng Nơ ron nhân tạo trong dự báo ngắn hạn phụ tải điện (giai đoạn I),” *Viện năng lượng*, 2006.
- [20] Trần Kỳ Phúc, Monique Polit, Nguyễn Tiên Phong, Lê Thị Thanh Hà, “Mạng Nơ ron – dự báo phụ tải điện ngắn hạn ứng dụng tại Hà Nội, ảnh hưởng của các thông số thời tiết,” *Tạp chí Tự động hoá ngày nay*, 2006.
- [21] Đinh Văn Nhượng, trường Đại học Sao Đỏ, “Một số ứng dụng mạng nơron xây dựng mô hình nhận dạng và dự báo”, *NXB Khoa học và kỹ thuật*, 2012.
- [22] Tài liệu báo cáo kết quả thực hiện kế hoạch năm 2021 và năm 2022, Công ty Điện lực Tiền Giang 2022.
- [23] Niu, D.; Wang, Y.; Wu, D.D. “Power load forecasting using support vector machine and ant colony optimization,” *Expert Systems with Applications*, vol. 37, no. 3, pp. 2531–2539, 15 March 2010, doi: 10.1016/j.eswa.2009.08.019.
- [24] Fan, G.-F.; Guo, Y.-H.; Zheng, J.-M.; Hong, W.-C. “Application of the Weighted K-Nearest Neighbor Algorithm for Short-Term Load

- Forecasting,” *Energies*, vol. 12, no. 5, p. 916, 2019, doi: 10.3390/en12050916.
- [25] Zhao, Feng; Su, Hongsheng. “Short-Term Load Forecasting Using Kalman Filter and Elman Neural Network,” *2nd IEEE Conference on Industrial Electronics and Applications*, pp. 1043–1047, 2007, doi:10.1109/ICIEA.2007.4318567
- [26] Dixit, M. M., and P. R. Chavan. “Short-term load forecasting using Kalman filter,” *Int. Res. J. Eng. Technol*, pp. 3458-3461, 2017.
- [27] EunJi Ahn, Jin Hur, “A short-term forecasting of wind power outputs using the enhanced wavelet transform and arimax techniques,”. *Renewable Energy*, Volume 212, 2023, pp. 394-402, <https://doi.org/10.1016/j.renene.2023.05.048>.
- [28] 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 Transactions on Smart Grid*, vol. 10, no. 1, pp. 841–851, 2017, doi: 10.1109/TSG.2017.2753802.
- [29] 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*, vol. 11, no. 12, p. 3493, 2018, doi: 10.3390/en11123493.
- [30] L. Alhmoud and Q. Nawafleh, “Short-Term Load Forecasting for Jordan Power System Based on NARX-ELMAN Neural Network and ARMA Model,” in *IEEE Canadian Journal of Electrical and Computer Engineering*, vol. 44, no. 3, pp. 356-363, 2021, doi: 10.1109/ICJECE.2021.3076124
- [31] Park, K.; Yoon, S.; Hwang, E. “Hybrid load forecasting for mixed-use complex based on the characteristic load decomposition by pilot signals,” *IEEE Access*, vol. 7, pp. 12297–12306, 2019, doi: 10.1109/ACCESS.2019.2892475.
- [32] 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*, vol. 19, no. 4, pp. 1821-1830, 2004, doi: 10.1109/TPWRS.2004.835679.
- [33] Che J, Wang J. “Short-term load forecasting using a kernel-based support vector regression combination model,” *Appl Energy*, vol. 132, pp. 602-609, 2014, doi: 10.1016/j.apenergy.2014.07.064.
- [34] Hong W-C. “Electric load forecasting by support vector model,” *Appl Math Model*, vol. 33, no. 5, pp. 2444-2454, doi: 10.1016/j.apm.2008.07.010.

- [35] Ceperic E, Ceperic V, Baric A. "A strategy for short-term load forecasting by support vector regression machines," *IEEE Trans Power Syst*; vol. 28, no. 4, pp. 4356-4364, 2013 doi: 10.1109/ICMLC.2005.1527695.
- [36] Selakov A, Cvijetinovic 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*, vol. 16: pp. 80-88, 2013, doi: 10.1016/j.asoc.2013.12.001.
- [37] Sun W. "A novel hybrid GA based SVM short term load forecasting model," *2009 second international symposium on knowledge acquisition and modeling*, vol. 2 p. 227-229, 2009, doi: 10.1109/KAM.2009.31.
- [38] 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*, vol. 41, no. 13, pp. 6047-6056, 2014, doi: 10.1016/j.eswa.2014.03.053.
- [39] Barman M, Dev Choudhury NB. "Season specific approach for short-term load forecasting based on hybrid FA-SVM and similarity concept," *Energy*, vol. 174, pp. 886-896, 2019, doi: 10.1016/j.energy.2019.03.010.
- [40] 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*, vol 145, pp. 710-720, 2018, doi: 10.1016/j.energy.2017.12.156.
- [41] 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 Reports*, vol. 5, pp. 666-677, 2019, doi: 10.1016/j.egy.2019.06.003.
- [42] 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*; vol. 9, no. 4, pp. 3341-3350, 2018, doi: 10.1109/TSG.2016.2628061.
- [43] 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*, pp. 1-10, 2016, doi: 10.1155/2016/9895639.
- [44] Chen Q, Wu Y, Zhang X, Chen X. "Forecasting system based on wavelet transform and PSO-SVM," *2008 2nd international conference on anti-counterfeiting. Security and Identification*, pp. 305-309, 2008, doi: 10.1109/IWASID.2008.4688383.

- [45] Qiang S, Pu Y. “Short-term power load forecasting based on support vector machine and particle swarm optimization,” *J Algorithm Comput Technol*, pp. 1-8, 2018, doi: 10.1177/1748301818797061.
- [46] 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*, pp. 1-10, 2015, doi: 10.1155/2015/862185.
- [47] 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*, vol. 9, no. 7, p. 1188, 2017, doi: 10.3390/su9071188.
- [48] O. Yu. Maryasin; A. I. Lukashov. “Analyzing and Forecasting Peak Load Hours,” *2021 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*, pp. 25-30, 2021, doi: 10.1109/ICIEAM51226.2021.9446369.
- [49] Anindita Satria Surya; Musa Partahi Marbun; K.G.H. Mangunkusumo; Muhammad Ridwan. “Peak Load Forecasting Using Long-Short Term Memory: Case Study of Jawa-Madura-Bali System,” *2021 International Conference on Technology and Policy in Energy and Electric Power (ICT-PEP)*, 29-30 September 2021, doi: 10.1109/ICT-PEP53949.2021.9600945.
- [50] Octavia D.P. Yuan; A.N. Afandi; Hari Putranto. “Demand Forecasting Considering Actual Peak Load Periods Using Artificial Neural Network,” *2018 5th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, pp. 198-203, 2018, doi: 10.1109/EECSI.2018.8752740.
- [51] Quyết định Ban hành quy trình dự báo nhu cầu phụ tải điện quốc gia.
- [52] Liao, Zhifang; Pan, Haihui; Fan, Xiaoping; Zhang, Yan; Kuang, Li. “Multiple Wavelet Convolutional Neural Network for Short-term Load Forecasting,” *IEEE Internet of Things Journal*, vol. 8, no. 12, pp. 9730–9739, 2020, doi: 10.1109/JIOT.2020.3026733.
- [53] Sheikh, S. K., & Unde, M. G. “Short-Term Load Forecasting Using Ann Technique,” *Article in International Journal of Engineering Sciences and Emerging Technologies*, vol. 1, no. 2, pp. 97-107, 2012, https://doi.org/10.7323/ijeset/v1_i2_12.
- [54] Zhao, Ling; Song, Yujiao; Zhang, Chao; Liu, Yu; Wang, Pu; Lin, Tao; Deng, Min; Li, Haifeng. “T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 9, pp. 3848-3858, 2019, doi: 10.1109/TITS.2019.2935152.

- [55] Heidari, Ali Asghar; Mirjalili, Seyedali; Faris, Hossam; Aljarah, Ibrahim; Mafarja, Majdi; Chen, Huiling. “Harris hawks optimization: Algorithm and applications,” *Future Generation Computer Systems*, vol. 97, pp. 849-872 2019, doi: 10.1016/j.future.2019.02.028.
- [56] Yuan, Octavia D.P.; Afandi, A.N.; Putranto, Hari. “Power Demand Forecasting Considering Actual Peak Load Periods Using Artificial Neural Network,” *Proceeding of EECESI 2018*, Malang - Indonesia, pp. 198–203, 2018, doi: 10.1109/EECSI.2018.8752740.
- [57] Santhadevi D; Janet B. “DLSTM-HHO: Enhanced Deep Learning Framework for Malware Detection at the Edge of the Iot System,” *Research Square*, doi: 10.21203/rs.3.rs-713566/v1.
- [58] T. N. Kipf and M. Welling, “Semi-supervised classification with graph convolutional networks,” *Published as a conference paper at ICLR 2017*, Sep. 2016, <https://doi.org/10.48550/arXiv.1609.02907>.
- [59] J. Bruna, W. Zaremba, A. Szlam, and Y. Lecun, “Spectral networks and locally connected networks on graphs,” *Computer Science*, Dec. 2013.
- [60] Y. Bengio, P. Simard, and P. Frasconi, “Learning long-term dependencies with gradient descent is difficult,” *IEEE Trans Neural Networks*, vol. 5, no. 2, pp. 157–166, 2002, doi: 10.1109/72.279181.
- [61] J. S. Sepp Hochreiter, “Long short-term memory,” *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Dec. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [62] K. Cho, B. V. Merriënboer, D. Bahdanau, and Y. Bengio, “On the properties of neural machine translation: Encoder-decoder approaches,” *Computer Science*, Sep. 2014.
- [63] Chung, C. Gulcehre, K. H. Cho, and Y. Bengio, “Empirical evaluation of gated recurrent neural networks on sequence modeling,” *Eprint Arxiv*, Dec. 2014.
- [64] Y. Li, R. Yu, C. Shahabi, and Y. Liu, “Graph convolutional recurrent neural network: Data-driven traffic forecasting,” Jul. 2017.
- [65] Abadi, M.; Barham, P.; Chen, J.; Chen, Z.; Davis, A.; Dean, J.; Devin, M.; Ghemawat, S.; Irving, G.; Isard, M. “Tensorflow: A system for large-scale machine learning,” *In Proceedings of the 12th Symposium on Operating Systems Design and Implementation, Savannah*, pp. 265–283, 2–4 November 2016.
- [66] Schlüter, S. ; Deuschle, C., & Schlüter, S. “Using Wavelets for Time Series Forecasting-Does it Pay Off?,” no. 4, 2010, <http://hdl.handle.net/10419/36698>.

- [67] H. Duong-Ngoc, H. Nguyen-Thanh, and T. Nguyen-Minh, “Short term load forecast using deep learning,” *2019 Innov. Power Adv. Comput. Technol. i-PACT*, pp. 1-5, 2019, doi: 10.1109/I-PACT44901.2019.8960036.
- [68] Dương Ngọc Hùng, Nguyễn Tùng Linh, Nguyễn Thanh Hoan, Nguyễn Minh Tâm. “Mô hình kết hợp HHO-GCN-LSTM ứng dụng trong dự báo đồ thị phụ tải cho lưới điện nhỏ,” *Tạp chí Khoa học và Công nghệ Đại học Công nghiệp Hà Nội*, vol. 58, no. 4, pp. 8-15, 2022, [Online]. Available: <https://jst-hau1.vn/media/30/uffile-upload-no-title30857.pdf>.
- [69] D. N. Hùng, N. T. Linh, and N. M. Tâm, “So sánh thuật toán tối ưu của mạng wavenet trong bài toán dự báo phụ tải điện - Compare the optimal algorithms for wavenet applications in load forecasting,” *Tạp chí Khoa học và công nghệ đại học Thái Nguyên*, vol. 228, no. 07, pp. 37-45, 2023, doi: 10.34238/TNU-JST.6956.
- [70] Duong, N.-H., Nguyen, M.-T., Nguyen, T.-H. and Tran, T.-P. 2023. “Application of Seasonal Trend Decomposition using Loess and Long Short-Term Memory in Peak Load Forecasting Model in Tien Giang,” *Engineering, Technology & Applied Science Research*, vol. 13, no. 5, pp. 11628-11634, 2023, doi: 10.48084/etasr.6181.
- [71] Ngọc Hùng, D., Minh Tâm, N., Tùng Linh, N., Thanh Hoan, N., Thanh Duy, N., Thanh Hoan, N., & Thanh Duy, N. (n.d.). “Applying seq2seq-lstm in a short-term load forecasting model for the power grid in Tien Giang”. *TNU Journal of Science and Technology*, vol. 228, no. 14, pp. 290–301, 2023, doi: <https://doi.org/10.34238/tnu-jst.9060>.
- [72] Đặng Văn Liệt, Dương Hiếu Đầu và Đỗ Đức Cường. “Áp dụng phép biến đổi wavelet 2-D Đề tách trường dị thường từ”.