

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 2025**

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

vào ngày tháng năm

- [41] 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* 2017, Vol. 9, Page 1188, vol. 9, no. 7, p. 1188, Jul. 2017, doi: 10.3390/SU9071188.
- [42] Q. Chen, Y. Wu, X. Zhang, and X. Chen, “Forecasting system based on Wavelet Transform and PSO-SVM,” *International Conference on Anti-counterfeiting, Security, and Identification*, pp. 305–309, 2008, doi: 10.1109/IWASID.2008.4688383.
- [43] A. A. Heidari, S. Mirjalili, H. Faris, I. Aljarah, M. Mafarja, and H. Chen, “Harris hawks optimization: Algorithm and applications,” *Future Generation Computer Systems*, vol. 97, pp. 849–872, Aug. 2019, doi: 10.1016/J.FUTURE.2019.02.028.
- [44] D. Ngoc Hung, N. Tung Linh, and N. Minh Tam, “So sánh thuật toán tối ưu của mạng Wavenet trong bài toán dự báo phụ tải điện,” *TNU Journal of Science and Technology*, vol. 228, no. 07, pp. 37–45, Apr. 2023, doi: 10.34238/TNU-JST.6956.
- [45] L. Zhao *et al.*, “T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 9, pp. 3848–3858, Sep. 2020, doi: 10.1109/TITS.2019.2935152.
- [46] T. N. Kipf and M. Welling, “Semi-Supervised Classification with Graph Convolutional Networks,” *5th International Conference on Learning Representations, ICLR 2017 - Conference Track Proceedings*, Sep. 2016, Accessed: Oct. 18, 2024. [Online]. Available: <https://arxiv.org/abs/1609.02907v4>
- [47] A. Borovykh, S. Bohte, and C. W. Oosterlee, “Conditional Time Series Forecasting with Convolutional Neural Networks,” *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 10614 LNCS, pp. 729–730, Mar. 2017, Accessed: Oct. 18, 2024. [Online]. Available: <https://arxiv.org/abs/1703.04691v5>

- [26] C. Ghenai, O. A. A. Al-Mufti, O. A. M. Al-Isawi, L. H. L. Amirah, and A. Merabet, “Short-term building electrical load forecasting using adaptive neuro-fuzzy inference system (ANFIS),” *Journal of Building Engineering*, vol. 52, p. 104323, Jul. 2022, doi: 10.1016/J.JOBE.2022.104323.
- [27] M. Abumohsen, A. Y. Owda, and M. Owda, “Electrical Load Forecasting Using LSTM, GRU, and RNN Algorithms,” *Energies 2023, Vol. 16, Page 2283*, vol. 16, no. 5, p. 2283, Feb. 2023, doi: 10.3390/EN16052283.
- [28] Công ty điện lực Tiền Giang, “BÁO CÁO KẾT QUẢ THỰC HIỆN KẾ HOẠCH NĂM 2022 MỤC TIÊU, NHIỆM VỤ KẾ HOẠCH NĂM 2023,” 2023.
- [29] M. Jacob, C. Neves, and D. Vukadinović Greetham, “Short Term Load Forecasting,” pp. 15–37, 2020, doi: 10.1007/978-3-030-28669-9\_2.
- [30] L. Friedrich and A. Afshari, “Short-term Forecasting of the Abu Dhabi Electricity Load Using Multiple Weather Variables,” *Energy Procedia*, vol. 75, pp. 3014–3026, Aug. 2015, doi: 10.1016/J.EGYPRO.2015.07.616.
- [31] Z. Tan, J. Zhang, Y. He, Y. Zhang, G. Xiong, and Y. Liu, “Short-Term Load Forecasting Based on Integration of SVR and Stacking,” *IEEE Access*, vol. 8, pp. 227719–227728, 2020, doi: 10.1109/ACCESS.2020.3041779.
- [32] D. P. Yuan Octavia, A. N. Afandi, and H. Putranto, “Power demand forecasting considering actual peak load periods using artificial neural network,” *International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, vol. 2018-October, pp. 198–203, Oct. 2018, doi: 10.1109/EECSI.2018.8752740.
- [33] M. A. Hammad, B. Jereb, B. Rosi, and D. Dragan, “Methods and Models for Electric Load Forecasting: A Comprehensive Review,” *Logistics & Sustainable Transport*, vol. 11, no. 1, pp. 51–76, Feb. 2020, doi: 10.2478/jlst-2020-0004.
- [34] F. M. Butt, L. Hussain, A. Mahmood, and K. J. Lone, “Artificial Intelligence based accurately load forecasting system to forecast short and medium-term load demands,” *Mathematical Biosciences and Engineering*, vol. 18, no. 1, pp. 400–425, 2021, doi: 10.3934/MBE.2021022.
- [35] Y. Tian, A. Alhammadi, A. Quran, and A. S. Ali, “A Novel Approach to Wavenet Architecture for RF Signal Separation with Learnable Dilation and Data Augmentation,” *2024 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops, ICASSPW 2024 - Proceedings*, pp. 79–80, 2024, doi: 10.1109/ICASSPW62465.2024.10627586.
- [36] A. van den Oord *et al.*, “WaveNet: A Generative Model for Raw Audio,” Sep. 2016, doi: 10.48550/arXiv.1609.03499.
- [37] F. D. Rueda, J. D. Suárez, and A. D. R. Torres, “Short-Term Load Forecasting Using Encoder-Decoder WaveNet: Application to the French Grid,” *Energies 2021, Vol. 14, Page 2524*, vol. 14, no. 9, p. 2524, Apr. 2021, doi: 10.3390/EN14092524.
- [38] C. Cai, Y. Li, Z. Su, T. Zhu, and Y. He, “Short-Term Electrical Load Forecasting Based on VMD and GRU-TCN Hybrid Network,” *Applied Sciences 2022, Vol. 12, Page 6647*, vol. 12, no. 13, p. 6647, Jun. 2022, doi: 10.3390/APP12136647.
- [39] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, “Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling,” Dec. 2014, Accessed: Oct. 18, 2024. [Online]. Available: <https://arxiv.org/abs/1412.3555v1>
- [40] A. K. Ghanavati, A. Afsharnejad, N. Vafamand, M. M. Arefi, M. S. Javadi, and J. P. S. Catalao, “Short-term load forecasting based on wavelet approach,” *SEST 2020 - 3rd International Conference on Smart Energy Systems and Technologies*, Sep. 2020, doi: 10.1109/SEST48500.2020.9203539.

## DANH MỤC CÔNG TRÌNH ĐÃ CÔNG BỐ

### Tạp chí quốc tế:

- [1] **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*. 13, 5 (Oct. 2023), 11628–11634. DOI:<https://doi.org/10.48084/etasr.6181>.

### Tạp chí trong nước:

- [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] **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, Tập 228, Số 07 (2023)*, doi: 10.34238/TNU-JST.6956.
- [4] **Ngọc Hùng, D.**, Minh Tam, N., Tung Linh, N., Thanh Hoan, N., & Thanh Duy, N. “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>
- [5] **Ngọc Hùng, D.**, Minh Tam, N., Tung Linh, N., Thanh Hoan, N., & Thanh Duy, N. “Application of combining data preprocessing with wavetet 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>

### Hội nghị quốc tế:

- [6] **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 2019*, Mar. 2019, doi: 10.1109/I-PACT44901.2019.8960036.

## MỞ ĐẦU

### 1. Lý do chọn đề tài

Điện là nguồn năng lượng rất linh hoạt và phổ biến, đóng vai trò không thể thiếu trong đời sống hàng ngày cũng như trong công nghiệp. Ngoài ra điện năng đáp ứng tốt và hiệu quả hơn các yêu cầu của xã hội, đồng thời thân thiện với môi trường so với các nguồn năng lượng truyền thống khác như dầu mỏ, than đá, và nguồn khí đốt tự nhiên [1]. Tầm quan trọng của điện đã gia tăng đáng kể trong những năm gần đây, dự báo điện năng đã trở thành một bài toán cần thiết trong nghiên cứu [2]. Tuy nhiên, điện là một sản phẩm đặc biệt có nhiều đặc điểm khác biệt so với những loại sản phẩm khác. Điện năng không thể dự trữ được với dung lượng lớn, nó phải được sản xuất tức thời khi có nhu cầu sử dụng. Ngoài ra nhu cầu điện năng sẽ tăng mạnh trên cả nước nói chung do dân số gia tăng cùng với sự phát triển của các khu công nghiệp, sử dụng các thiết bị công suất lớn. Các yếu tố này dẫn đến việc quản lý hệ thống điện gặp nhiều khó khăn [3]. Do đó cần phải dự báo phụ tải trước để ngành điện lực lập kế hoạch sản xuất điện năng.

Dự báo phụ tải điện là quá trình quan trọng, then chốt trong việc lập kế hoạch và vận hành hệ thống điện, dự báo tải điện gắn liền với phát triển kinh tế, an ninh quốc gia, và hoạt động hằng ngày của toàn xã hội [4]. Vì vậy sai số của mô hình dự báo có tầm quan trọng đối với việc xây dựng kế hoạch vận hành, công suất nguồn phát, và quản lý HTĐ. Độ chính xác của mô hình giúp tiết kiệm được chi phí vận hành, bảo trì, và quyết định đúng đắn cho sự phát triển các cơ sở sản xuất, truyền tải và phân phối trong thời gian tới. Tuy nhiên, độ chính xác của mô hình dự báo phụ tải bị ảnh hưởng nhiều yếu tố như sự phát triển kinh tế, chính sách quốc gia và biến đổi khí hậu, cùng với hoạt động của con người [5]. Tóm lại, điện năng giữ vai trò quan trọng trong xã hội. Mức tiêu thụ năng lượng toàn cầu không ngừng gia tăng dẫn số, kinh tế phát triển và yếu tố thời tiết, đặc biệt rõ rệt ở các nước đang phát triển. Sự thay đổi mô hình tiêu dùng khiến HTĐ gặp khó khăn trong việc cung cấp theo thời gian thực. Trong luận án này đề xuất các mô hình dự báo dựa trên mạng học sâu để giải quyết bài toán “**Dự báo phụ tải hệ thống điện**” nhằm giải quyết bài toán dự báo công suất đỉnh Pmax ngày tới và đồ thị phụ tải điện cho 24 giờ tới, dữ liệu ngõ vào của mô hình được sử dụng từ nguồn dữ liệu quá khứ của khu vực lưới điện Tiền Giang.

### 2. Đối tượng và phạm vi nghiên cứu

- Dự báo Pmax và tải 24 giờ ngày tiếp theo. Phân tích các yếu tố ảnh hưởng đến nhu cầu tải.
- Thu thập các dữ liệu phụ tải quá khứ, nhiệt độ và các yếu tố mùa của khu vực áp dụng.
- Tìm hiểu các mô hình dựa trên mạng học sâu trong STLF. Mô hình được dùng phổ biến LSTM; CNN-LSTM; mạng WaveNet và mô hình kết hợp GCN-GRU; FF-DNN kết hợp R-DNN; SEQ2SEQ-LSTM; mô hình tiền xử lý dữ liệu đầu vào Wavelet kết hợp thuật toán tối ưu hoá và mạng GCN-LSTM.
- Áp dụng mô hình đề xuất dự báo khu vực lưới điện cụ thể (lưới điện Tiền Giang).
- Kết quả chỉ số sánh đối chiếu với các mô hình cùng tập dữ liệu. Nghiên cứu không xét dự báo siêu ngắn hạn, trung hạn và dài hạn, chỉ áp dụng cho ngày làm việc trong tuần và không bao gồm ngày lễ, Tết.
- Do dự báo nhu cầu tải cho 24 giờ và Pmax ngày tiếp theo nên không đặt nặng thời gian thực của mô hình dự báo.
- Kết quả của mô hình dự báo chỉ xem xét đến giá trị sai số phần trăm tuyệt đối trung bình  $e_{MAPE}$  theo tiêu Quyết định Số 07 /QĐ-ĐTĐL năm 2013. Trung bình bình phương sai số  $e_{RMSE}$  không xem xét trong nghiên cứu.
- Nhiệt độ của ngày dự báo được sử dụng theo nguồn chia sẻ của đài khí tượng thủy văn.
- Mô hình đề xuất GCN-GRU; Wavelet-HHO-GCN-GRU đòi hỏi tài nguyên tính toán lớn, nghiên cứu không phân tích chi phí về mặt công nghệ hay thời gian xử lý khi áp dụng vào mô hình thực tế, đặc biệt khi cần dự báo trong thời gian ngắn và xử lý dữ liệu khối lượng lớn, việc đánh giá cần quá trình thực nghiệm thống kê trên thực tế.

- [13] Q. Lou, Q. Lyu, Z. Na, D. Ma, and X. Ma, “Short-term electric power demand forecasting using a hybrid model of SARIMA and SVR,” *IOP Conf Ser Earth Environ Sci*, vol. 619, no. 1, p. 012035, Dec. 2020, doi: 10.1088/1755-1315/619/1/012035.
- [14] U. B. Tayab, A. Zia, F. Yang, J. Lu, and M. 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, Jul. 2020, doi: 10.1016/J.ENERGY.2020.117857.
- [15] Z. Liao, H. Pan, X. Fan, Y. Zhang, and L. Kuang, “Multiple Wavelet Convolutional Neural Network for Short-Term Load Forecasting,” *IEEE Internet Things J*, vol. 8, no. 12, pp. 9730–9739, Jun. 2021, doi: 10.1109/JIOT.2020.3026733.
- [16] 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, Oct. 2018, doi: 10.1177/1748301818797061/ASSET/IMAGES/LARGE/10.1177\_1748301818797061-FIG3.JPEG.
- [17] M. Barman, N. B. Dev Choudhury, and S. Sutradhar, “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, Feb. 2018, doi: 10.1016/j.energy.2017.12.156.
- [18] X. Wang and Y. Wang, “A Hybrid Model of EMD and PSO-SVR for Short-Term Load Forecasting in Residential Quarters,” *Math Probl Eng*, vol. 2016, no. 1, p. 9895639, Jan. 2016, doi: 10.1155/2016/9895639.
- [19] H. Jiang, Y. Zhang, E. Muljadi, 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 Trans Smart Grid*, vol. 9, no. 4, pp. 3331–3350, Jul. 2018, doi: 10.1109/TSG.2016.2628061.
- [20] Z. Chen, C. Wang, L. Lv, L. Fan, S. Wen, and Z. Xiang, “Research on Peak Load Prediction of Distribution Network Lines Based on Prophet-LSTM Model,” *Sustainability 2023, Vol. 15, Page 11667*, vol. 15, no. 15, p. 11667, Jul. 2023, doi: 10.3390/SU151511667.
- [21] O. Rubasinghe, X. Zhang, T. K. Chau, Y. H. Chow, T. Fernando, and H. H. C. Iu, “A Novel Sequence to Sequence Data Modelling Based CNN-LSTM Algorithm for Three Years Ahead Monthly Peak Load Forecasting,” *IEEE Transactions on Power Systems*, vol. 39, no. 1, pp. 1932–1947, Jan. 2024, doi: 10.1109/TPWRS.2023.3271325.
- [22] S. S. Arnob, A. I. M. S. Arefin, A. Y. Saber, and K. A. Mamun, “Energy Demand Forecasting and Optimizing Electric Systems for Developing Countries,” *IEEE Access*, vol. 11, pp. 39751–39775, 2023, doi: 10.1109/ACCESS.2023.3250110.
- [23] H. Habbak, M. Mahmoud, K. Metwally, M. M. Fouda, and M. I. Ibrahim, “Load Forecasting Techniques and Their Applications in Smart Grids,” *Energies 2023, Vol. 16, Page 1480*, vol. 16, no. 3, p. 1480, Feb. 2023, doi: 10.3390/EN16031480.
- [24] N. B. Vanting, Z. Ma, and B. N. Jørgensen, “A scoping review of deep neural networks for electric load forecasting,” *Energy Informatics*, vol. 4, no. 2, pp. 1–13, Sep. 2021, doi: 10.1186/S42162-021-00148-6/FIGURES/1.
- [25] N. Kim, H. Park, J. Lee, and J. K. Choi, “Short-Term Electrical Load Forecasting with Multidimensional Feature Extraction,” *IEEE Trans Smart Grid*, vol. 13, no. 4, pp. 2999–3013, Jul. 2022, doi: 10.1109/TSG.2022.3158387.

## TÀI LIỆU THAM KHẢO

- [1] Y. Lin, H. Luo, D. Wang, H. Guo, and K. Zhu, “An Ensemble Model Based on Machine Learning Methods and Data Preprocessing for Short-Term Electric Load Forecasting,” *Energies (Basel)*, vol. 10, no. 8, p. 1186, Aug. 2017, doi: 10.3390/EN10081186.
- [2] G. Nalcaici, A. Özmen, and G. W. Weber, “Long-term load forecasting: models based on MARS, ANN and LR methods,” *Cent Eur J Oper Res*, vol. 27, no. 4, pp. 1033–1049, Dec. 2019, doi: 10.1007/s10100-018-0531-1.
- [3] M. Y. Khamaira, A. S. Krzma, and A. M. Alnass, “Long Term Peak Load Forecasting for the Libyan Network,” *First Conference for Engineering Sciences and Technology*, 2018, Accessed: Nov. 10, 2024. [Online]. Available: [https://dspace.elmergib.edu.ly/bitstream/handle/123456789/34/CEST\\_2\\_182.pdf?sequence=1&isAllowed=y](https://dspace.elmergib.edu.ly/bitstream/handle/123456789/34/CEST_2_182.pdf?sequence=1&isAllowed=y)
- [4] J. Zhang, “Research on Power Load Forecasting Based on the Improved Elman Neural Network,” *Chem Eng Trans*, vol. 51, pp. 589–594, Aug. 2016, doi: 10.3303/CET1651099.
- [5] X. Zhang, J. Wang, and K. Zhang, “Short-term electric load forecasting based on singular spectrum analysis and support vector machine optimized by Cuckoo search algorithm,” *Electric Power Systems Research*, vol. 146, pp. 270–285, May 2017, doi: 10.1016/J.EPSR.2017.01.035.
- [6] C. C. Thuần, L. X. Tuấn, H. T. Long, H. X. Bách, and N. T. Hùng, “Phương pháp tổ hợp có hiệu chỉnh các mô hình dự báo phụ tải điện ngắn hạn cho điện lực miền nam,” *Tạp chí Khoa học Công nghệ và Thực phẩm*, vol. 22, no. 3, pp. 359–366, 2022, Accessed: Nov. 09, 2024. [Online]. Available: [https://huitjournal.vn/uploads/files/so-tap-chi/nam-2022/Tap-22-So-3/35\\_202203CNTT12\\_R1\\_Thu%E1%BA%A7n\\_H%C3%B9ng\\_359-366\\_8p.pdf](https://huitjournal.vn/uploads/files/so-tap-chi/nam-2022/Tap-22-So-3/35_202203CNTT12_R1_Thu%E1%BA%A7n_H%C3%B9ng_359-366_8p.pdf)
- [7] L. D. Duong, “A short-term load forecasting model based on group method of data handling,” *Journal of Science and Technology - University of Danang*, vol. 17, no. 7, 2019, Accessed: Nov. 09, 2024. [Online]. Available: <https://jst-ud.vn/jst-ud/article/download/2363/2363>
- [8] P. D. Lê *et al.*, “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,” *VNUHCM Journal of Engineering and Technology*, vol. 2, no. 4, pp. 223–239, Feb. 2020, doi: 10.32508/stdjet.v2i4.614.
- [9] P. T. T. Binh, T. N. Le, and N. P. Xuan, “Advanced som & k mean method for load curve clustering,” *International Journal of Electrical and Computer Engineering*, vol. 8, no. 6, pp. 4829–4835, Dec. 2018, doi: 10.11591/ijece.v8i6.pp4829-4835.
- [10] N. H. Tuyền and N. P. Khải, “Dự báo công suất phụ tải cực đại tại công ty điện lực vĩnh long bằng mạng nơron nhân tạo,” *Tạp chí Khoa học Công nghệ và Thực phẩm - Đại học Công Thương TP.HCM*, vol. 21, no. 4, pp. 156–164, 2021, Accessed: Nov. 09, 2024. [Online]. Available: [https://huitjournal.vn/uploads/files/so-tap-chi/nam-2021/Tap-21-So-4/14\\_2021030007R2\\_mang%20noron\\_156-164.pdf](https://huitjournal.vn/uploads/files/so-tap-chi/nam-2021/Tap-21-So-4/14_2021030007R2_mang%20noron_156-164.pdf)
- [11] B. Yildiz, J. I. Bilbao, and A. B. Sproul, “A review and analysis of regression and machine learning models on commercial building electricity load forecasting,” *Renewable and Sustainable Energy Reviews*, vol. 73, pp. 1104–1122, Jun. 2017, doi: 10.1016/J.RSER.2017.02.023.
- [12] S. G. N and Dr. G. S. Sheshadri, “ARIMAX Model for Short-Term Electrical Load Forecasting,” *International Journal of Recent Technology and Engineering (IJRTE)*, vol. 8, no. 4, pp. 2786–2790, Nov. 2019, doi: 10.35940/ijrte.D7950.118419.

### 3. Mục tiêu và nhiệm vụ nghiên cứu

- Xây dựng mô hình dựa trên mạng học sâu để dự báo công suất đỉnh cho ngày tới và đồ thị phụ tải cho 24 giờ tới.
- Đánh giá hiệu năng của mô hình dự báo học sâu để xuất (so sánh với các phương pháp dự báo truyền thống).
- Áp dụng mô hình để xuất để dự báo công suất đỉnh Pmax và đồ thị phụ tải cho một khu vực lưới điện cụ thể.
- Thu thập dữ liệu quá khứ, đánh giá và phân tích các yếu tố tác động đến kết quả bài toán dự báo phụ tải điện.
- Lựa chọn và xây dựng các kiến trúc học sâu thông dụng: LSTM, CNN-LSTM, mạng WaveNet. Đề xuất mô hình kết hợp GCN-GRU và Wavelet – HHO – GCN – LSTM để dự báo công suất đỉnh và đồ thị phụ tải tương ứng.
- Tích hợp các yếu tố đầu vào để thiết kế mô hình dự báo. Huấn luyện tạo mô hình, chạy thử nghiệm.

### 4. Phương pháp nghiên cứu

- Nghiên cứu phần mềm Pycharm, ngôn ngữ Python, và thư viện Tensorflow để thực hiện chương trình huấn luyện và dự báo. Thu thập dữ liệu quá khứ.
- Sử dụng mô hình dự báo công suất đỉnh thông dụng (LSTM, CNN-LSTM, mạng WaveNet) và GCN-GRU: Huấn luyện mô hình, chạy thử nghiệm, đánh giá và so sánh.
- Sử dụng mô hình dự báo đồ thị phụ tải thông dụng và mô hình kết hợp Wavelet-HHO-GCN-LSTM. Xử lý dữ liệu đầu vào dựa trên phép biến đổi Wavelet, huấn luyện, chạy thử nghiệm, đánh giá và so sánh.

### 5. Điểm mới của luận án

- Phân tích và đánh giá được dữ liệu trong bài toán STLF theo hướng tiếp cận đánh giá mới. Nó phụ thuộc không gian và thời gian. Qua đó, luận án đề xuất được các phương pháp dự báo mới nhằm cải thiện sai số trong bài toán dự báo. Xây dựng được mô hình kết hợp học sâu mới để dự báo công suất đỉnh: GCN-GRU (T-GCN), kết quả mô hình đề xuất có độ chính xác cao.
- Xây dựng được ba mô hình trong mạng học sâu để dự báo đồ thị phụ tải: kiến trúc mô hình kết hợp FF-DNN và R-DNN, Seq2Seq-LSTM, phép biến đổi Wavelet kết hợp với giải thuật tối ưu HHO-GCN-LSTM, kết quả của mô hình đề xuất sai số bé. Chỉ số đánh giá phần trăm tuyệt đối trung bình phù hợp nằm trong phạm vi cho phép của cục điều tiết điện lực.

### 6. Giá trị thực tiễn của luận án

- Luận án đã đóng góp tích cực và hiệu quả trong đề xuất phương pháp mới để giải quyết bài toán dự báo phụ tải điện dựa trên mạng học sâu thông qua các phương pháp kết hợp mới: GCN-GRU (T-GCN); kiến trúc mô hình FF-DNN và R-DNN; SEQ2SEQ-LSTM dựa trên cơ chế mã hoá và giải mã; tiền xử lý dữ liệu Wavelet kết hợp với thuật toán HHO và mạng GCN-LSTM. Kết quả dự báo phụ tải đỉnh là một đại lượng quan trọng, cần thiết trong quá trình lập kế hoạch quản lý năng lượng và điều tiết nguồn điện một cách hiệu quả.
- Kết quả dự báo đồ thị phụ tải ngày chính xác, hỗ trợ việc lập kế hoạch vận hành và khai thác hệ thống điện trong khu vực một cách an toàn và tin cậy. Kết quả của bài toán dự báo công suất đỉnh ngày tới và đồ thị phụ tải 24 giờ tới có ý nghĩa quan trọng đối với lưới điện khi có sự tham gia của hệ thống lưu trữ năng lượng pin (BESS) và xe điện (EV). Có thể luận giải mô hình để xuất để dự báo công suất đỉnh cho ngày tới và đồ thị phụ tải 24 giờ tới áp dụng trong thực tế, đáp ứng đầy đủ các yêu cầu và quy định của cục điều tiết điện lực về quy trình dự báo phụ tải.

### 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 1. TỔNG QUAN

### 1.1. Giới thiệu

Trong những năm gần đây, nhờ vào sự phát triển của khoa học, đặc biệt là khoa học máy tính đã ảnh hưởng lớn góp phần mang lại nhiều chuyển biến tích cực, các ứng dụng công nghệ thông tin trong dự đoán được triển khai rộng rãi trong nhiều lĩnh vực [6]. Hiện nay DBPT điện là một trong những lĩnh vực mà Nhà nước đặc biệt quan tâm, chỉ đạo và ban hành các hướng dẫn cụ thể theo Thông tư số 19/2017/TT-BCT quy định nội dung, phương pháp và trình tự nghiên cứu phụ tải điện của Bộ Công thương ban hành năm 2017 và Quyết định số 07/QĐ-ĐTĐL Quy trình dự báo nhu cầu phụ tải điện hệ thống điện quốc gia của Cục Điều tiết Điện lực – Bộ Công Thương ban hành năm 2013. Bài toán DBPT điện thu hút các nhà nghiên cứu và được chú ý bởi các cơ quan quản lý năng lượng và vận hành HTĐ, DBPT cung cấp thông tin cần thiết cho việc lập kế hoạch đầu tư trong tương lai, ngoài ra nó còn ảnh hưởng đến kế hoạch vận hành hệ thống và sản xuất. Nếu kết quả dự báo vượt quá thực tế đáng kể, cần huy động vốn để đầu tư các nguồn phát điện. Tuy nhiên, trên thực tế không sử dụng hết công suất phát dẫn đến lãng phí. Trái lại, nếu kết quả dự báo thấp hơn so với thực tế yêu cầu, sẽ làm giảm độ an toàn trong cung cấp điện, gây ra tình trạng cắt điện trên diện rộng và gây thiệt hại nghiêm trọng về kinh tế, xã hội cũng như an ninh quốc gia [7].

Tóm lại, dự báo phụ tải điện nói chung, cũng như STLF nói riêng, đóng vai trò quan trọng trong việc đảm bảo sự vận hành hiệu quả và tin cậy HTĐ. Hiện nay trong và ngoài nước có nhiều phương pháp DBPT đã được đề xuất, mỗi phương pháp đều có những ưu điểm và hạn chế.

### 1.2. Tình hình nghiên cứu trong nước

Trong thời gian gần đây, trong nước có nhiều nghiên cứu về DBPT. Nghiên cứu [8] xem xét chất lượng nguồn dữ liệu quá khứ trước khi đưa vào mô hình dự báo STLF trên lưới điện TP.HCM. Nghiên cứu [9] đề xuất SOM & K Mean để phân cụm đường cong phụ tải, cải thiện kết quả và giảm thời gian tính toán. Nghiên cứu [7] áp dụng kỹ thuật xử lý dữ liệu nhóm kết hợp xác suất thống kê, giúp tăng độ chính xác và linh hoạt. Nghiên cứu [10] sử dụng mạng nơ-ron nhân tạo trong Matlab để dự báo công suất PTD, với sai số 0,19%. Nhóm nghiên cứu [6] đề xuất thuật toán học có giám sát và điều chỉnh giá trị dự báo nhằm giảm độ lệch âm, cải thiện độ chính xác.

### 1.3. Tình hình nghiên cứu ngoài nước

Phương pháp cổ điển như ARMAX, ARIMA, SARIMA được dùng rộng rãi để dự báo STLF [11]. Mô hình ARIMA [12] dự báo tải theo giờ với MAPE 4,46%. Mô hình ARIMA-SVR [13] gồm hai bước: ARIMA xử lý hàm tuyến tính, SVR điều chỉnh độ lệch, sai số 4,757%. Các nghiên cứu gần đây sử dụng mạng nơ-ron và học sâu để cải thiện độ chính xác so với phương pháp thống kê. Mô hình CS-SSA-SVM [5] kết hợp SSA, SVM, CS để lọc tín hiệu và tối ưu hóa dự báo. Mô hình Wavelet-FNN [14] tối ưu bằng thuật toán chim ưng, đạt MAPE 1,2262%. Mô hình MWCNN [15] khai thác đặc điểm chu kỳ dữ liệu tải. Các phương pháp kết hợp PSO [16], GOA [17], EMD [18], GTA-PSO [19] cũng được áp dụng trong STLF.

Mô hình Prophet-LSTM [20] dự báo tải đỉnh với MAE 8,569 và RMSE 11,68. Mô hình CNN-LSTM [21] dự báo tải đỉnh hàng tháng trong 3 năm, đạt độ chính xác cao. Phương pháp PRISMA-P [22] giúp phân tích tổng hợp, lựa chọn chiến lược dự báo tối ưu. Các nghiên cứu AI, ML, DL [23] cải thiện độ chính xác với sai số MAPE tối ưu. Mô hình lai CNN-LSTM [24] kết hợp CNN nhận dạng mẫu và LSTM học đặc trưng tuần tự. Phương pháp trích xuất tính năng đa chiều [25] giúp giảm sai số RMSE từ 5% - 12%. Mô hình ANFIS [26] dự báo năng lượng tòa nhà với sai số thấp. Mô hình LSTM-GRU-RNN [27] dự báo tải từ dữ liệu SCADA, giúp tối ưu kế hoạch năng lượng và cân bằng cung cầu.

Luận án đề xuất hai giải thuật chính: GCN-GRU dự báo công suất đỉnh cho ngày tới và Wavelet-HHO-GCN-LSTM dự báo đồ thị phụ tải 24 giờ. Các mô hình khác được thử nghiệm để đối sánh kết quả.

Luận án này phát triển xây dựng một mô hình dự báo kết hợp mới là Wavelet-HHO-GCN-LSTM, một phương pháp tiếp cận mới và hiệu quả. Mô hình này được thiết kế để sử dụng các ưu điểm của việc lọc nhiễu và phân tích dữ liệu dùng Wavelet, thêm vào đó là khả năng tối ưu hóa của HHO và sức mạnh của mạng nơ-ron học sâu GCN-LSTM trong việc mô hình hóa dữ liệu phức tạp. Trong phần kết quả thực nghiệm, chương này cung cấp một so sánh chi tiết giữa mô hình đề xuất và các mô hình dự báo FF-DNN và R-DNN; SEQ2SEQ-LSTM cho phụ tải điện. Kết quả cho thấy mô hình Wavelet-HHO-GCN-LSTM vượt trội về độ chính xác, với giá trị RMSE và MAPE thấp hơn đáng kể so với các mô hình so sánh như LSTM, CNN-LSTM và mạng WaveNet, đồng thời chứng tỏ khả năng dự báo tải điện một cách chính xác và đáng tin cậy.

Bên cạnh việc đạt được sai số thấp hơn so với các mô hình truyền thống, mô hình Wavelet-HHO-GCN-LSTM mang lại nhiều ưu điểm nổi bật trong bài toán dự báo đồ thị phụ tải. Trước hết, bộ lọc Wavelet giúp phân tách dữ liệu thành các thành phần tần số khác nhau, loại bỏ nhiễu và trích xuất đặc trưng hữu ích trước khi đưa vào mô hình học sâu, giúp cải thiện đáng kể chất lượng đầu vào. Tiếp theo, thuật toán tối ưu HHO được sử dụng để tinh chỉnh các tham số của mô hình, giúp tối ưu hóa quá trình huấn luyện, giảm thiểu sai số và tăng cường khả năng hội tụ.

Ngoài ra, sự kết hợp của GCN và LSTM trong mô hình giúp khai thác triệt để mối quan hệ không gian và thời gian của dữ liệu phụ tải. GCN có khả năng học được cấu trúc của dữ liệu dưới dạng đồ thị, phù hợp với đặc trưng liên kết phức tạp giữa các trạm biến áp, khu vực tiêu thụ điện. Trong khi đó, LSTM giúp ghi nhớ thông tin theo chuỗi thời gian, đặc biệt hữu ích trong việc dự báo phụ tải với dữ liệu có sự thay đổi theo mùa và theo giờ.

Kết quả thực nghiệm cho thấy mô hình đề xuất không chỉ vượt trội về độ chính xác so với các mô hình học sâu thông dụng như LSTM, CNN-LSTM, WaveNet, mà còn có tính tổng quát hóa tốt hơn so với các mô hình lai trước đây như FF-DNN, R-DNN, Seq2Seq-LSTM. Điều này khẳng định tính hiệu quả của phương pháp tiếp cận mới trong việc dự báo phụ tải điện, đặc biệt trong bối cảnh hệ thống điện ngày càng phức tạp và biến động mạnh do sự phát triển của năng lượng tái tạo và các yếu tố môi trường.

Nghiên cứu đã tập trung vào lưới điện khu vực Tiền Giang, nhưng khả năng mở rộng mô hình ra các khu vực khác với điều kiện kinh tế-xã hội và khí hậu khác biệt có thể chưa được xem xét rõ. Mô hình cần được kiểm chứng tính khả dụng và tính linh hoạt để có thể áp dụng cho các vùng với cấu trúc lưới điện khác nhau. Chưa đánh giá cho các nguồn dữ liệu, khu vực khác. Nhưng việc sử dụng các phương pháp dự báo có thể xem xét triển khai, và kiểm tra hiệu chỉnh trên thực tế.

## 2. Kiến nghị

Luận án đã phân tích và đề xuất các phương pháp dự báo công suất đỉnh và phụ tải. Tuy nhiên, vẫn còn một số hạn chế khi chưa xem xét hết các yếu tố ảnh hưởng. Nghiên cứu sinh tiếp tục nghiên cứu các bài toán mở rộng như:

- Dự báo công suất đỉnh và đồ thị phụ tải cho các ngày đặc biệt trong năm, bao gồm các ngày lễ, Tết, hoặc các thời điểm có biến động lớn về nhu cầu điện, nhằm nâng cao độ chính xác của mô hình trong các tình huống bất thường.
- Tích hợp giá điện làm yếu tố đầu vào của mô hình dự báo, giúp phản ánh tác động của chính sách giá điện đến hành vi tiêu thụ, đặc biệt khi có sự điều chỉnh giá theo mùa hoặc theo khung giờ.
- Xem xét các yếu tố kinh tế - môi trường ảnh hưởng đến hành vi tiêu thụ điện, bao gồm GDP, độ ẩm, lượng mưa, nhằm đánh giá tác động gián tiếp của các yếu tố này đến nhu cầu sử dụng điện trong các lĩnh vực công nghiệp, thương mại và dân dụng.

## KẾT LUẬN – KIẾN NGHỊ

### 1. Kết luận

Luận án “Dự báo phụ tải hệ thống điện” đề xuất mô hình giải quyết hai bài toán áp dụng dự báo công suất đỉnh và đồ thị phụ tải.

**Bài toán 1:** Xây dựng mô hình mạng kết hợp mạng tích chập đồ thị với đơn vị công hồi quy GCN-GRU dự báo công suất đỉnh. Trong chương 3 của nghiên cứu, nội dung quan trọng đã được luận án thực hiện, bao gồm việc dự báo công suất đỉnh Pmax sử dụng thuật toán GCN-GRU. Nhiệm vụ dự báo công suất đỉnh Pmax góp phần quan trọng trong nghiên cứu, dựa trên việc phân tích dữ liệu quá khứ Pmax và các yếu tố tác động. Mô hình được đề xuất, gọi là GCN-GRU, mô hình thử nghiệm được áp dụng với số liệu 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 phần trăm tuyệt đối trung bình bé cụ thể MAPE là 0,0006% và được đối sánh thể hiện trong Bảng 3.2.

Kết quả dự báo của mô hình cũng được so sánh với các mô hình dự báo mạng học sâu thông dụng như là LSTM, CNN-LSTM, mạng WaveNet. Các mô hình dự báo học sâu thông dụng được thử nghiệm trên cùng tập dữ liệu với mô hình GCN-GRU (khu vực lưới điện Tiền Giang), dựa vào Bảng 3.2 kết quả dự báo sai số của mô hình đề xuất GCN-GRU là bé nhất, chứng tỏ hiệu năng của mô hình đề xuất được cải thiện, theo hướng tiếp cận mới về mối quan hệ dữ liệu trong bài toán dự báo, phụ thuộc theo không gian và thời gian, sai số của mô hình đảm bảo chỉ tiêu đánh giá trong bài toán dự báo. Kết quả của nghiên cứu được công bố [69].

Bên cạnh việc cải thiện độ chính xác dự báo, mô hình GCN-GRU còn mang lại một số ưu điểm quan trọng so với các phương pháp truyền thống. Thứ nhất, việc tích hợp mạng tích chập đồ thị (GCN) giúp khai thác mối quan hệ không gian giữa các điểm dữ liệu trong lưới điện, điều mà các mô hình học sâu tuần tự như LSTM hay CNN-LSTM chưa tối ưu hóa. Thứ hai, đơn vị công hồi quy (GRU) cho phép mô hình ghi nhớ thông tin trong chuỗi thời gian một cách hiệu quả, giảm thiểu vấn đề biến mất gradient khi làm việc với dữ liệu dài hạn.


Hơn nữa, kết quả thử nghiệm trên tập dữ liệu lưới điện tỉnh Tiền Giang cho thấy khả năng tổng quát hóa tốt của mô hình, ngay cả khi áp dụng cho các điều kiện thời tiết và mô hình phụ tải khác nhau. Điều này mở ra tiềm năng ứng dụng GCN-GRU cho các khu vực lưới điện khác với đặc điểm vận hành khác biệt, giúp hỗ trợ các nhà vận hành hệ thống điện trong việc lập kế hoạch, tối ưu hóa nguồn lực và giảm thiểu rủi ro do sai lệch dự báo.

Với những ưu điểm này, nghiên cứu không chỉ đề xuất một mô hình có độ chính xác cao mà còn góp phần mở rộng hướng tiếp cận mới trong bài toán dự báo phụ tải điện, đặc biệt trong bối cảnh hệ thống điện ngày càng phức tạp với sự gia tăng của các nguồn năng lượng tái tạo và sự biến động của phụ tải theo không gian và thời gian.

**Bài toán 2:** Xây dựng mô hình mạng kết hợp, bộ lọc Wavelet – thuật toán tối ưu HHO - tích chập đồ thị với bộ nhớ dài hạn/ngắn hạn (Wavelet-HHO-GCN-LSTM), dự báo ĐTPT mô hình thử nghiệm được áp dụng với dữ liệu 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 mô hình đề xuất có sai số bé, thể hiện cụ thể là sai số phần trăm tuyệt đối trung bình MAPE là 0,54 được so sánh với các mô hình khác thể hiện trong. Đề thu được kết quả tốt trong bài toán dự báo ĐTPT nghiên cứu đã xây dựng 3 mô hình DBPT dựa trên mạng học sâu thông dụng LSTM, CNN-LSTM, mạng WaveNet. Sai số phần trăm tuyệt đối trung bình MAPE lần lượt là 4,6159; 3,7519; và 0,8749 tương ứng. Sai số của 3 mô hình thông dụng đều đạt yêu cầu về sai số. Từ đó dựa trên kết quả khả quan này, nghiên cứu sử dụng 3 mô hình lai trong bài toán dự báo ĐTPT với sự cải tiến so với các mô hình học sâu thông dụng đã được triển khai trước đây như mô hình một FF-DNN R-DNN và mô hình 2 Seq2Seq-LSTM, đã được thử nghiệm lại trên dữ liệu Tiền Giang, kết quả sai số thể hiện trong Bảng 4.4.

### 1.4. Giới thiệu chung về HTĐ Tiền Giang

Theo tài liệu báo cáo kết quả thực hiện kế hoạch năm 2021 và năm 2022 của Công ty điện lực Tiền Giang [28]. Đặc điểm của lưới điện Tiền Giang bao gồm: Tiền Giang là tỉnh thuộc vùng đồng bằng sông Cửu Long (miền Tây Nam Bộ), nằm dọc theo bờ Bắc sông Tiền, một nhánh của sông Mê Kông dài khoảng 120 km. Tiền Giang có 11 đơn vị hành chính cấp huyện (8 huyện, 01 thành phố, 02 thị xã) và 173 đơn vị hành chính cấp xã, trong đó thành phố Mỹ Tho là đô thị loại I trực thuộc tỉnh Tiền Giang. Khí hậu của Tiền Giang chia thành hai mùa rõ rệt: mùa khô từ tháng 12 đến tháng 4 và mùa mưa từ tháng 5 đến tháng 11. Nhiệt độ trung bình hàng năm khoảng 27°C, với lượng mưa hàng năm đạt khoảng 1.467 mm. Kinh tế các khu vực trên toàn tỉnh Tiền Giang phát triển không đồng đều chủ yếu tập trung ở khu công nghiệp Tân Hương và khu công nghiệp Long Giang dẫn đến công suất phụ tải ở các khu vực này có sự chênh lệch lớn. Phụ tải chủ yếu tập trung ở các khu công nghiệp phát triển. Ở những khu vực không phát triển phụ tải vào cao điểm chủ yếu là phụ tải sinh hoạt, điều này gây khó khăn rất lớn trong vận hành kinh tế hệ thống điện. Các thành phần phụ tải được thể hiện trong Hình 1.1.



Hình 1.1: Thành phần cấu thành phụ tải Tiền Giang

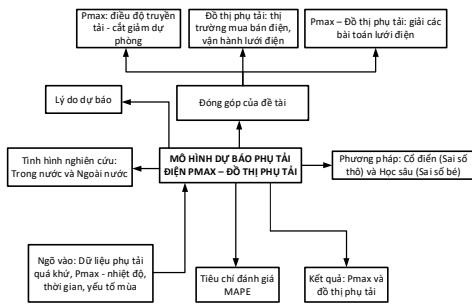
Lưới điện khu vực Tiền Giang thuộc lưới điện quốc gia, do đó việc dự báo phụ tải của khu vực Tiền Giang tuân theo các quy định của cục điều tiết điện lực (Quyết định Số 07/QĐ-ĐTDL). Các phương pháp dự báo phụ tải theo quy định trước đây: Phương pháp ngoại suy, phương pháp hồi quy, phương pháp hệ số đàn hồi, phương pháp mạng nơ-ron nhân tạo, phương pháp tương quan – xu thế, phương pháp chuyên gia, các phương pháp khác. Hiện nay, Phòng điều độ thuộc Công ty Điện lực Tiền Giang đang thực hiện dự báo phụ tải theo phương pháp sau: theo phần mềm SPC, phần mềm NSMO. Sai số hiện nay trong dự báo của khu vực lưới điện Tiền Giang dao động từ 5% - 10%. Tuy nhiên, thực tế cho thấy các phương pháp khi áp dụng vào STLF trong khu vực lưới điện Tiền Giang vẫn còn gặp phải vấn đề về giá trị dự báo thấp so với nhu cầu thực tế, kèm với sai số mô hình dự báo lớn, gây khó khăn trong việc lựa chọn đưa ra quyết định hợp lý.

### 1.5. Kết luận chương

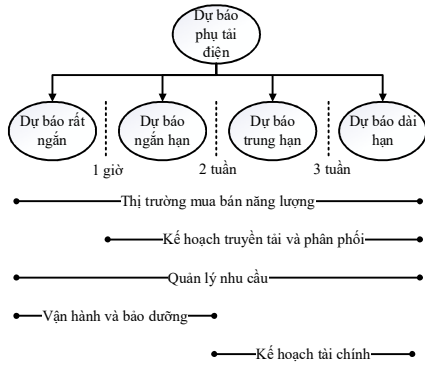
Trong chương này nghiên cứu đã giới thiệu được tổng quan về bài toán dự báo phụ tải điện, STLF đóng vai trò quan trọng trong việc đảm bảo, vận hành HTĐ hiệu quả và đáng tin cậy. Nghiên cứu đã tổng hợp được tình hình nghiên cứu trong và ngoài nước, các phương pháp đã đề xuất, qua đó nghiên cứu đã nắm bắt được các thông tin quan trọng và kết quả đã được được trong bài toán dự báo PTĐ. Nghiên cứu đã cập nhật làm cơ sở cho nghiên cứu trong các chương tiếp theo. Ngoài ra trong chương này phản ánh thực trạng tình hình công tác giải quyết bài toán dự báo tại khu vực lưới điện Tiền Giang, sai số mô hình dự báo còn cao, dẫn đến vận hành HTĐ còn gặp nhiều khó khăn. Đề giải quyết vấn đề tồn tại về sai số mô hình dự báo cao đang gặp phải tại khu vực lưới điện Tiền Giang  $e_{MAPE}$  là 5% đến 10%. Nghiên cứu tiếp tục giải quyết vấn đề này trong luận án.

## CHƯƠNG 2. CƠ SỞ LÝ THUYẾT

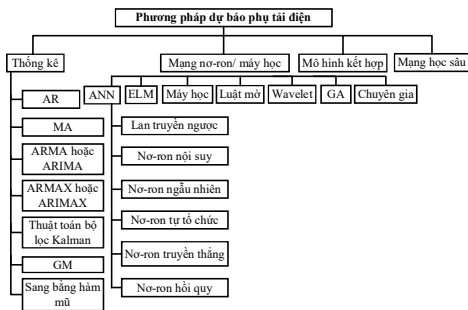
### 2.1. Phân tích sơ đồ dự báo phụ tải điện



**Hình 2.1:** Sơ đồ phân tích về "Dự báo phụ tải điện"



**Hình 2.2:** Các loại dự báo phụ tải điện



**Hình 2.3:** Các phương pháp dự báo phụ tải điện [33]

Dựa trên cơ sở các công trình nghiên cứu trong và ngoài nước STLF, mục đích DBPT là ước tính phụ tải trong giờ tới, ngày tới [29], trừ các phụ tải có nguồn cung cấp điện riêng. Hình 2.1 phân tích sơ đồ dự báo PTD, cơ sở để lập kế hoạch đầu tư phát triển lưới điện phân phối hàng năm, kế hoạch vận hành HTĐ phân phối, kế hoạch và kế hoạch vận hành thị trường điện, ngoài ra dự báo sản lượng điện của một HTĐ hoặc một khu vực cụ thể trong tương lai gần, thường trong khoảng thời gian từ một giờ đến một tuần.

Việc phân loại DBPT thành các loại khác nhau đóng vai trò quan trọng. Mỗi loại dự báo có đặc điểm riêng và phù hợp với các mô hình khác nhau. Do đó việc phân chia này giúp nghiên cứu, xây dựng mô hình và thực hiện dự báo một cách hiệu quả [30] dưới đây là các loại dự báo: Dự báo tải dài hạn (LTLF), Dự báo tải trung hạn (MTLF), Dự báo tải ngắn hạn (STLF), Dự báo tải cực ngắn/rất ngắn hạn (VSTLF)

Chỉ số đánh giá sai số trong bài toán dự báo phụ tải điện: Chỉ số đánh giá dự báo được xây dựng với sai số phần trăm tuyệt đối trung bình  $e_{MAPE}$  và trung bình phương sai số  $e_{RMSE}$  được biểu diễn bởi [31]

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n [x(i) - y(i)]^2} \quad (2.1)$$

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{x(i) - y(i)}{x(i)} \right| \times 100\% \quad (2.2)$$

Trong nghiên cứu [32] thống kê chỉ số  $e_{MAPE}$  như sau:

**Bảng 2.1:** Tiêu chí đánh giá sai số phần trăm tuyệt đối trung bình tham khảo

MAPE	Dự báo
MAPE ≤ 10%	Kết quả cao
10% < MAPE ≤ 20%	Kết quả tốt
20% < MAPE ≤ 50%	Kết quả phù hợp
MAPE > 50%	Kết quả thấp

động phụ tải điện, nó có khả năng xử lý quan hệ thời gian phi tuyến và không ổn định. Ngoài ra, thuật toán HHO tối ưu tham số mạng GCN-LSTM, cải thiện khả năng hội tụ và độ chính xác của mô hình dự báo. Từ các tính năng vượt trội này, nghiên cứu này đã xây dựng nhóm hai phương pháp dự báo ĐTPT điện (mô hình kết hợp): FF-DNN và R-DNN; SEQ2SEQ-LSTM; Bộ lọc Wavelet-HHO-GCN-LSTM, để đối sánh kết quả của mô hình đề xuất trên cùng tập dữ liệu (khu vực lưới điện Tiền Giang). Đối với mô hình FF-DNN và R-DNN và SEQ2SEQ-LSTM có sai số MAPE% là 0,5376 và 0,5450 tương ứng có hai phương pháp này có sai số đều nhỏ hơn 1%, chỉ số MAPE% đạt yêu cầu về sai số. Mô hình Bộ lọc Wavelet-HHO-GCN-LSTM có sai số MAPE% là 0,5473 cho nhóm phụ tải từ ngày thứ 2 đến thứ 6, ngoài ra kết quả mô hình này cũng được so sánh với mô hình HHO-GCN-LSTM (không sử dụng bộ lọc Wavelet), khi sử dụng mô hình HHO-GCN-LSTM sai số MAPE% của mô hình là 0,5828. Điều này chứng tỏ dữ liệu thu thập được trong quá khứ về sản lượng không ổn định và chính xác, bộ tiền xử lý dữ liệu Wavelet góp phần cải thiện sai số của mô hình đáng kể. Nhìn chung ba mô hình kết hợp được đề xuất trong luận án, sai số MAPE% đều nhỏ hơn 1% đạt yêu cầu về sai số với quy định cục điều tiết điện lực.

Dựa vào Bảng 4.4 sai số mô hình LSTM và CNN nhỏ hơn 5% các mô hình còn lại WaveNet; FF-DNN và R-DNN; SEQ2SEQ-LSTM; HHO-GCN-LSTM; Bộ lọc Wavelet-HHO-GCN-LSTM đều nhỏ hơn 1% đáp ứng về yêu cầu sai số MAPE trong dự báo. Tránh trường hợp xử lý sự chênh lệch giá trị dự báo và giá trị thực tế (đáy hoặc đỉnh) quá cao, khi gặp trường hợp này HTĐ phải xử lý như sau:

- Đối với chương trình dự báo: giá trị thực sẽ được cập nhật lại vào input của mô hình để so sánh với giá trị dự báo, tính sai số, có thể chạy lại mô hình để cải thiện dự báo.

- Đối với việc vận hành HTĐ: trong trường hợp công suất đỉnh P<sub>max</sub>, đại lượng P<sub>max</sub> được dùng trong thị trường mua bán điện, cung cấp điện (tuần hoặc tháng), phương thức. Thông thường khi gặp sai số giữa giá trị dự báo và giá trị thực tế lấy kết quả dự báo cộng dự trừ 5% để chuẩn bị cho việc vận hành HTĐ. Nguyên tắc số liệu sử dụng từ dự báo phải lớn hơn giá trị thực tế (không được lớn quá). Trong trường hợp đồ thị phụ tải, ĐTPT được phục vụ trong việc cấu trúc lưới điện, phương thức, và đáp ứng phụ tải. Trên lưới điện luôn có dự phòng nhưng nếu có sự khác biệt lớn thì phải thay đổi nguồn tạm thời.



#### 4.4. Kết quả dự báo tổng thể

**Bảng 4.4:** Kết quả dự báo tổng thể

Model	MAPE (%)
LSTM	4,6159
CNN-LSTM	3,7519
WaveNet	0,8749
FF-DNN và R-DNN	0,5376
Seq2Seq -LSTM	0,5450
HHO-GCN-LSTM	0,5828
Bộ lọc Wavelet -HHO-GCN-LSTM (T2-T6)	0,5473

Theo kết quả thể hiện ở Bảng 4.4 kết quả dự báo đồ thị phụ tải với nhiều phương pháp dự báo khác nhau, được chạy thử nghiệm với cùng tập dữ liệu thuộc khu vực lưới điện Tiền Giang. Dựa vào đồ thị hình 5.3, 5.4, 5.5, 5.8, 5.13, 5.14 các phương pháp có giá trị dự báo và giá trị thực tế bám nhau. Sai số phần trăm tuyệt đối trung bình MAPE% đều nhỏ hơn 5%. Đối với nhóm phương pháp dự báo dựa trên mạng học sâu được dùng phổ biến gồm mạng LSTM, CNN-LSTM, và mạng WaveNet. Cụ thể mô hình dự báo sử dụng LSTM cho kết quả sai số MAPE% là 4,6159, mô hình CNN-LSTM có sai số MAPE% đạt giá trị là 3,75, mô hình mạng WaveNet (mạng WaveNet = Wavelet + CNN) có sai số MAPE% là 0,8749 nhỏ hơn 1%. Điều này chứng tỏ nguồn dữ liệu thu thập được và được áp dụng thử nghiệm cho mô hình dự báo bị nhiễu cao trong quá trình thu thập dữ liệu. Trong mạng WaveNet nhờ vào bộ tiền xử lý dữ liệu Wavelet trước khi dữ liệu được đưa vào mô hình dự báo, độ tin cậy của nguồn dữ liệu được nâng cao, điều này cũng là cơ sở cho nghiên cứu đề xuất mô hình Wavelet-HHO-GCN-LSTM.


#### 4.5. Kết luận

Trong chương 4, kế thừa các công trình nghiên cứu trong nước [6-10] và ngoài nước [11-19]. Nghiên cứu đã xây dựng được sơ đồ tổng quan mô hình dự báo ĐTPT (Hình 4.2) thông qua việc phân tích các yếu tố tác động đến kết quả của bài toán dự báo ĐTPT điện, nghiên cứu đã xác định được các biến ngõ vào của bài toán dự báo ĐTPT điện: sản lượng điện quá khứ (MWh), yếu tố thời tiết – nhiệt độ tương ứng, đặc điểm thời gian. Luận án xây dựng hai nhóm phương pháp để dự báo ĐTPT điện, nhóm một được xem là nhóm mô hình dự báo được sử dụng thông dụng bao gồm: LSTM; CNN-LSTM; và mạng WaveNet, nhóm hai bao gồm các mô hình kết hợp: FF-DNN và R-DNN; SEQ2SEQ-LSTM; và Wavelet-HHO-GCN-LSTM. Đối với nhóm một mô hình LSTM có sai số là 4,6159; CNN-LSTM là 3,7519; mạng WaveNet là 0,8749 nhìn chung sai số của cả ba phương pháp đều nhỏ hơn 5% dựa vào đồ thị hình 4.3; 4.4; và 4.5 đồ thị dự báo ĐTPT trong đó phương pháp LSTM và CNN-LSTM giá trị dự báo bám tốt. Tuy nhiên, sai số còn cao tại các điểm đỉnh. Đối với mô hình mạng WaveNet có sai số vượt trội nhờ vào phép biến đổi chất lượng bộ dữ liệu được nâng cao cải thiện sai số của mô hình. Từ kết quả sai số của nhóm phương pháp một nghiên cứu này đã phát triển nhóm phương pháp hai, các mô hình dự báo, sử dụng các đặc điểm vượt trội của ưu điểm của các mô hình trong phương pháp một. Thứ nhất là bộ lọc Wavelet hỗ trợ phân tích và tách các thành phần tần số trong dữ liệu phụ tải, giúp giảm nhiễu và trích xuất thông tin đặc trưng, hiệu quả nhằm cải thiện độ chính xác dự báo nhờ xử lý tín hiệu theo các mức độ phân giải khác nhau. Wavelet phù hợp với dữ liệu phi tuyến và không ổn định thường gặp trong bài toán phụ tải. Thứ hai mạng CNN tổng quát hoá thành GCN để xử lý dữ liệu phi cấu trúc trên đồ thị thay vì dữ liệu lưới.

Trong DBPT điện mạng GCN khai thác mối quan hệ không gian giữa các nét nâng cao độ chính xác của mô hình dự báo. Thứ ba sử dụng mạng LSTM xử lý hiệu quả chuỗi thời gian, ghi nhớ thông tin dài hạn, phù hợp với sự biến

#### 2.2. Mạng bộ nhớ dài – ngắn hạn LSTM

Từ khuyết điểm của mạng RNN cổ điển (xử lý nhớ bước dài), LSTM là một mạng cải tiến của RNN. LSTM là bộ nhớ dài – ngắn hạn/bộ nhớ ngắn – dài/hạn là một trong những mạng thần kinh nhận tạo được sử dụng trong lĩnh vực học sâu, không giống như các mạng nơron thần kinh truyền thẳng. LSTM bao gồm các kết nối phản hồi. LSTM không chỉ xử lý các điểm dữ liệu đơn lẻ, mà còn xử lý toàn bộ dữ liệu thông qua công điều khiển.



**Hình 2.4:** Cấu trúc bên trong của LSTM [34]


$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (2.3)$$

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (2.4)$$

$$C_t = f_t \times C_{t-1} + i_t \times (\tanh(W_c \times [h_{t-1}, x_t] + b_c)) \quad (2.5)$$

$$O_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (2.6)$$

$$h_t = O_t \times \tanh(C_t) \quad (2.7)$$



**Hình 2.5:** Kiến trúc mạng WaveNet [35]


#### 2.3. Mạng WaveNet (Mạng WaveNet = phép biến đổi Wavelet + CNN)

Mạng WaveNet được thiết kế để tạo dạng sóng âm thanh thô [36], [37]. Mô hình mạng WaveNet có thể được mở rộng ra ngoài âm thanh để áp dụng cho bất kỳ loại vấn đề dự báo chuỗi thời gian, để nắm bắt các mối phụ thuộc dài hạn mà không cần quá nhiều tham số.

#### 2.4. Nút hồi quy có cổng GRU

Trong nghiên cứu [38], [39] mạng bộ nhớ dài hạn/ngắn (LSTM) có thể giải quyết vấn đề bùng nổ gradient và biến mất gradient trong RNN, và LSTM đã được sử dụng rộng rãi trong lĩnh vực xử lý dữ liệu trong những năm gần đây.

GRU là một biến thể của LSTM với ít đơn vị nội bộ hơn; nó kết hợp cổng đầu vào và cổng quên thành một cổng cập nhật. Nó dễ thực hiện quy trình đào tạo và tiết kiệm thời gian tính toán hơn so với LSTM. Cấu trúc phụ của GRU được thể hiện trong



Hình 2.6 chỉ có hai cổng: cụ thể là cổng cập nhật và cổng đặt lại. Mô tả toán học của nó được thể hiện trong công thức (2.19).

**Hình 2.6:** Kiến trúc GRU [38]

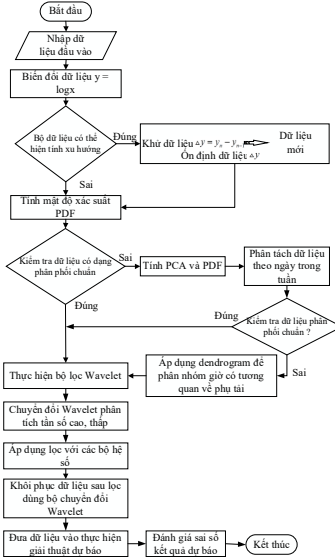
$$\begin{cases} r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \\ z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \\ \tilde{h}_t = \phi(W_{\tilde{h}} \cdot [r_t \times h_{t-1}, x_t]) \\ h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \\ y_t = \sigma(W_o \cdot h_t) \end{cases} \quad (2.8)$$

## 2.5. Phép biến đổi Wavelet

Nghiên cứu [40], [41], [42], phương pháp biến đổi Wavelet được sử dụng nhiều trong các nghiên cứu, 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 mô hình toán Wavelet như sau:

Một lớp các hàm số có bình phương khả tích có thể biểu diễn bằng phép biến đổi Wavelet.

Một trong những ứng dụng quan trọng của phép biến đổi wavelet là lọc nhiễu, đặc biệt là trong xử lý hình ảnh và tín hiệu. Wavelet có khả năng tách biệt thông tin hữu ích khỏi nhiễu do nó cho phép phân biệt giữa các thành phần ở các mức độ chi tiết khác nhau. Trong quá trình lọc nhiễu, các hệ số wavelet mà phản ánh nhiễu thường nhỏ hơn và có thể được giảm bớt hoặc loại bỏ, trong khi giữ lại các hệ số đại diện cho thông tin quan trọng.



Hình 2.7: Lưu đồ giải thuật bộ lọc Wavelet

$$f(x) \in L^2(R) \Rightarrow \int_{-\infty}^{\infty} |f(x)|^2 dx < \infty \quad (2.9)$$

$$\psi_{s,\tau}(x) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{x-\tau}{s}\right) \text{ với } s, \tau \in R, s \neq 0 \quad (2.10)$$

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

**Bước 1:** dữ liệu đầu vào thô

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

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

**Bước 4:** tính mật độ xác suất PDF cho  $\Delta Y$

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2.11)$$

$$\Sigma = \frac{1}{n-1} X^T X \quad (2.12)$$

$$\text{Biến đổi } Z: Z = XW \quad (2.13)$$

$$\text{- Ma trận hiệp phương sai: } \Sigma = \frac{1}{n-1} X^T X \quad (2.14)$$

$$\text{- Phương trình giá trị riêng: } \Sigma U = \lambda U \quad (2.15)$$

$$\text{- Biến đổi dữ liệu: } Z = XW \quad (2.16)$$

Thuật toán phân cụm thứ bậc:

**Bước 1:** Tính toán khoảng cách giữa tất cả các cặp điểm trong tập dữ liệu.

**Bước 5:** Tính Dendrogram theo các nhóm Thứ 7 và Chủ nhật để tách thành các nhóm giờ.

Công thức Dendrogram

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (2.17)$$

Khoảng cách giữa các cụm: Liên kết đơn:

$$d(A, B) = \min \{d(x_i, x_j) | x_i \in A, x_j \in B\} \quad (2.18)$$

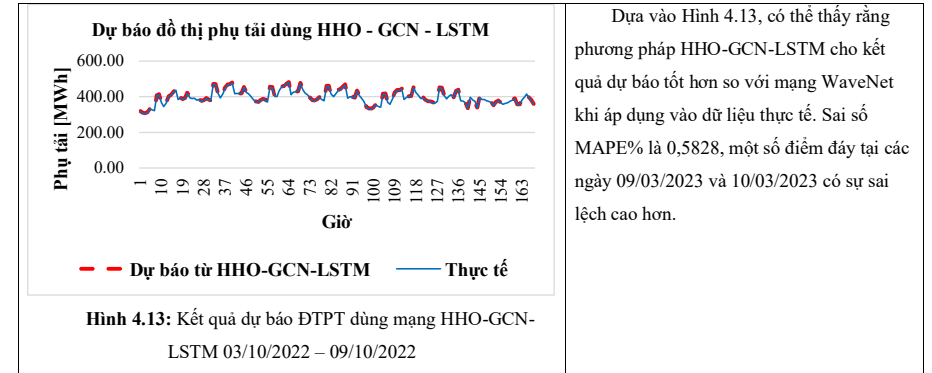
Liên kết hoàn chỉnh:

$$d(A, B) = \max \{d(x_i, x_j) | x_i \in A, x_j \in B\} \quad (2.19)$$

mô hình RMSprop-WaveNet, MAPE đã giảm xuống còn 0,51. Thuật toán HHO được đề xuất được tối ưu hóa cho mạng WaveNet, kết quả được cải thiện đáng kể với MAPE là 0,3%.


Tóm lại, HHO được thiết kế để hoạt động hiệu quả trong không gian tham số rộng nhờ khả năng khám phá và khai thác tốt, giúp tìm kiếm tối ưu trên các miền tham số lớn và phức tạp. Khả năng chuyển đổi linh hoạt giữa tìm kiếm và khai thác trong HHO giúp cân bằng hiệu quả giữa việc duyệt toàn bộ không gian tham số và tối ưu hoá cục bộ, điều này cho phép HHO tránh rơi vào cực trị cục bộ và cải thiện chất lượng tính toán. Ngoài ra, thuật toán HHO giảm đáng kể thời gian tính toán so với các phương pháp cổ điển nhờ vào cơ chế tối ưu hoá đơn giản và hiệu quả trong việc hội tụ nhanh đến vùng tối ưu. Đây là các yếu tố làm cho HHO phù hợp với các bài toán có không gian tham số lớn và phức tạp.

### Kết quả dự báo mô hình đề xuất dự báo ĐTPT



Hình 4.13: Kết quả dự báo ĐTPT dùng mạng HHO-GCN-LSTM 03/10/2022 – 09/10/2022

### Dự báo đồ thị phụ tải dùng Wavelet-HHO-GCN-LSTM



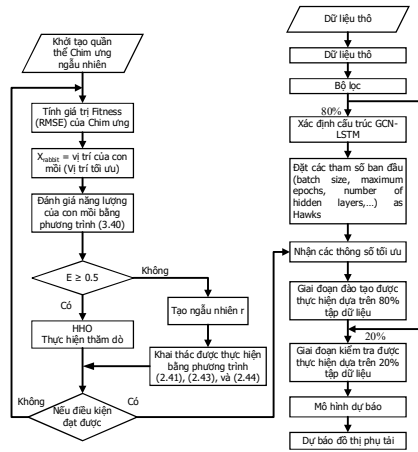
Hình 4.14: Kết quả dự báo ĐTPT dùng Bộ lọc Wavelet-HHO-GCN-LSTM từ ngày 03/10/2022 – 07/10/2022

Dựa vào đồ thị kết quả Hình 4.14 kết quả dự báo từ ngày 03/10/2022 đến 07/10/2022 có thể thấy rằng mô hình Wavelet-HHO-GCN-LSTM cho kết quả dự báo rất tốt khi áp dụng vào dữ liệu thực tế.

đến ngày 04/12/2023 của khu vực lưới điện Tiền Giang nhằm giảm thiểu các dữ liệu nhiễu và những dữ liệu sai lệch trong quá trình thu thập dữ liệu. Dữ liệu sau khi xử lý được làm đầu vào cho mô hình đề xuất.

Hình 4.12 minh họa mô hình tích hợp giữa bộ tiền xử lý dữ liệu Wavelet kết hợp với giải thuật HHO-GCN-LSTM. Trong GCN-LSTM các trọng số trong quá trình huấn luyện nhờ vào thuật toán tối ưu hóa HHO. Dữ liệu sau khi được lọc bằng bộ lọc Wavelet được chia thành hai bộ dữ liệu: 80% nguồn dữ liệu dùng để huấn tạo mô hình, 20% còn lại dùng để dự báo.

**Hình 4.12:** Giải thuật đề xuất tích hợp Bộ lọc Wavelet – HHO – GCN – LSTM



Nghiên cứu [73], HHO thường được dùng để tối ưu hóa các bài toán phức tạp như: mạng lưới phân phối điện, các bài toán đa mục tiêu, tối ưu hóa trong học máy. Trong thuật toán HHO,  $X_{rabbit}$  không được tính toán trực tiếp bằng một công thức cụ thể, mà nó là vị trí tốt nhất hiện tại tại quần thể, tương ứng với cá thể có giá trị hàm fitness nhỏ nhất (hoặc tốt nhất, tùy thuộc vào bài toán tối ưu).

**Bảng 4.2:** Thông số huấn luyện mạng HHO-GCN-LSTM

Tham số trong mô hình huấn luyện	Giá trị
Learning rate (Tần suất huấn luyện)	0,03
Dim (Số chiều mẫu đầu vào đưa vào từng lần huấn luyện)	24
Lb (Giá trị thấp nhất của dữ liệu)	0
Ub (Giá trị cao nhất của dữ liệu)	5000
Popsiz (Kích thước quần thể cho thuật toán tối ưu sử dụng cho mạng huấn luyện)	50
Maxiter (Số Chu kỳ lặp cho thuật toán tối ưu sử dụng cho mạng huấn luyện)	100
Epochs (Số lần lặp huấn luyện)	25
Bach_size (Kích thước khung dữ liệu được lấy trên 1 lần lặp huấn luyện)	10

Tương tự dự báo phụ tải đỉnh, kết quả dự báo từ sau mô hình huấn luyện dưới dạng số thập phân trong miền [0, 1] được áp dụng chuyển đổi ngược với hàm chuẩn hóa ban đầu (có sử dụng hàm logarit và hàm mũ) và được cộng với giá trị cơ sở ban đầu – được dùng trong quá trình chuyển đổi dữ liệu sang các nhóm phân phối chuẩn. Sau khi chuyển đổi ngược giá trị về miền giá trị thực, kết quả sau sẽ được đánh giá sai số với giá trị thực tế.

*So sánh thuật toán HHO với các thuật toán tối ưu khác*

Kết quả nghiên cứu thể hiện trong Bảng 4.3 cho thấy hiệu suất của các mô hình được đề cập. Mô hình HHO-WaveNet hoạt động tốt hơn các mô hình SGD-WaveNet, Adagrad-WaveNet, RMSprop-WaveNet, và Adam-WaveNet chỉ số sai số phần trăm tuyệt đối trung bình, MAPE cho thấy rõ tính ưu việt của phương pháp đề xuất. Trong đó, mô hình đề xuất cho các số liệu thấp hơn nhiều so với các phương pháp được so sánh.

**Bảng 4.3:** Kết quả dự báo của các thuật toán tối ưu kết hợp mạng WaveNet

Mô hình	RMSE	MAPE (%)
SGD- WaveNet	101,48	0,58
Adagrad-WaveNet	323,74	1,69
Adam-WaveNet	1062,31	4,49
RMSprop-WaveNet	95,93	0,51
HHO-WaveNet	56,13	0,30

Theo kết quả thể hiện trong Bảng 4.3, mô hình dự báo sử dụng Adam-WaveNet có sai số cao nhất MAPE là 4,49. Các mô hình Adagrad-WaveNet và SGD-WaveNet cho kết quả lỗi MAPE tốt hơn lần lượt là 1,69% và 0,58%. Trong

**Bước 2:** Tìm cặp cụm có khoảng cách nhỏ nhất và hợp nhất chúng thành một cụm mới.

**Bước 3:** Tính toán lại khoảng cách giữa cụm mới và tất cả các cụm còn lại.


**Bước 4:** Lặp lại bước 2 và 3 cho đến khi tất cả các điểm được hợp nhất thành một cụm duy nhất.

**Bước 5:** Thực hiện lọc Wavelet với các nhóm dữ liệu trên Thứ 7, Chủ nhật các nhóm theo giờ và các ngày còn lại là một nhóm áp dụng lọc với các bộ hệ số lên dữ liệu đã biến đổi trên các miền tần số, biến đổi ngược: khôi phục dữ liệu từ miền tần số sang miền thời gian.

**Bước 6:** Sử dụng dữ liệu sau lọc vào dự báo

## 2.6. Giải thuật HHO

Trong nghiên cứu [43], [44], mô hình hoá các giai đoạn khám phá và khai thác của HHO được đề xuất lấy cảm hứng từ việc khám phá con mồi, vỗ bắt ngờ và các chiến lược tấn công khác nhau của điều hâu Harris. HHO là một kỹ thuật tối ưu hóa không có độ dốc, dựa trên quần thể. Do đó, nó có thể được áp dụng cho bất kỳ bài toán tối ưu hóa nào.



**Hình 2.8:** Các giai đoạn HHO

- Giai đoạn thăm dò


$$X(t+1) = \begin{cases} X_{rand}(t) - r_1 |X_{rand}(t) - 2r_2 X(t)| & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3(LB + r_4(UB - LB)) & q < 0.5 \end{cases} \quad (2.20)$$

$$X_m(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \quad (2.21)$$

- Chuyển đổi từ thăm dò sang khai thác

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \quad (2.22)$$

- Giai đoạn khai thác



- Vây bắt nhẹ

$$X(t+1) = \Delta X(t) - E |JX_{rabbit}(t) - X(t)| \quad (2.23)$$

$$\Delta X(t) = X_{rabbit}(t) - X(t) \quad (2.24)$$


- Vây bắt gắt gao

$$X(t+1) = X_{rabbit}(t) - E |\Delta X(t)| \quad (2.25)$$

**Hình 2.9:** Ví dụ về vector tổng thể trong trường hợp bị

vây bắt gắt gao [43]

- Vây bắt mềm với tiến nhanh liên tục



mềm với tiến nhanh liên tục [43]

$$Y = X_{rabbit}(t) - E |JX_{rabbit}(t) - X(t)| \quad (2.26)$$

$$Z = Y + S \times LF(D) \quad (2.27)$$

$$LF(x) = 0.01 \times \frac{u \times \sigma}{|v|^\beta}, \sigma = \left( \frac{r(1+\beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{r\left(\frac{1+\beta}{2}\right) \times \beta \times 2^{\left(\frac{\beta-1}{2}\right)}} \right)^{\frac{1}{\beta}} \quad (2.28)$$

**Hình 2.10:** Ví dụ về các vector tổng thể trong trường hợp vây bắt

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(X) < F(X(t)) \end{cases} \quad (2.29)$$

- Vậy bắt gát gao với tiến nhanh liên tục

## 2.7. Lý thuyết mô hình GCN

Nghiên cứu [45], [46], [47], mạng tích chập đồ thị GCN: Trích xuất được đặc trưng không gian và thời gian từ nguồn dữ liệu thu thập.

*Định nghĩa biểu diễn dữ liệu theo không gian:* sự phụ thuộc không gian của dữ liệu là mối quan hệ giữa các giá trị phụ tải tại các nút trong cùng một thời điểm xét, là yếu tố then chốt trong việc giải quyết bài toán DBPT.

Đối với DBPT định:

$$G = (V, E) = X_t = G_t = \begin{bmatrix} P_{\max 1} & T_1^0 \\ P_{\max 2} & T_2^0 \\ P_{\max 3} & T_3^0 \end{bmatrix} \quad (2.33)$$

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(X) < F(X(t)) \end{cases} \quad (2.30)$$

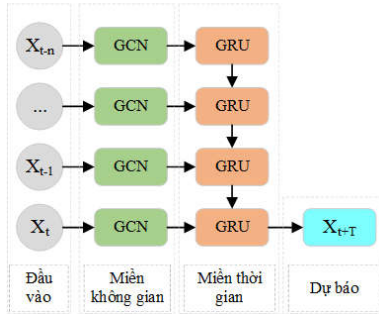
$$Y = X_{\text{rabbit}}(t) - E |JX_{\text{rabbit}}(t) - X_m(t)| \quad (2.31)$$

$$Z = Y + S + LF(D) \quad (2.32)$$

Đối với dự báo đồ thị phụ tải:

$$G = (V, E) = X_t = G_t = \begin{bmatrix} A_1 & T_{11}^0 \\ \vdots & \vdots \\ A_{24} & T_{24}^0 \end{bmatrix} \quad (2.34)$$


$$[X_{t+1}, \dots, X_{t+T}] = f(G, (X_{t-n}, \dots, X_{t-1}, X_t)) \quad (2.35)$$



Hình 2.11: Mạng chuyển đổi GCN và GRU

## 2.8. Kết luận chương


Chương 2 nghiên cứu đã tập trung vào việc phân tích các yếu tố ảnh hưởng đến hành vi tiêu thụ điện dựa trên tập dữ liệu quá khứ thu được từ số liệu lưới điện Tiền Giang, nhằm lựa chọn các biến đầu vào trong mô hình dự báo đề xuất. Thêm vào đó nghiên cứu đã nêu được lý do, vai trò và tầm quan trọng trong dự báo, phân loại dự báo và tổng hợp các phương pháp dự báo PTĐ từ phương pháp cổ điển và mạng học sâu các mô hình kết hợp. Ngoài ra trong chương đã trình bày đầy đủ các mạng học sâu được sử dụng trong nghiên cứu. Đặc biệt xây dựng lưu đồ giải thuật bộ lọc Wavelet, nhằm xử lý dữ liệu đầu vào nâng cao nguồn chất lượng dữ liệu trước khi đưa vào mô hình dự báo, ngoài ra thuật toán HHO được đề xuất nhằm tối ưu hoá bộ trọng số mạng nơron học sâu GCN-LSTM trong quá trình huấn luyện mạng tạo mô hình dự báo ĐTPT. Sau cùng nghiên cứu đã xây dựng được mô hình tổng quan dự báo PTĐ nói chung dựa trên mạng học sâu, làm tiền đề cho chương 3 và chương 4.



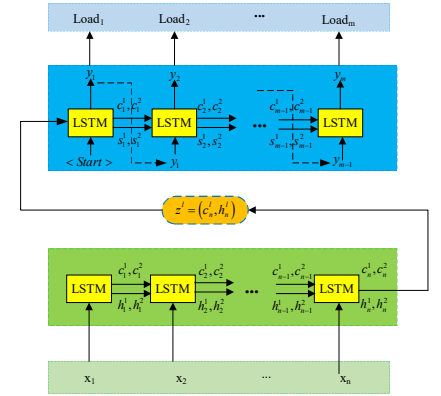
Hình 2.12: Mô hình mẫu cho mạng GCN

## 4.3.2. Dự báo đồ thị phụ tải sử dụng mô hình Seq2Seq-LSTM

Luận án đã đề xuất mô hình thứ hai để dự báo ĐTPT, nhằm cải thiện độ chính xác của kết quả dự báo đồ thị phụ tải điện so với mô hình thứ nhất. Mô hình đã phát triển từ dự báo chuỗi sang chuỗi bằng cách kết hợp nhiều mạng LSTM, đầu vào không đều, mô hình này hỗ trợ ngõ vào và ngõ ra có độ dài thay đổi được, nhằm cải thiện ở mô hình một, nâng cao độ chính xác của kết quả dự báo. Thực chất của Seq2Seq-LSTM là mạng LSTM được áp dụng để mã hoá và giải mã. Đầu vào của bộ mã hoá là một chuỗi có độ dài thay đổi được sau đó chuỗi dữ liệu đầu vào được chuyển đổi ở một trạng thái đã được mã hoá nhờ vào mạng LSTM. Bộ giải mã thực chất cũng là một mạng LSTM, nó chuyển đổi trạng thái mã hóa từ định dạng cố định thành chuỗi có độ dài thay đổi được. Được gọi là mô hình mã hoá – giải mã được minh họa trong Hình 4.9.




Hình 4.9: Sơ đồ mã hoá – giải mã.



Hình 4.10: Mô hình Seq2Seq-LSTM

Hình 4.10 mô tả mô hình LSTM kết hợp Seq2Seq được đề xuất để tiên đoán đồ thị phụ tải điện. Chuỗi dữ liệu đầu vào  $X = (x_1, x_2, \dots, x_n)$ , nó được mã hoá nhờ vào mạng LSTM đa tầng, và trạng thái ẩn  $h = (h_1, h_2, \dots, h_n)$  đầu ra của tầng LSTM thứ nhất dùng làm đầu vào mạng LSTM thứ hai.

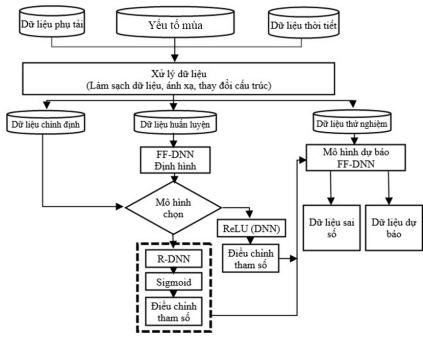


Hình 4.11: Kết quả dự báo ĐTPT dùng mạng Seq2Seq-LSTM ngày 03/10/2022 – 09/10/2022

## 4.3.3. Dự báo đồ thị phụ tải sử dụng mô hình bộ lọc Wavelet-HHO-GCN-LSTM

Trong bài toán STLF, luận án này đã đề xuất mô hình HHO-GCN-LSTM, có xem xét đến độ tin cậy của bộ dữ liệu đầu vào nhờ vào bộ tiền xử lý dữ liệu đầu vào Wavelet [79], [80], dữ liệu là nguồn sản lượng điện từ ngày 01/01/2020

### 4.3.1. Dự báo đô thị phụ tải sử dụng FF-DNN và R-DNN




**Hình 4.7:** Kiến trúc mô hình FF-DNN và R-DNN

Luận án đề xuất mô hình thứ nhất trong bài toán dự báo ĐTPT một kết hợp sử dụng các kỹ thuật học sâu như FF-DNN và R-DNN, sơ đồ thuật toán được thể hiện như Hình 4.7 phương pháp này cho kết quả dự báo nhanh hơn và chính xác hơn. Nghiên cứu đề xuất rằng chiến lược thuật toán để dự báo ngắn hạn dựa trên các kỹ thuật học sâu, trong đó kết quả của mỗi mô-đun trước được dùng làm đầu vào cho các mô-đun tiếp theo.

**Bảng 4.1:** Các thông số mô phỏng

Thông số đầu vào	Các giá trị
Tổng thời gian lấy mẫu	34416
Dữ liệu huấn luyện	27533
Dữ liệu thử nghiệm	6883
Thuật toán huấn luyện	trainlm
Các ngày trong tuần	[1 ~ 7]
Giờ trong ngày	[0 ~ 23]
Learning rate (Tần suất huấn luyện)	0,05
Dim (Số chiều mẫu đầu vào đưa vào từng lần huấn luyện)	3
Lb (Giá trị thấp nhất của dữ liệu)	0
Ub (Giá trị cao nhất của dữ liệu)	5000
Popsiz (Kích thước phần tử cho thuật toán tối ưu sử dụng cho mạng huấn luyện)	50
Maxiter (Số Chu kỳ lặp cho thuật toán tối ưu sử dụng cho mạng huấn luyện)	100
Epochs (Số lần lặp huấn luyện)	25
Bach_size (Kích thước khung dữ liệu được lấy trên 1 lần lặp huấn luyện)	10




**Hình 4.8:** Kết quả dự báo ĐTPT dùng mạng FFDNN-RDNN từ ngày 03/10/2022 – 09/10/2022

## CHƯƠNG 3. DỰ BÁO PHỤ TẢI ĐỈNH

### 3.1. Giới thiệu vấn đề nghiên cứu

Phụ tải đỉnh là giá trị cực đại của đường cong nhu cầu điện trong ngày [64]. Dự báo phụ tải đỉnh đóng vai trò quan trọng trong huy động, phối hợp và lập kế hoạch vận hành HTĐ, đảm bảo lưới điện ổn định và đáp ứng chính sách môi trường. Tuy nhiên, dự báo chính xác vẫn là thách thức do tính phi tuyến và nhiễu động của dữ liệu. Các mô hình chuỗi thời gian và hồi quy truyền thống gặp khó khăn trong việc nắm bắt quan hệ phi tuyến giữa đầu vào và đầu ra. Dữ liệu chuỗi thời gian có dung lượng lớn, phi tuyến và nhiễu động, đòi hỏi các thuật toán tiên tiến hơn. Xu hướng hiện nay là kết hợp mô hình thống kê với máy học và học sâu để cải thiện hiệu suất dự báo [65].

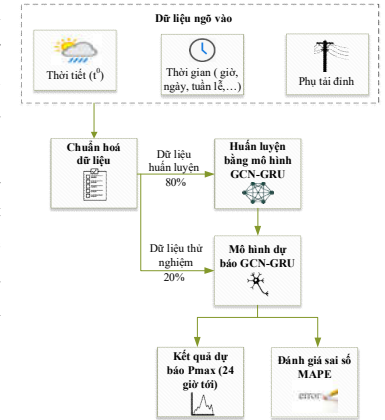
Mô hình RNN-LSTM [40] dự báo phụ tải đỉnh với MAPE 8,6%, nhỏ hơn tiêu chuẩn 10%. Dự báo phụ tải đỉnh ngày là yếu tố quan trọng trong lưới điện thông minh, giúp tối ưu hóa cân bằng tải [64]. Mô hình đa độ phân giải [66] kết hợp thông tin độ phân giải cao và thấp để dự báo thời điểm và kích thước phụ tải đỉnh, giúp giảm chi phí năng lượng khi áp dụng biện pháp tiết kiệm trong giờ cao điểm. Mô hình Bi-LSTM chuỗi sang chuỗi [67] dự báo phụ tải đỉnh 24 giờ tới, có thể áp dụng cho cả ngày lễ và ngày bình thường. Tuy nhiên, dữ liệu ngày lễ thường hạn chế, gây khó khăn trong dự báo chính xác. Nghiên cứu [41] [68] xây dựng mô hình tổng quát hóa dự báo công suất đỉnh Pmax dựa trên dữ liệu quá khứ và các yếu tố không gian, thời gian. Qua đó, nghiên cứu đã xây dựng khái quát hoá mô hình dự báo công suất đỉnh Pmax (Hình 3.1).



**Hình 3.1:** Quy trình thực hiện dữ liệu cho dự báo phụ tải đỉnh

Các biến đầu vào được xác định bởi các yếu tố tác động đến hành vi tiêu thụ điện năng từ Hình 3.1 luận án đề xuất giải thuật dự báo công suất đỉnh cho ngày tới, mô hình kết hợp GCN-GRU, sai số phần trăm tuyệt đối trung bình MAPE là chỉ số đánh giá hiệu suất của mô hình đề xuất.

Hình 3.2 minh họa sơ đồ tổng quan mô hình dự báo Pmax dựa trên mạng học sâu, với dữ liệu ngõ vào bao gồm phụ tải đỉnh, nhiệt độ tại thời điểm Pmax và yếu tố thời gian. Dữ liệu này sau đó được chuẩn hóa, nhằm giảm sự khác biệt về thang đo giữa các biến đầu vào đảm bảo tính đồng nhất, chất lượng và hiệu quả của quá trình huấn luyện mô hình. Tiếp theo, dữ liệu được chia thành hai phần: 80% dùng để huấn luyện và chọn mô hình trong GCN-GRU, 20% còn lại dùng để chạy dự báo.




**Hình 3.2:** Sơ đồ tổng quan mô hình dự báo Pmax

### 3.2. Phân tích và đánh giá dữ liệu quá khứ công suất đỉnh khu vực lưới điện Tiền Giang

Dựa vào phân tích dữ liệu phụ tải đỉnh trong một tuần như Hình 3.3, khung đồ đánh dấu cho mẫu 1 ngày. Trong một ngày được thể hiện trên đồ thị cho thấy dữ liệu phân bố chia phụ tải đỉnh thành 3 điểm cao nhất trong ngày, và các ngày còn lại trong tuần cũng tương đồng có 3 đỉnh tương tự. Đối với ngày cuối tuần (Chủ Nhật) thì khác biệt các đỉnh không rõ rệt (thể hiện hoạt động sử dụng điện giảm đáng kể). Qua đó, nghiên cứu phân tích theo đặc điểm thực tế của



phụ tải đỉnh khu vực lưới điện Tiền Giang; thực hiện chia phụ tải đỉnh trong ngày thành 3 nhóm khung giờ: từ 0h đến 11h00, từ 11h00 đến 17h00 và từ 17h00 – 23h59. Nghiên cứu chọn các điểm phụ tải đỉnh (phụ tải cao nhất tại mỗi khung giờ) và tương ứng với dữ liệu nhiệt độ tại các điểm phụ tải đỉnh đó. Kết quả mối quan hệ giữa phụ tải đỉnh theo 3 khung giờ và nhiệt độ được thể hiện như Hình 3.3.




**Hình 3.3:** Phụ tải đỉnh và nhiệt độ theo khung giờ trong 1 tuần của Tiền Giang

### 3.3. Mô hình đề xuất dự báo công suất đỉnh Pmax – áp dụng dữ liệu Tiền Giang

#### 3.3.1. Kiến trúc 1 ô nhớ GCN-GRU

Hình 3.4 minh họa, bên trái là mô hình GCN và bên phải là cấu trúc cụ thể của một ô GRU. Công thức (2.21) 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 3.4:** Kiến trúc chi tiết của một đơn vị GCN-GRU [41]

#### 3.3.2. Phân tích dữ liệu phụ thuộc vào không gian


$$X_t = G = (V, E) \tag{3.1} \quad E = (P_{max} - T^0) \tag{3.3}$$

$$G_t = \begin{bmatrix} P_{max1} & T_1^0 \\ P_{max2} & T_2^0 \\ P_{max3} & T_3^0 \end{bmatrix} \tag{3.2} \quad V = \{E_1, E_2, E_3\} \tag{3.4}$$

#### 3.3.3. Phân tích dữ liệu phụ thuộc theo thời gian

$$X^{NsP} = \{X_t\}_{Dngày} = \{G(V, E)\}_{Dngày} \tag{3.5}$$

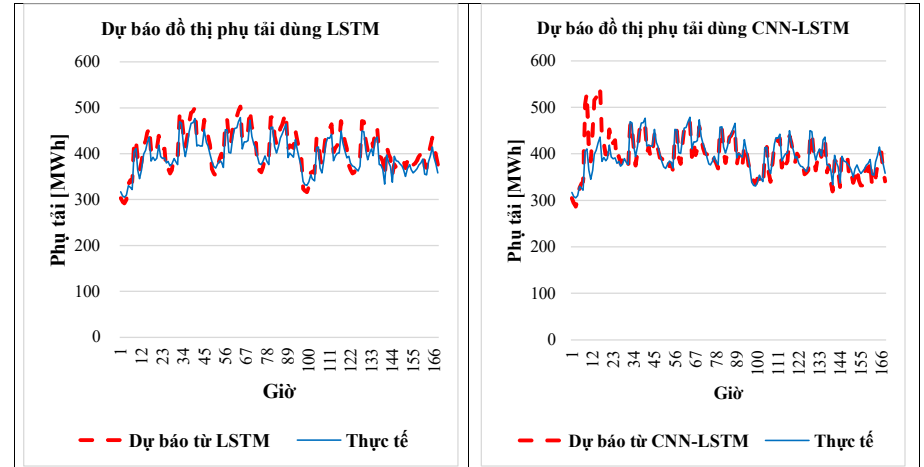
#### 3.3.4. Mối tương quan giữa không gian và thời gian công suất đỉnh



**Hình 3.5:** Mối quan hệ sự phụ thuộc không gian và thời gian  
Nghiên cứu [41], dữ liệu trong bài toán DBPT đỉnh thể hiện sự phụ thuộc theo Hình 3.5.


#### 3.3.5. Mô hình đề xuất

## 4.2. Mô hình dự báo đồ thị phụ tải thông dụng




**Hình 4.3:** Kết quả dự báo ĐTPPT dùng mạng LSTM ngày 03/10/2022 – 09/10/2022

**Hình 4.4:** Kết quả dự báo ĐTPPT dùng mạng CNN-LSTM từ 03/10/2022 – 09/10/2022



**Hình 4.5:** Kết quả dự báo ĐTPPT dùng mạng WaveNet ngày 03/10/2022 – 09/10/2022

## 4.3. Mô hình đề xuất dự báo đồ thị phụ tải




**Hình 4.6:** Biểu diễn sự phụ thuộc giữa không gian và thời gian trong tập dữ liệu của bài toán DBPT điện

## CHƯƠNG 4. DỰ BÁO ĐỒ THỊ PHỤ TẢI

### 4.1. Giới thiệu vấn đề nghiên cứu

Phụ tải điện: Các thiết bị tiêu thụ điện được kết nối vào lưới điện, tiêu thụ năng lượng điện và chuyển đổi nó thành các dạng năng lượng khác (ánh sáng, cơ năng hoặc nhiệt năng). Các thiết bị này tiêu thụ năng lượng điện dưới dạng dòng điện theo đơn vị thời gian. Đơn vị đo của phụ tải điện là [MWh]. Biểu đồ phụ tải điện biểu diễn đặc tính tiêu thụ điện theo thời gian của hệ thống, các thành phần, nhóm và phân nhóm PTĐ.

Trong [71], ngành điện đối mặt với nhiều thách thức trong phân tích dòng công suất, lập kế hoạch và kiểm soát HTĐ. STLF có nhiều nghiên cứu nhằm nâng cao độ chính xác dự báo. Trong [43], [51], [72], Wavelet được dùng để tiền xử lý dữ liệu. Nghiên cứu [60], [73] ứng dụng HHO tối ưu trọng số mạng nơ-ron. Trong [41], T-GCN được áp dụng trong dự báo. Mạng tích chập đồ thị [74] kết hợp GCN và GRU để học phụ thuộc không gian và thời gian. CNN xử lý đặc điểm không gian, trong khi GCN mở rộng cho dữ liệu đồ thị. RNN thường dùng cho chuỗi thời gian nhưng gặp hạn chế, được cải thiện bởi LSTM, GRU [75], [76]. Nghiên cứu [70] chứng minh LSTM và GRU là biến thể của RNN.

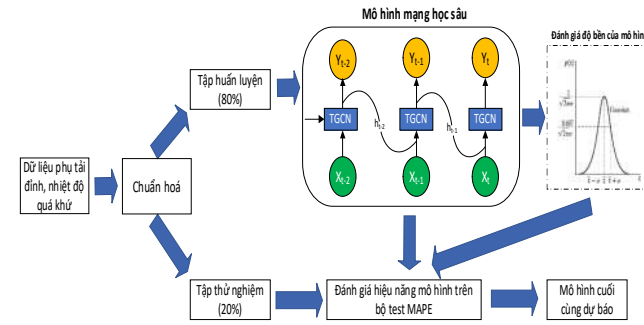


Hình 4.1: Phương pháp sử dụng dữ liệu cho dự báo đồ thị phụ tải

Qua đó trong luận án này đề xuất mô hình kết hợp để giải bài toán dự báo đồ thị phụ tải, dựa vào phương trình (2.35) làm cơ sở, nhằm nâng cao nguồn dữ liệu đầu vào dùng bộ lọc Wavelet thuật toán tối ưu hoá HHO cho mạng GCN-LSTM.

Hình 4.2: Sơ đồ tổng quan mô hình dự báo đồ thị phụ tải

Hình 4.2 trình bày sơ đồ tổng quan của mô hình STLF, dữ liệu ngõ vào thô sau khi qua khâu chuẩn hoá (nhằm giảm kích thước và đảm bảo tính nhất quán của nguồn dữ liệu) được đưa qua bộ lọc Wavelet, nhằm nâng cao chất lượng của nguồn dữ liệu đầu vào do sai số trong quá trình đo lường cũng như giá trị sản lượng của phụ tải của từng thời điểm không đồng đều nhau, tập dữ liệu được tách làm 2 thành phần, thành phần thứ 1 (80% tương ứng 27533 mẫu tương đương 1147 ngày) dùng tạo mô hình huấn luyện, thành phần thứ 2 (20% tương ứng 6883 mẫu tương đương 287 ngày) để tạo mô hình. Trong quá trình huấn luyện mạng nơ-ron học sâu GCN-LSTM với mục đích hàm loss được giảm sai số trong thời gian sớm nhất, thuật toán tối ưu hoá HHO được dùng nhằm tối ưu bộ trọng số của mạng nơ-ron trong quá trình huấn luyện. Kết thúc quá trình này mô hình dự báo được chọn, thông số sai số phần trăm tuyệt đối trung bình MAPE là chỉ số được đánh giá cho mô hình.



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

Mô hình dự báo công suất đỉnh Pmax được đề xuất GCN-GRU (T-GCN), sử dụng các biến sau đây làm đầu vào, 3 giá trị Pmax trong ngày tương ứng với nhiệt độ Tmax tại điểm đỉnh Pmax trong ngày. Quá trình huấn luyện và chạy thử nghiệm cho mô hình

đề xuất, được sử dụng với tập dữ liệu lưới điện Tiền Giang, dữ liệu Pmax và nhiệt độ được thu thập 1434 số mẫu tương ứng 34416 mẫu. Qua quá trình phân tích số điểm đạt đỉnh theo khung giờ trong ngày là 3 đỉnh vậy số đỉnh Pmax tương ứng trong tập dữ liệu là 4302 mẫu.

Dữ liệu đầu vào được chuẩn hóa thành khoảng [0,1]. Sau đó, tập dữ liệu được tách làm 2 thành phần, 80% dữ liệu được sử dụng làm tập huấn luyện (3442 mẫu tương ứng 1147 ngày) và 20% còn lại được sử dụng làm tập thử nghiệm chạy dự báo (860 mẫu tương ứng 287 ngày). 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 mô hình sau khi huấn luyện từ mạng T-GCN chỉ số MAPE được đánh giá cho mô hình, mục đích nhằm đánh giá tính hiệu quả của mô hình dự báo dưới tác động nhiễu Gaussian.

Bảng 3.1: Thông số huấn luyện GCN-GRU

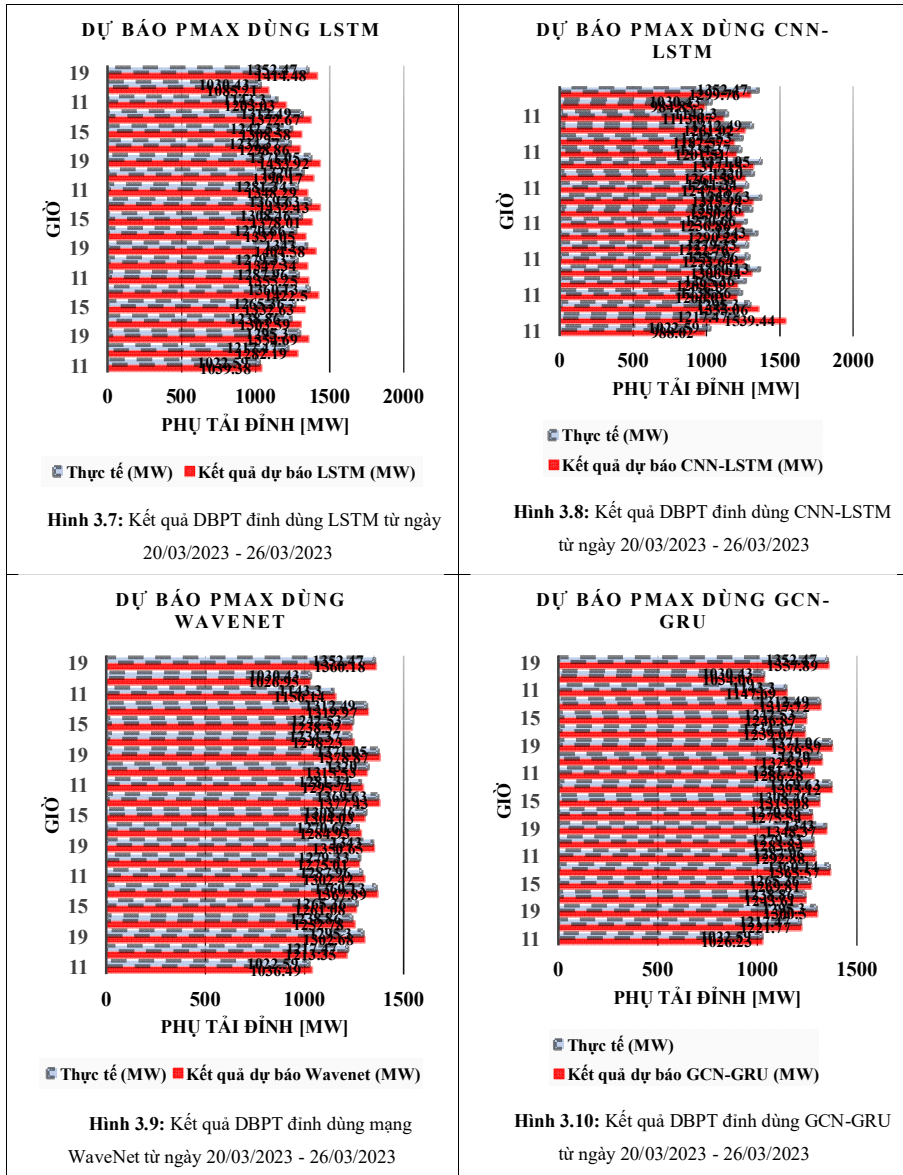
Tham số trong mô hình huấn luyện	Giá trị
Learning rate (Tần suất huấn luyện)	0,05
Dim (Số chiều mẫu đầu vào đưa vào từng lần huấn luyện)	3
Lb (Giá trị thấp nhất của dữ liệu)	0
Ub (Giá trị cao nhất của dữ liệu)	5000
Popsze (Kích thước phân tử cho thuật toán tối ưu sử dụng cho mạng huấn luyện)	50
Maxiter (Số Chu kỳ lặp cho thuật toán tối ưu sử dụng cho mạng huấn luyện)	100
Epochs (Số lần lặp huấn luyện)	25
Bach_size (Kích thước khung dữ liệu được lấy trên 1 lần lặp huấn luyện)	10

Kết quả dự báo từ sau mô hình huấn luyện dưới dạng số thập phân trong miền [0, 1] được áp dụng chuyển đổi ngược với hàm chuẩn hóa ban đầu (có sử dụng hàm logarit và hàm mũ) và được cộng với giá trị cơ sở ban đầu – được dùng trong quá trình chuyển đổi dữ liệu sang các nhóm phân phối chuẩn. Sau khi chuyển đổi ngược giá trị về miền giá trị thực, kết quả sau sẽ được đánh giá sai số với giá trị thực tế để xem xét chọn mô hình dự báo cho sai số tối nhất kết quả dự báo phụ tải đỉnh.

### 3.4. Kết quả dự báo công suất đỉnh Pmax tổng thể

Bảng 3.2: Kết quả dự báo theo các phương pháp khác nhau

Model	MAPE (%)
LSTM	4,7093
CNN-LSTM	4,0972
WaveNet	1,1109
GCN-GRU	0,0006



Qua Bảng 3.2 thống kê kết quả về chỉ số sai số phần trăm tuyệt đối trung bình MAPE% của các phương pháp dự báo công suất đỉnh. Hầu như các phương pháp dự báo, giá trị dự báo và giá trị thực tế bám nhau. Tuy nhiên, sai số MAPE của các phương pháp có sai số khác biệt tại các điểm đỉnh. Mô hình LSTM có MAPE là 4,7093%, sai số còn cao tại các điểm đỉnh khung giờ (11, 15, và 19) giờ, mạng LSTM có hiệu quả trong bài toán dự báo phụ tải đỉnh. Tuy

nhiên, mạng LSTM vẫn còn tồn tại một số hạn chế, LSTM yêu cầu lượng dữ liệu lớn và chất lượng nguồn dữ liệu quá khứ cao để đạt được kết quả tốt, thời gian huấn luyện của mạng LSTM thường khá lâu do cấu trúc phức tạp và nhiều tham số cần tối ưu. Ngoài ra, LSTM không thích nghi với dữ liệu nhiễu nhiều điều này có thể làm giảm độ chính xác của mô hình. Mô hình kết hợp CNN-LSTM có sai số MAPE là 4,0972%, mô hình này sai số có cải thiện hơn so với mô hình LSTM. Nhưng sai số vẫn còn cao tại các điểm đỉnh có sự chênh lệch khá cao giữa giá trị dự báo so với giá trị thực tế tại điểm đỉnh 19 giờ. Tại điểm đỉnh này có sự thay đổi phụ tải lớn (tải sinh hoạt và tải công nghiệp). Mạng CNN-LSTM hạn chế khả năng tổng quát hoá dữ liệu khi có biến động bất thường. Đối với mô hình mạng WaveNet có sai số cải thiện đáng kể so với mô hình LSTM và CNN-LSTM, sai số MAPE là 1,1109, giá trị dự báo và giá trị thực tế bám sát nhau, tại các điểm đỉnh sai số rất bé so với so với mô hình LSTM và CNN-LSTM. Đối với mạng WaveNet, nhờ vào mạng WaveNet (Wavelet-CNN) xử lý tốt mối quan hệ phi tuyến với các đặc trưng phức tạp trong dữ liệu phụ tải đỉnh quá khứ, ngoài ra mạng WaveNet còn sử dụng các lớp tích chập giãn, cho phép mạng học các mối quan hệ dài hạn trong chuỗi dữ liệu. Điều này rất hữu ích khi dự báo phụ tải đỉnh vì xu hướng phụ tải thường có các chu kỳ dài như hàng ngày, hàng tuần, hoặc theo mùa, mạng WaveNet chính là mô hình kết hợp giữa bộ lọc Wavelet với CNN, trong đó dữ liệu được tiền xử lý bằng cách loại bỏ nhiễu nhờ vào bộ lọc Wavelet trước khi đưa vào mạng CNN để thực hiện dự báo. Mô hình được đề xuất trong luận án để dự báo công suất đỉnh là GCN-GRU, mạng tích chập đồ thị với cổng hồi quy. Tiếp cận với hướng phân tích và đánh giá mới về sự phụ thuộc dữ liệu trong bài toán dự báo phụ tải đỉnh, sự phụ thuộc theo mô hình không gian và thời gian. Do đó, sai số của mô hình đề xuất dự báo GCN-GRU có sai số MAPE là 0,0006%, tại các điểm đỉnh trong các khung giờ không còn tồn tại sai số, mô hình GCN-GRU khai thác hiệu quả sự phụ thuộc không gian từ thông tin dữ liệu quá khứ, và GRU xử lý hiệu quả dữ liệu chuỗi thời gian đảm bảo tính liên kết và kết quả dự báo chính xác. Kết quả chứng tỏ mô hình đề xuất dự báo công suất đỉnh GCN-GRU có MAPE phù hợp với các quy định của cục điều tiết điện lực.

### 3.5. Kết luận chương

Trong chương 3, nghiên cứu thực hiện dự báo công suất đỉnh và mô hình đề xuất được thử nghiệm với số liệu lưới điện Tiền Giang. Qua việc phân tích các yếu tố ảnh hưởng tích cực đến công suất đỉnh, nghiên cứu đã chọn các biến ngõ vào là: công suất đỉnh quá khứ, nhiệt độ, và yếu tố mùa (được trình bày ở phụ lục 1 và phụ lục 3). Tập dữ liệu trong nghiên cứu được thu thập từ lưới điện Tiền Giang từ ngày 01/01/2020 đến ngày 04/12/2023, qua việc phân tích và đánh giá số liệu quá khứ của công suất đỉnh, các điểm đạt đỉnh trong ngày là 3 điểm đỉnh, nghiên cứu bước đầu tiên đã thực hiện mô hình dự báo phụ tải đỉnh các mô hình học sâu thông dụng LSTM, CNN-LSTM, và mạng WaveNet. Trong đó mô hình LSTM và CNN-LSTM có giá trị dự báo và giá trị thực tế bám nhau. Tuy nhiên, sai số của hai phương pháp này còn cao tại các điểm đỉnh trong ngày, do ảnh hưởng của sự biến đổi nhiệt độ, tải sinh hoạt, sản xuất tại các giờ trong ngày.

Đối với mô hình mạng WaveNet có sai số bé tại các điểm đỉnh, hiệu năng của mô hình cải thiện đáng kể. Trên nền tảng kết quả 3 mô hình dự báo thông dụng, nghiên cứu đã xây dựng mô hình dự báo công suất đỉnh GCN-GRU, nhờ vào khả năng xử lý dữ liệu không gian và thời gian của GCN. Mạng GCN có thể học được mối quan hệ dữ liệu giữa các nút, GRU xử lý dữ liệu chuỗi thời gian, chuỗi dữ liệu lịch sử phụ tải và thời gian xảy ra đỉnh phụ tải, giúp nắm bắt tính xu hướng và tính chu kỳ của dữ liệu. 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 mạng WaveNet sự khác biệt là ở chỗ GCN được kết hợp thay vì mạng WaveNet, nhằm nâng cao độ tin cậy của nguồn dữ liệu quá khứ thu thập được cải thiện được sai số MAPE là 0,0006%, hiệu năng của mô hình đề xuất cải thiện đáng kể chỉ số MAPE đáp ứng phù hợp tiêu chí đo lường về chỉ số sai số phần trăm tuyệt đối trung bình.