

MÔ HÌNH KẾT HỢP HHO-GCN-LSTM ỨNG DỤNG TRONG DỰ BÁO ĐỒ THỊ PHỤ TẢI CHO LƯỚI ĐIỆN NHỎ

HHO-GCN-LSTM APPLY IN LOADPROFILE FORECASTING FOR MICROGRID

Dương Ngọc Hùng^{1,2}, Nguyễn Tùng Linh^{3,*},
Nguyễn Thanh Hoan⁴, Nguyễn Minh Tâm²

TÓM TẮT

Dự báo biểu đồ phụ tải điện được quan tâm nhiều trong quản lý năng lượng của microgrid (MG). Nhu cầu trong việc xác định biểu đồ phụ tải chính xác trong ngắn hạn là đặc biệt quan trọng để quản lý điện năng hiệu quả cho MG. Bài báo này đề xuất một phương pháp mới để dự báo phụ tải ngắn hạn (STLF). Phương pháp này sử dụng chuỗi dữ liệu phụ tải và nhiệt độ theo thời gian được cung cấp cho mô hình dựa trên Mô hình Mạng đồ thị tích chập (GCN) để kết hợp đặc tính của các dữ liệu ngõ vào, ngõ ra được đưa vào tính toán cho mạng LSTM tương ứng để dự báo đồ thị phụ tải hàng giờ trong tương lai. Nhằm đánh giá độ chính xác của mô hình dự báo, nghiên cứu này sử dụng Thuật toán tối ưu hóa HHO để đưa vào tính toán cho mạng GCN-LSTM. Để so sánh kết quả của mô hình với các mô hình dự báo khác, chúng tôi thực hiện với tập dữ liệu phụ tải của một mô hình MG thuộc lưới điện TP Hồ Chí Minh. Mô hình dự báo được so sánh với các mô hình dự báo trước đây. Kết quả cho thấy rằng mô hình được đề xuất trong nghiên cứu này có kết quả vượt trội so với các mô hình dựa trên học sâu khác về sai số bình phương trung bình gốc (RMSE) và sai số phần trăm tuyệt đối trung bình (MAPE).

Từ khóa: HHO, GCN, tối ưu hóa giải thuật Harris hawks, phép biến đổi Wavenet, dự báo phụ tải ngắn hạn, mạng neuron tích chập.

ABSTRACT

Power load graph forecasting is of great interest in microgrid (MG) energy management. The need for accurate short-term load charting is particularly important for efficient power management for MG. This paper proposes a new method for short-term load forecasting (STLF). This method uses the time series of temperature and load data provided to the model based on the Graph Convolutional Network (GCN) model to combine the characterization of the input and output data given into the calculation for the corresponding LSTM network to forecast the hourly load graph in the future. In order to evaluate the accuracy of the prediction model, this study used the HHO optimization algorithm to calculate the GCN-LSTM network. To compare the results of the model with other forecasting models, we work with the load data set of an MG model belonging to the Ho Chi Minh City power grid. The forecast model is compared with previous forecasting models. The results show that our proposed model has superior results compared to other deep learning-based models in terms of root mean square error (RMSE) and mean absolute percentage error (MAPE).

Keywords: HHO, GCN, Harris hawks optimization, Wavenet, short-term load forecasting, Graph Convolutional Neural Network.

¹Trường Đại học Tiền Giang

²Trường Đại học Sư phạm Kỹ thuật TP.HCM

³Trường Đại học Điện Lực

⁴Tổng công ty Điện Lực TP.HCM

*Email:linhnt@epu.edu.vn

Ngày nhận bài: 15/6/2022

Ngày nhận bài sửa sau phản biện: 10/8/2022

Ngày chấp nhận đăng: 29/8/2022

1. GIỚI THIỆU

Trong xu hướng phát triển hiện nay, công nghệ ngày càng chiếm lấy một thành phần lớn trong cuộc sống. Và nhu cầu phụ tải điện ngày càng gia tăng nhanh chóng, cùng với sự phát triển của microgrid (MG) [1]. Các mô hình MG dưới dạng một lưới điện quy mô nhỏ, các kỹ thuật và công cụ tiên tiến được đặt ra để vận hành năng lượng tối ưu [2]. Tầm quan trọng của việc dự báo phụ tải của người tiêu dùng càng được đề cao. Bài toán dự báo phụ tải ngắn hạn (STLF) được đánh giá là phức tạp so với các bài toán khác. Kết quả dự báo ngắn hạn chính xác sẽ hỗ trợ các công tác vận hành và khai thác hệ thống điện ở khu vực được hiệu quả, thuận lợi. Nếu dự đoán cho biết dung lượng lưu trữ không đủ để hỗ trợ tải trong tương lai, thì công ty điện lực có thể thông báo tình trạng này cho người dùng, điều này cuối cùng khiến họ giảm mức sử dụng điện, vì người dùng không chỉ muốn trả thêm tiền cho năng lượng thông thường mà còn muốn được các cơ quan chức năng ưu đãi.

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

xét cách tiếp cận khác trong nghiên cứu [4], WaveNet sử dụng phức hợp nhân quả giãn nở và kết nối bỏ qua để sử dụng thông tin dài hạn. Loại kiến trúc ML mới lạ này thể hiện những ưu điểm khác nhau liên quan đến các thuật toán thống kê khác.

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

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

của các phương pháp đề xuất. Một WT lai với tối ưu hóa ruồi giấm (FFO) và thuật toán LSSVM dựa trên cá nhà táng đã được đề xuất trong Refs. [30, 31] cho STLF. Hiệu suất vượt trội của các phương pháp được đề xuất chứng tỏ kết quả của công việc được trình bày.

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

2. GIẢI THUẬT ĐỀ XUẤT

2.1. Giải thuật chim ưng Harris

Giải thuật chim ưng Harris (Harris's Hawks Optimization - HHO) là một giải thuật tối ưu hoá lấy cảm hứng từ phương thức săn mồi của chim ưng trong tự nhiên, đây là một giải thuật nằm trong nhánh metaheuristic lấy cảm hứng từ tự nhiên (nature-based). Phương pháp này được đề cao do khả năng tuy biến cao, phù hợp với nhiều bài toán thực tế (nếu ta có thể biến dữ liệu đầu vào phù hợp với dạng thức đầu vào của phương pháp), khiến cho mật độ sử dụng tương đối cao sau khi được giới thiệu lần đầu tiên vào năm 2019 bởi Heidari và các cộng sự trên tờ báo uy tín Journal for Future Generations Computation. Tuy nhiên, một phương pháp khác cũng đã từng xuất hiện dưới cái tên giải thuật chim ưng Harris, một dạng biến thể nâng cao của phương pháp tối ưu hoá sói xám (GWO), được thêm vào khả năng tối ưu các bài toán đòi hỏi nhiều biến số được xem xét. Trong khuôn khổ của bài báo này, phương pháp được nhắc chỉ có khả năng tối ưu hoá một biến số, với các quy tắc toán học ẩn sau khác biệt so với phương pháp kể trên. Phương pháp chim ưng được chia làm ba giai đoạn: tìm hiểu, chuyển từ thăm dò sang khai thác và khai thác.

- Giai đoạn thăm dò: Exploration phase

Trong giai đoạn thăm dò, thuật toán lấy cảm hứng từ việc quan sát và ra quyết định của đàn chim ưng. Với t là lần lặp lại hiện tại, Y_{rand} là chim ưng được chọn ngẫu nhiên từ quần thể, Y_{prey} là vị trí của con mồi, và U_B và L_B lần lượt là giới hạn trên và giới hạn dưới của không gian tìm kiếm. Mặt khác, r_1, r_2, r_3, r_4 ; và q là các số ngẫu nhiên từ 0 đến 1. Y_m là vị trí trung bình của chim ưng, được tính bằng phương trình (1):

$$Y_m(t) = \frac{1}{N} \sum_{i=1}^N Y_i(t) \quad (1)$$

Trong đó, N là tổng số thành viên trong nhóm và Y_i đại diện cho vị trí của mỗi con chim ưng ở mỗi lần lặp lại tương ứng.

• Giai đoạn chuyển đổi từ thăm dò sang khai thác:
Phase of transition from exploration to exploitation:


Giai đoạn thứ hai của HHO là chuyển đổi từ thăm dò sang khai thác. Trong pha này, năng lượng của con mồi giảm dần do quá trình chạy trốn và truy đuổi. Phần năng lượng giữ lại của con mồi được mô tả như sau:

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

Ở đây, E là năng lượng thoát ra của con mồi, E₀ được xác định từ -1 đến 1 (cho biết mức năng lượng ban đầu của con mồi tại mỗi lần lặp) và T là số lần lặp tối đa, tương ứng. Lưu ý rằng giá trị của E xác định cơ sở cho sự chuyển đổi từ thăm dò đến khai thác. Khi giá trị của E ≥ 1 thì giai đoạn thăm dò xảy ra và khi giá trị của E < 1 thì giai đoạn khai thác giai đoạn bắt đầu.

• Giai đoạn khai thác: Exploitation phase:

Giai đoạn thứ ba trong HHO được gọi là khai thác. Trong giai đoạn này, chim ưng Harris thực hiện cú vỗ bắt ngờ để tóm gọn con mồi đã chọn. Có bốn kiểu gấn trong giai đoạn này để bắt con mồi đã chọn. Ở đây, gọi q là xác suất ra đòn thành công của chim ưng, q sẽ phụ thuộc vào vị trí của chim ưng được chọn trong mỗi lần tìm kiếm so với các chim ưng khác trong đàn và phụ thuộc vào vị trí của con mồi.



Hình 1. Sơ đồ tổng quát phương pháp HHO [1]

Sau khi xác định mục tiêu trong giai đoạn tìm hiểu, đàn chim ưng sẽ thực hiện việc vây bắt con mồi. Gọi r là khả năng con mồi trốn thoát thành công (r < 0,5) và trốn thoát không thành công (r ≥ 0,5) trước phương án vây bắt của đàn chim ưng. Trong tự nhiên, do con mồi luôn tìm cách thoát thân nên đàn chim ưng sẽ lựa chọn giữa vây bắt nhẹ (soft besiege) và vây bắt gắt gao (hard besiege) tùy thuộc vào chỉ số năng lượng E của con mồi. Do chỉ số năng lượng của con mồi là hữu hạn và giảm qua mỗi chu kì, đàn chim

ưng sẽ tăng độ gắt gao trong mỗi cuộc vây bắt qua mỗi chu kì tương ứng. Ta quy ước khi abs(E) ≥ 0,5, đàn chim ưng sẽ thực hiện vây bắt nhẹ và khi abs(E) < 0,5, vây bắt gắt gao sẽ được thực hiện. Sau khi vây bắt, giá trị tối ưu hoá sẽ được thể hiện dưới dạng vị trí của con mồi khi đàn chim ưng thực hiện tấn công trực diện (surprise pounce) để kết thúc. Do tính ngẫu nhiên của phương pháp, cả 4 trường hợp tương ứng với các mức r và E khác nhau đều được xem xét.

a) Vây bắt nhẹ:

Xét trường hợp r ≥ 0,5 và abs(E) ≥ 0,5, con mồi vẫn còn nhiều năng lượng nhưng vẫn không trốn thoát thành công, khi này đàn chim ưng thực hiện nhiều cuộc vây bắt nhẹ, làm năng lượng của con mồi giảm dần cho đến khi bị bắt. Phương trình mô phỏng cho trường hợp này là:

$$Y(t+1) = \Delta Y(t) - E |JY_{prey}(t) - Y(t)| \tag{3}$$

$$\Delta Y(t) = Y_{prey}(t) - Y(t) \tag{4}$$

Trong đó, ΔY là biến thiên giữa vector vị trí của con mồi và vị trí của đàn chim ưng trong chu kì t tương ứng, r_s là trị số ngẫu nhiên trong khoảng (0,1) với J = 2(1 - r_s) thể hiện lực nhảy của con mồi trước sự vây bắt. Giá trị của J sẽ biến thiên với mỗi chu kì, tùy thuộc vào trị số ngẫu nhiên r_s.

b) Vây bắt gắt gao:

Xét trường hợp r ≥ 0,5 và abs(E) < 0,5, do mức năng lượng của con mồi thấp nên đàn chim ưng thực hiện vây bắt gắt gao ngay từ sớm, phương trình tương ứng cho vị trí của con mồi là:

$$Y(t+1) = Y_{prey}(t) - E |\Delta Y(t)| \tag{5}$$

c) Vây bắt nhẹ với độ nặng tăng dần:

Xét trường hợp r < 0,5 và abs(E) ≥ 0,5, chỉ số năng lượng của con mồi vẫn đủ cao để trốn thoát nhưng các cuộc vây hãm của chim ưng có độ gắt gao tăng dần qua các chu kì, phù hợp với quy tắc săn mồi của chim ưng trong tự nhiên.

$$X = Y_{prey}(t) - E |JY_{prey}(t) - Y(t)| \tag{6}$$

$$Z = X + S * LF(D) \tag{7}$$

Trong đó, D là kích thước, S là vectơ ngẫu nhiên và LF (D) là hàm đường bay Levy, được tính như sau:

$$LF(D) = 0,01 * \frac{\mu * \sigma}{|v|^{\frac{1}{\beta}}} \tag{8}$$

$$\sigma = \left(\frac{\Gamma(1+\beta) * \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) * \beta * 2^{\left(\frac{\beta-1}{2}\right)}} \right)^{\frac{1}{\beta}} \tag{9}$$

Với β là giá trị không đổi, u và v lần lượt là các số ngẫu nhiên trong khoảng 0 và 1. Sau mỗi cú tấn công, độ hiệu quả của nó sẽ được so sánh với các cú tấn công khả dĩ. Nếu chưa tối ưu trong lần tấn công trước (do tính bất thường của vị trí con mồi khi gặp nguy hiểm), trong các chu kì sau,

ngoài các đường bay như trước, các đường bay bất thường và dứt khoát hơn sẽ được thêm vào trong tính toán theo phương trình quỹ đạo bay Levy. Cuối cùng, vị trí của chim ưng trong vòng vây mềm có thể được cập nhật bằng phương trình (10).

$$Y(t+1) = \begin{cases} X, & \text{if } F(X) < F(Y(t)) \\ Z, & \text{if } F(Z) < F(Y(t)) \end{cases} \quad (10)$$

Trong đó, X và Z được tính bằng phương trình (6) và (7).

d) Vây bắt gắt gao với độ nặng tăng dần: Hard besiege with progressive rapid dive

Xét trường hợp $r < 0,5$ và $abs(E) < 0,5$, chỉ số năng lượng của con mồi thấp, thuận tiện cho việc thu hẹp khoảng cách trước khi thực hiện vây hãm của đàn chim. Khi khoảng cách được thu hẹp, các cú tấn công trực diện sẽ có tần suất tăng dần, với quỹ đạo bay dựa vào phương trình sau:

$$X = Y_{prey}(t) - E \cdot |JY_{prey}(t) - Y_m(t)| \quad (11)$$

$$Z = X + S \cdot LF(D) \quad (12)$$

Trong đó, Y_m thu được bằng cách sử dụng phương trình (1) và vị trí cập nhật của chim ưng trong cuộc vây hãm khó khăn có thể được thực hiện như sau:

$$Y(t+1) = \begin{cases} X, & \text{if } F(X) < F(Y(t)) \\ Z, & \text{if } F(Z) < F(Y(t)) \end{cases} \quad (13)$$


Trong đó, X và Z thu được từ phương trình (11) và (12).

2.2. Mô hình GCN - LSTM

• Mô hình hóa sự phụ thuộc vào không gian

Có được sự phụ thuộc không gian phức tạp là một vấn đề then chốt trong dự báo phụ tải. Mạng nơ ron tích chập truyền thống (CNN) có thể thu được các đặc trưng không gian cục bộ, nhưng nó chỉ có thể được sử dụng trong không gian Euclid, chẳng hạn như hình ảnh, lưới thông thường,... Mạng điểm thời gian ngày trong năm ở dạng đồ thị chứ không phải là lưới hai chiều, có nghĩa là mô hình CNN không thể phản ánh cấu trúc tô pô phức tạp của mạng điểm thời gian và do đó không thể nắm bắt chính xác sự phụ thuộc vào không gian. Gần đây, việc tổng hợp CNN thành mạng tích chập đồ thị (GCN), có thể xử lý dữ liệu có cấu trúc đồ thị tùy ý, đã nhận được sự quan tâm rộng rãi. Mô hình GCN đã được sử dụng thành công trong nhiều ứng dụng, bao gồm phân loại dữ liệu [17], học tập không giám sát [32] và phân loại hình ảnh [33]. Mô hình GCN xây dựng một bộ lọc trong miền Fourier, bộ lọc hoạt động trên các nút của biểu đồ và vùng lân cận bậc nhất của nó để nắm bắt các đặc điểm không gian giữa các nút và sau đó mô hình GCN có thể được xây dựng bằng cách xếp chồng nhiều lớp phức hợp. Trong hình 2, giả sử rằng nút 1 là đường trung tâm, mô hình GCN có thể thu được mối quan hệ tô pô giữa đường trung tâm và các con đường xung quanh, mã hóa cấu trúc tô pô của mạng lưới điểm thời gian và các thuộc tính dự liệu sau đó thu được sự phụ thuộc về không gian. Tóm lại, chúng tôi sử dụng mô

hình GCN [34] để tìm hiểu các đặc điểm không gian từ dữ liệu theo thời gian.



Hình 2. Giả sử rằng nút 1 là đường trung tâm. (a) Các nút màu xanh lam biểu thị các đường nối với đường trung tâm. (b) Đặc điểm không gian có được bằng các mối quan hệ tô pô giữa đường 1 và các đường xung quanh

$$f(X, A) = \sigma(\hat{A} \text{Relu}(\hat{A}XW_0)W_1) \quad (14)$$


trong đó, X đại diện cho ma trận đặc trưng, A đại diện

cho ma trận kề cận, $\hat{A} = \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}}$ biểu thị bước tiền xử lý, $A_e = A + I_N$ là ma trận có cấu trúc tự kết nối, D_e là ma trận bậc, $D_e = P_j A_{eij}$. W_0 và W_1 đại diện cho ma trận trọng số ở lớp thứ nhất và thứ hai và $\sigma(\cdot)$, $\text{Relu}()$ đại diện cho hàm kích hoạt.


• Mô hình hóa sự phụ thuộc theo thời gian

Có được sự phụ thuộc vào thời gian là một vấn đề quan trọng khác trong dự báo phụ tải. Hiện tại, mô hình mạng nơ ron được sử dụng rộng rãi nhất để xử lý dữ liệu tuần tự là mạng nơ ron tuần hoàn (RNN). Tuy nhiên, do những khiếm khuyết như suy giảm gradient và bùng nổ gradient, mạng nơ ron tuần hoàn truyền thống có những hạn chế đối với dự đoán dài hạn [35]. Mô hình LSTM [36] và mô hình GRU [37] là các biến thể của mạng nơ ron tuần hoàn và đã được chứng minh là có thể giải quyết các vấn đề trên. Các nguyên tắc cơ bản của LSTM và GRU gần giống nhau [38] tất cả đều sử dụng cơ chế gated (cổng) để ghi nhớ càng nhiều thông tin lâu dài càng tốt và hiệu quả như nhau cho các nhiệm vụ khác nhau. Tuy nhiên, do cấu trúc phức tạp nên LSTM có thời gian huấn luyện lâu hơn trong khi mô hình GRU có cấu trúc tương đối đơn giản, ít tham số hơn, khả năng huấn luyện nhanh hơn. Do đó, nghiên cứu này đã chọn mô hình GRU để thu được sự phụ thuộc theo thời gian từ dữ liệu lưu lượng. Như

trong hình 3, h_{t-1} biểu thị trạng thái ẩn tại thời điểm $t - 1$; x_t là thông tin dự liệu vào tại thời điểm t ; r_t là cổng thiết lập lại, được sử dụng để kiểm soát mức độ bỏ qua thông tin trạng thái tại thời điểm trước đó; u_t là cổng cập nhật, được sử dụng để kiểm soát mức độ mà thông tin trạng thái tại thời điểm trước đó được đưa vào trạng thái hiện tại; c_t là nội dung bộ nhớ được lưu trữ tại thời điểm t ; và h_t là trạng thái đầu ra tại thời điểm t . GRU nhận được trạng thái lưu lượng tại thời điểm t bằng cách lấy trạng thái ẩn tại thời điểm $t-1$ và thông tin lưu lượng hiện tại làm đầu vào. Trong khi nắm bắt thông tin tại thời điểm hiện tại, mô hình vẫn giữ được xu hướng thay đổi của thông tin lịch sử và có khả năng nắm bắt phụ thuộc thời gian.



Hình 3. Kiến trúc của mô hình Gated Recurrent Unit



Hình 4. Phần bên phải đại diện cho kiến trúc cụ thể của một đơn vị T-GCN và GC đại diện cho tích chập của đồ thị

• Mạng chuyển đổi đồ thị thời gian

Để nắm bắt đồng thời sự phụ thuộc không gian và thời gian từ dữ liệu phụ tải, chúng tôi đề xuất mô hình mạng tích chập đồ thị thời gian (T-GCN) dựa trên mạng tích chập đồ thị và các đơn vị định kỳ định mức. Như trong hình 4, bên trái là quá trình dự đoán lưu lượng không gian-thời gian, bên phải là cấu trúc cụ thể của một ô T-GCN, h_{t-1} biểu thị đầu ra tại thời điểm $t-1$, GC là quá trình tích chập đồ thị và u_t, r_t là cổng cập nhật và cổng đặt lại tại thời điểm t , và h_t biểu thị đầu ra tại thời điểm t . $f(A, X_t)$ đại diện cho quá trình tích chập đồ thị và được xác định trong phương trình (14). W và b đại diện cho trọng số và độ lệch trong quá trình huấn luyện.

$$u_t = \sigma(W_u [f(A, X_t), h_{t-1}] + b_u) \tag{15}$$

$$r_t = \sigma(W_r [f(A, X_t), h_{t-1}] + b_r) \tag{16}$$

$$c_t = \tanh(W_c [f(A, X_t), (r_t * h_{t-1})] + b_c) \tag{17}$$

$$h_t = u_t * h_{t-1} + (1 - u_t) * c_t \tag{18}$$

Tóm lại, mô hình T-GCN có thể xử lý với sự phụ thuộc không gian phức tạp và thời gian biến động. Một mặt,


mạng tích chập đồ thị được sử dụng để nắm bắt cấu trúc tô pô của mạng lưới đường đô thị để thu được sự phụ thuộc vào không gian. Mặt khác, đơn vị định kỳ định kỳ được sử dụng để nắm bắt sự biến đổi động của thông tin phụ tải trên các điểm thời gian trong năm để có được sự phụ thuộc theo thời gian và cuối cùng thực hiện các nhiệm vụ dự báo phụ tải.

2.3. Giải thuật chim ưng Harris với GCN-LSTM

Dữ liệu đầu vào được xử lý qua phần trên cùng, nơi thông tin đã học được từ các bước trước đó, trong trường hợp này là các hyperparameter đã được xử lý qua thuật toán HHO. Thông tin này được đưa qua ba cổng chính, lần lượt là cổng quên, cổng đầu vào và cổng đầu ra, để quyết định trạng thái của trạng thái nạp vào hay xóa đi của trạng thái ẩn. Sau khi định cấu hình cấu trúc của Mạng GCN-LSTM, tập hợp trọng số của GCN-LSTM sẽ được điều chỉnh bởi một thuật toán huấn luyện để giảm thiểu lỗi. Do đó, HHO được áp dụng để huấn luyện GCN-LSTM đạt độ chính xác cao với sai số tối thiểu. Sự đại diện của tác nhân tìm kiếm trong HHO và việc lựa chọn thích hợp hàm mục tiêu là những yếu tố quan trọng. Trong HHO-GCN-LSTM, mỗi tác nhân tìm kiếm được hình thành bởi ba phần, tức là một tập hợp các kết nối trọng số giữa lớp đầu vào và lớp ẩn, trọng số và một tập hợp các kết nối trọng số từ lớp ẩn với lớp đầu ra và trọng số thiên vị. Trong công việc này, các tác nhân tìm kiếm HHO được mã hóa dưới dạng vectơ thuộc khoảng $[-1, 1]$.

• Tập dữ liệu:

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



Hình 5. Dữ liệu một khu vực phụ tải điện trong 1 tuần ở TP. Hồ Chí Minh

Để giải quyết bài toán dự đoán phụ tải, các yếu tố ảnh hưởng đến tiêu thụ điện năng khi được đưa vào xem xét ngoài tính chu kỳ của nhu cầu còn có yếu tố về mặt thời tiết như độ bức xạ mặt trời, tốc độ và cường độ gió trong ngày; các yếu tố về thời gian như các dịp lễ hội hay chỉ các yếu tố về chỉ số kinh tế sẽ đóng vai trò quan trọng trong việc dự báo tải trọng một cách chính xác. Tuy nhiên, việc thu thập các yếu tố bên ngoài kể trên rất phức tạp, số liệu thu thập thường được biểu hiện dưới dạng chuỗi thời gian liên tục và tuần hoàn trong ngày. Do đó, nghiên cứu này thực hiện đánh giá dữ liệu theo mốc thời gian.

Dữ liệu thô trước khi được đưa vào phương pháp để xuất sẽ được xử lý, bao gồm các bước như kiểm tra và thay thế các giá trị rỗng dựa trên thông tin về các giá trị xung quanh, tách tập dữ liệu thành phần dữ liệu huấn luyện và dữ liệu kiểm chứng cũng như chuẩn hoá dữ liệu đầu vào. Dữ liệu được sử dụng cho nghiên cứu được lấy từ ngày 01 tháng 01 năm 2015 đến ngày 30 tháng 12 năm 2021. Trong quá trình chuẩn hoá dữ liệu, phương trình nền tảng được dùng là:

$$z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (19)$$

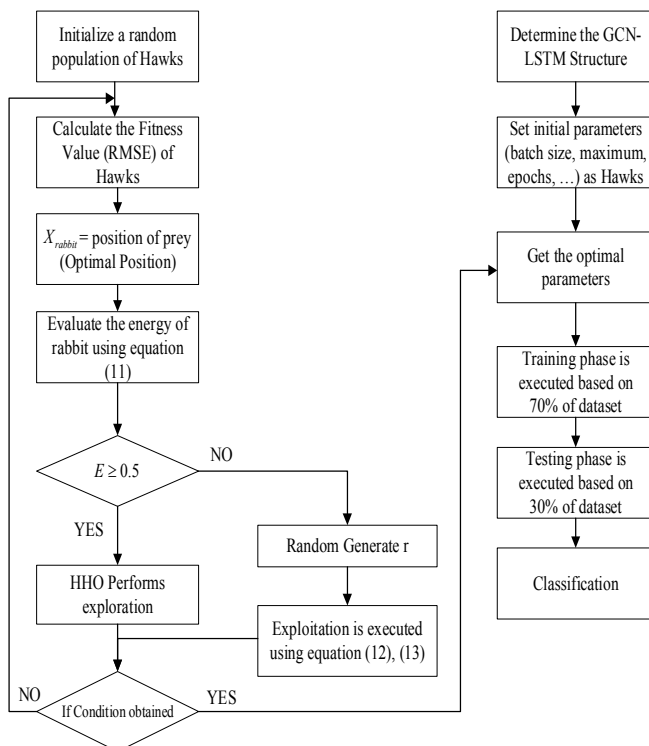
$x = x_1, \dots, x_n$ và z_i là dữ liệu chuẩn hóa thứ i .

$x = x_1, \dots, x_n$ and z_i are the i -th normalized data.

• Mô hình đề xuất:

Bài toán dự báo phụ tải trong ngắn hạn, thông qua số lượng các nghiên cứu trước đây được cho là một bài toán phức tạp. Trong nghiên cứu này, mô hình được đề xuất là một mô hình Wavenet với các hyperparameters được tối ưu hoá bởi thuật toán HHO, trong đó mỗi đầu vào neuron của GCN-LSTM là các giá trị tối ưu từ bộ dữ liệu đã được xử lý qua thuật toán HHO. Lấy cảm hứng từ thành công của mô hình trong việc xử lý chuỗi dữ liệu thời gian liên tục trong quá trình lọc phần mềm độc hại của Santhadevi D và cộng sự, một mô hình tương tự được sử dụng để dự báo phụ tải.

Hình 6 thể hiện mô hình tích hợp HHO để tính toán tối ưu hóa cho mạng GCN-LSTM. Các tham số tối ưu trọng số được tính toán bằng giải thuật HHO cho tất cả các lớp của mạng GCN-LSTM. Các tham số này được đưa vào cho mạng training với 70% dataset và mạng testing với 30% dataset.



Hình 6. Sơ đồ của thuật toán HHO-GCN-LSTM

3. KẾT QUẢ VÀ THẢO LUẬN

3.1. Đánh giá hiệu suất mô hình

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

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

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (20)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (21)$$

3.2. Dự báo phụ tải

Bảng 1 hiển thị hiệu suất của các mô hình đề cập ở trên. Mô hình đề xuất hoạt động tốt hơn các mô hình khác ở hầu hết các tiêu chí, trong đó hệ số RSME và MAPE thể hiện rõ sự ưu việt của phương pháp được đề xuất. Trong đó, mô hình được đề xuất cho các số liệu thấp hơn rất nhiều so với các phương pháp được so sánh (ít nhất là % so với phương pháp tiếp theo).


Bảng 1. Kết quả dự báo

Model	RMSE	MAPE (%)
ANN	1509,5	6,34
LSTM	730,87	4,96
CNN-LSTM	359,18	2,08
Wavenet	298,93	1,66
HHO-GCN-LSTM	241,17	1,45

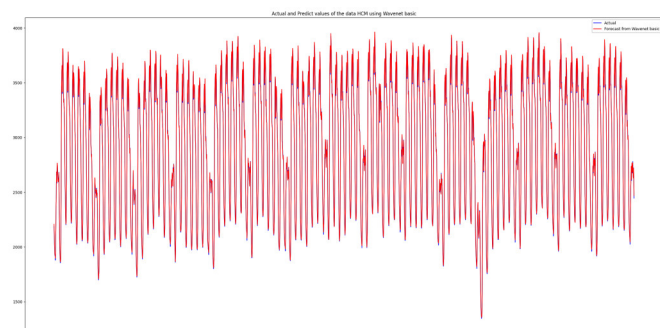
Theo bảng 1, mô hình dự báo sửa dụng ANN cho kết quả sai số cao nhất. Mô hình LSTM và dạng tích hợp CNN-LSTM cho sai số MAPE cải thiện hơn lần lượt là 11,61% và 7,06%. Kết quả khi áp dụng mô hình Wavenet có sự cải thiện rõ rệt. Cụ thể là mô hình Wavenet cơ bản thì MAPE đã giảm xuống dưới 1 là 0,78. Nhưng Wavenet cơ bản vẫn còn khá cao với RMSE là 5,69. Giải thuật đề xuất HHO tối ưu hóa cho mạng Wavenet, kết quả cải thiện rõ rệt với MAPE là 0,4% và RMSE là 2,92.

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


xuất (HHO-Wavenet) cho thấy sự chính xác tốt hơn khi thể hiện trên đồ thị, kết quả dự báo và dữ liệu thực tế gần như trùng khớp với nhau. Các phương pháp khác có sai số lớn, đồ thị cho thấy sai lệch giữa 2 dữ liệu lớn.




Hình 7. Đồ thị thể hiện giá trị thực tế với phương pháp được đề xuất kết hợp mạng GCN-LSTM với bộ tối ưu hoá HHO




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



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



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



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

4. KẾT LUẬN

Có thể thấy từ các kết quả nêu trên, khi sử dụng thuật toán HHO làm một hàm tối ưu hoá (Optimizer) cho mạng GCN-LSTM, hiệu năng của mạng được phát triển đáng kể, với các thông số MAPE và RMSE vượt trội (bảng 1). Tuy nhiên, một nhược điểm hiện tại của nghiên cứu đó là thuật toán khi sử dụng tốn rất nhiều tài nguyên tính toán cũng như tốn nhiều thời gian hơn các phương pháp được so sánh. Một hạn chế của việc chỉ một trị số các thể được tối ưu hoá khi thuật toán chìm ứng được sử dụng ở dạng thức hiện tại. Trong tương lai, nghiên cứu sẽ tập trung hướng nghiên cứu vào mở rộng thuật toán để có thể cùng lúc xử lý tối ưu hoá nhiều trị số cũng như giảm thiểu sự hao tổn tài nguyên tính toán của phương pháp, trong khi vẫn giữ nguyên hoặc cải tiến hiệu năng của chương trình.

TÀI LIỆU THAM KHẢO

[1]. Yu K, Ai Q, Wang S, Ni J, Lv T., 2016. *Analysis and optimization of droop controller for microgrid system based on small-signal dynamic model*. IEEE Transactions on Smart Grid 7(2):695e705.

[2]. Tayab UB, Humayun QM, 2018. *Enhanced droop controller for operating parallelconnected distributed-generation inverters in a microgrid*. J Renew Sustain Energy, 10(4):045303.

[3]. Usman Bashir Tayab, Ali Zia, Fuwen Yang, Junwei Lu, Muhammad Kashif, 2020. *Short-term load forecasting for microgrid energy management system using hybrid HHO-FNN model with best-basis stationary wavelet packet transform*. Journal Elsevier Energy; DOI 10.1016/j.energy.2020.117857

[4]. Fernando Dorado Rueda, Jaime Durán Suárez, Alejandro del Real Torres, 2021. *Short-Term Load Forecasting Using Encoder-Decoder WaveNet: Application to the French Grid*. Energies 14, 2524. DOI: 1996-1073/14/9/2524

[5]. Niu D., Wang Y., Wu D.D, 2010. *Power load forecasting using support vector machine and ant colony optimization*. Expert Syst. Appl. 2010, 37, 2531–2539.

[6]. Fa, G. F., Guo Y.H., Zheng J.M., Hong W.C., 2019. *Application of the Weighted K-Nearest Neighbor Algorithm for Short-Term Load Forecasting*. Energies, 12, 916.

- [7]. Dong Y., Zhang Z., Hong W.C., 2018. *A hybrid seasonal mechanism with a chaotic cuckoo search algorithm with a support vector regression model for electric load forecasting*. *Energies* 11, 1009.
- [8]. Zhang R., Dong Z.Y., Xu Y., Meng K., Wong K.P., 2013. *Short-term load forecasting of Australian National Electricity Market by an ensemble model of extreme learning machine*. *IET Gener. Transm. Distrib.*, 7, 391–397.
- [9]. Ghofrani M., Ghayekhloo M., Arabali A., Ghayekhloo A., 2015. *A hybrid short-term load forecasting with a new input selection framework*. *Energy*, 81, 777–786.
- [10]. Kong W., Dong Z.Y., Jia Y., Hill D.J., Xu Y., Zhang Y., 2017. *Short-term residential load forecasting based on LSTM recurrent neural network*. *IEEE Trans. Smart Grid*, 10, 841–851.
- [11]. Tian C., Ma J., Zhang C., Zhan P., 2018. *A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network*. *Energies* 2018, 11, 3493.
- [12]. Han L., Peng Y. Li, Y., Yong B., Zhou Q., Shu L., 2018. *Enhanced deep networks for short-term and medium-term load forecasting*. *IEEE Access* 7, 4045–4055.
- [13]. Park K., Yoon S., Hwang E., 2019. *Hybrid load forecasting for mixed-use complex based on the characteristic load decomposition by pilot signals*. *IEEE Access*, 7, 12297–12306.
- [14]. Bo-Juen C, Ming-Wei C, Chih-Jen, 2004. *Load forecasting using support vector Machines: a study on EUNITE competition 2001*. *IEEE Trans Power Syst* 19(4):1821e30.
- [15]. Che J, Wang J., 2014. *Short-term load forecasting using a kernel-based support vector regression combination model*. *Appl Energy* 2014;132:602e9.
- [16]. Hong W.C., 2009. *Electric load forecasting by support vector model*. *Appl Math Model* 2009;33(5):2444e54.
- [17]. Ceperic E, Ceperic V, Baric A., 2013. *A strategy for short-term load forecasting by support vector regression machines*. *IEEE Trans Power Syst*;28(4): 4356e64.
- [18]. Selakov A, Cvijetinovic D, Milovic L, Mellon S, Bekut D, 2014. *Hybrid PSOSVM method for short-term load forecasting during periods with significant temperature variations in city of Burbank*. *Appl Soft Comput* 2014/03/01/2014;16: 80e8.
- [19]. Sun W., 2009. *A novel hybrid GA based SVM short term load forecasting model*. 2009 second international symposium on knowledge acquisition and modeling, vol. 2; p. 227e9.
- [20]. Kavousi-Fard A, Samet H, Marzbani F, 2014. *A new hybrid modified firefly algorithm and support vector regression model for accurate short-term load forecasting*. *Expert Syst Appl*;41(13):6047e56. /10/01/2014.
- [21]. Barman M, Dev Choudhury NB, 2019. *Season specific approach for short-term load forecasting based on hybrid FA-SVM and similarity concept*. *Energy* 2019/05/ 01/2019;174:886e96.
- [22]. Barman M, Dev Choudhury NB, Sutradhar S., 2018. *A regional hybrid Goa-SVM model based on similar day approach for short-term load forecasting in Assam, India*. *Energy* 2018/02/15/2018;145:710e20.
- [23]. Lu H, Azimi M, Iseley T., 2019. *Short-term load forecasting of urban gas using a hybrid model based on improved fruit fly optimization algorithm and support vector machine*. *Energy Rep*;5:666e77.
- [24]. Jiang H, Zhang Y, Muljadi E, Zhang JJ, Gao DW., 2018. *A short-term and highresolution distribution system load forecasting approach using support vector regression with hybrid parameters optimization*. *IEEE Transactions on Smart Grid* 9(4):3341e50.
- [25]. Wang X, Wang Y., 2016. *A hybrid model of EMD and PSO-SVR for short-term load forecasting in residential quarters*. *Journal of Mathematical Problems in Engineering* 2016;2016:1e10.
- [26]. Chen Q, Wu Y, Zhang X, Chen X., 2008. *Forecasting system based on wavelet transform and PSO-SVM*. 2nd international conference on anti-counterfeiting. Security and Identification; p. 305e9. 2008.
- [27]. Qiang S, Pu Y., 2018. *Short-term power load forecasting based on support vector machine and particle swarm optimization*. *J Algorithm Comput Technol* 13.
- [28]. Sun W, Ye M., 2015. *Short-term load forecasting based on wavelet transform and least squares support vector machine optimized by fruit fly optimization algorithm*. *Journal of Electrical and Computer Engineering* 2015:1e10.
- [29]. Liu J-p, Li C-l, 2017. *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* 9(7):1188.
- [30]. Santhadevi D, Janet B., 2021. *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
- [31]. T. N. Kipf, M. Welling, 2016. *Semi-supervised classification with graph convolutional networks*.
- [32]. Y. Li, R. Yu, C. Shahabi, Y. Liu, 2017. *Graph convolutional recurrent neural network: Data-driven traffic forecasting*.
- [33]. J. Bruna, W. Zaremba, A. Szlam, Y. Lecun, 2013. *Spectral networks and locally connected networks on graphs*. *Computer Science*, Dec. 2013.
- [34]. Y. Bengio, P. Simard, P. Frasconi, 2002. *Learning long-term dependencies with gradient descent is difficult*. *IEEE Trans Neural Networks*, vol. 5, no. 2, pp. 157–166.
- [35]. J. S. Sepp Hochreiter, 1997. *Long short-term memory*. *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Dec. 1997.
- [36]. K. Cho, B. V. Merriënboer, D. Bahdanau, Y. Bengio, 2014. *On the properties of neural machine translation: Encoder-decoder approaches*. *Computer Science*.
- [37]. J. Chung, C. Gulcehre, K. H. Cho, Y. Bengio, 2014. *Empirical evaluation of gated recurrent neural networks on sequence modeling*. *Eprint Arxiv*.

AUTHORS INFORMATION

Duong Ngoc Hung^{1,2}, Nguyen Tung Linh³, Nguyen Thanh Hoan⁴, Nguyen Minh Tam²

¹Tien Giang University

²Ho Chi Minh City University of Technology and Education

³Electric Power University

⁴Hochiminh City Power Corporation