

DỰ BÁO CÔNG SUẤT NGUỒN PHÁT ĐIỆN MẶT TRỜI BẰNG MÔ HÌNH BIGRU**SOLAR POWER GENERATION PREDICTION USING BIGRU MODEL****Nguyễn Tuấn Anh¹, Phạm Mạnh Hải¹, Nguyễn Đăng Toàn¹, Vũ Thị Anh Thơ¹, Vũ Minh Pháp²**¹Trường Đại học Điện lực²Viện Khoa học công nghệ năng lượng và môi trường - Viện Hàn lâm Khoa học và Công nghệ Việt Nam

Ngày nhận bài: 25/12/2023, Ngày chấp nhận đăng: 22/02/2024, Phản biện: PGS. TS Đỗ Như Ý

Tóm tắt:

Tiến bộ trong lĩnh vực năng lượng tái tạo ngày càng trở nên quan trọng khi xã hội đang nỗ lực tìm kiếm các giải pháp bền vững đáp ứng nhu cầu năng lượng toàn cầu. Trong các loại nguồn năng lượng tái tạo, năng lượng mặt trời nổi bật với tiềm năng lớn để cung cấp điện năng sạch và hiệu quả. Việc dự báo công suất phát điện từ các hệ thống điện mặt trời trở nên quan trọng để tối ưu hóa sử dụng nguồn năng lượng mặt trời, đồng thời hỗ trợ quản lý nguồn điện và lập kế hoạch vận hành lưới điện một cách hiệu quả. Để dự báo công suất phát điện mặt trời cho một nhà máy ở miền Trung Việt Nam, trong nghiên cứu này, các tác giả đã phát triển mô hình dự báo là mô hình nút có cổng hồi tiếp hai chiều (Bi-directional Gated Recurrent Unit-BiGRU). Nghiên cứu tập trung vào sự ảnh hưởng của số lượng lớp ẩn trong mô hình BiGRU đến hiệu suất dự báo. Kết quả nghiên cứu cho thấy rằng với một tập dữ liệu đầy đủ, mô hình BiGRU một lớp ẩn đạt được hiệu suất dự báo tương đương với mô hình BiGRU hai lớp ẩn, nhưng thời gian tính toán của mô hình một lớp ẩn thấp hơn đáng kể. Dựa trên kết quả này, nhóm nghiên cứu mong muốn tìm ra giải pháp hiệu quả nhất cho dự báo công suất phát điện mặt trời, đồng thời cung cấp cái nhìn rõ ràng về lợi ích của việc sử dụng mô hình BiGRU một lớp ẩn so với BiGRU hai lớp ẩn trong việc dự báo công suất phát điện mặt trời tại Việt Nam.

Từ khóa:

Điện mặt trời, dự báo, BiGRU, lớp ẩn.

Abstract:

The progress in the field of renewable energy is becoming increasingly crucial as society endeavors to seek sustainable solutions to meet global energy demands. Among various renewable energy sources, solar energy stands out with significant potential to provide clean and efficient power. Forecasting the electricity output from solar power systems has become essential to optimize the utilization of solar energy and efficiently manage power resources and grid operations. In this study, to forecast solar power generation for a plant in central Vietnam, the research team developed a forecasting model known as the Bidirectional Gated Recurrent Unit (BiGRU) with a two-way feedback node. The research focuses on investigating the impact of the number of hidden layers in the BiGRU model on forecasting performance. The research findings indicate that, with a comprehensive dataset, a BiGRU model with a single hidden layer achieves forecasting performance equivalent to that of a BiGRU model with two hidden layers, while significantly reducing computational time. Based on these results, the research team aims to identify the most effective solution for solar power forecasting. Simultaneously, we aim to provide a clear perspective on the benefits of using a BiGRU

model with a single hidden layer compared to a BiGRU model with two hidden layers in predicting solar power generation in Vietnam.

Keywords:

Solar power, prediction, BiGRU, hidden layer.

KÝ HIỆU:

GRU: nút có cổng hồi tiếp

BiGRU: nút có cổng hồi tiếp hai chiều

GHI: tổng xạ phương ngang

GA: giải thuật di truyền

XGB: thuật toán XGboost

KPCA (Kernel Principal Component Analysis): phân tích thành phần chính nhân hệ điều hành (kernel)

MAPE: sai số phần trăm tuyệt đối trung bình

MSE : sai số bình phương trung bình

RMSE: sai số bình phương trung bình gốc

NRMSE: sai số bình phương trung bình gốc được chuẩn hóa

1. GIỚI THIỆU CHUNG

Tiềm năng phát triển nguồn điện mặt trời tại Việt Nam đã đặt nền móng cho sự đa dạng hóa nguồn năng lượng và giảm thiểu ảnh hưởng của các nguồn năng lượng truyền thống đối với môi trường. Theo quy hoạch điện VIII vừa được Thủ tướng Chính phủ phê duyệt theo quyết định 500/QĐ-TTg ngày 15/5/2023 [1] Việt Nam có tiềm năng điện mặt trời lên đến 963.000 MW, bao gồm cả các hình thức lắp đặt trên mặt đất, trên mặt nước và trên mái nhà. Vào năm 2030 tổng công suất

điện mặt trời mục tiêu đạt 12.836 MW (8,5% tổng công suất các nhà máy điện trong nước, không bao gồm điện mặt trời mái nhà hiện hữu) gồm các nguồn điện mặt trời tập trung 10.236 MW, nguồn điện mặt trời tự sản, tự tiêu khoảng 2.600 MW; trong khi nguồn điện mặt trời tự sản, tự tiêu được ưu tiên phát triển không giới hạn công suất. Đến năm 2050, tổng công suất năng lượng mặt trời mục tiêu đạt từ 168.594 đến 189.294 MW (gấp 13-15 lần năm 2030).

Tuy nhiên, điện mặt trời mang đến một thách thức đặc biệt, đó là sự không ổn định, phụ thuộc nhiều vào điều kiện thời tiết và các yếu tố địa lý. Để giải quyết vấn đề này và tối ưu hóa quản lý vận hành, Bộ Công Thương đã ban hành quyết định 67/QĐ-ĐTĐL ngày 10/8/2021 [2] về quy trình dự báo công suất phát của các nguồn điện tái tạo, bao gồm các nhà máy điện mặt trời nổi lưới và nhà máy điện gió. Tuy nhiên, dự báo chính xác và hiệu quả vẫn đang là một thách thức, đặc biệt khi các nhà máy điện mặt trời ngày càng phát triển. Hiện nay tại Việt Nam có rất ít các nghiên cứu khoa học về dự báo công suất phát điện mặt trời. Bảng 1 thống kê các nghiên cứu khoa học tiêu biểu về dự báo công suất phát điện mặt trời do các nhóm nghiên cứu tại Việt Nam thực hiện.

Với mục tiêu cải thiện dự báo công suất phát điện từ nguồn năng lượng mặt trời tại Việt Nam, nhóm nghiên cứu đề xuất sử dụng mô hình BiGRU để dự báo công suất phát điện mặt trời cho một nhà máy tại miền Trung Việt Nam. Mô hình BiGRU được kỳ vọng không chỉ giúp dự báo chính xác hơn mà còn có khả năng học từ hai hướng (cả quá khứ và tương lai) của dữ liệu, điều này quan trọng để ứng phó với tính không ổn định của điện mặt trời. Đặc biệt, nghiên cứu này quan tâm tới việc so sánh giữa sử dụng mô hình BiGRU một lớp ẩn và BiGRU hai lớp ẩn

để hiểu rõ hơn về ảnh hưởng của cấu trúc mô hình đối với hiệu suất dự báo.

Bài báo gồm các nội dung sau: phần 1 giới thiệu về hệ thống điện mặt trời và các nghiên cứu về dự báo công suất phát điện mặt trời tại Việt Nam. Phần 2 giới thiệu bản chất và tham số cho mô hình dự báo BiGRU gồm mô hình một lớp ẩn và hai lớp ẩn. Phần 3 trình bày các kết quả về dự báo công suất phát điện mặt trời của mô hình BiGRU với một lớp ẩn và hai lớp ẩn. Cuối cùng là thảo luận về kết quả và kết luận.

Bảng 1. Các nghiên cứu khoa học về dự báo công suất phát điện mặt trời tại Việt Nam

Số TT	Tên bài báo	Tên tác giả	Mô hình dự báo	Kết quả thu được
1	Applying Artificial Intelligence in Forecasting the Output of Industrial Solar Power Plant in Vietnam [3]	Nguyễn Quang Ninh, Bùi Duy Linh, Đoàn Văn Bình, Nguyễn Đình Quang	LSTM, áp dụng cho nhà máy Phong Điền	- Khi áp dụng với tập dữ liệu lịch sử của nhà máy thì MAPE bằng 1,5% và $MAPE_{min}$ bằng 1,085%. - Khi áp dụng tập dữ liệu của bên thứ ba thì RMSE tăng từ 0,996 MW lên 3,216 MW. $MAPE_{min}$ tăng từ 1,085% lên 4,432%
2	A new method for forecasting energy output of a large-scale solar power plant based on long short-term memory networks a case study in Vietnam [4]	Nguyễn Quang Ninh, Bùi Duy Linh, Đoàn Văn Bình, Nguyễn Đình Quang, Eleonora Riva Sanseverino, Dario Di Cara	LSTM, áp dụng cho nhà máy Thành Công 1	- Sử dụng dữ liệu thời tiết dự báo gây ra sai số MAPE lớn hơn so với việc sử dụng dữ liệu thời tiết lịch sử (10,857% so với 3,491%). - Sau khi cải thiện mô hình, bổ sung tính năng mới và xử lý sai số từ dự báo thời tiết, MAPE giảm từ 10,857% xuống còn 9,881%.
3	Forecasting energy output of a solar power plant in curtailment condition based on LSTM using P/GHI coefficient and validation in training process, a case study in Vietnam [5]	Nguyễn Quang Ninh, Bùi Duy Linh, Đoàn Văn Bình, Eleonora Riva Sanseverino	LSTM kết hợp với kỹ thuật chia khoảng GHI và cộng hệ số P/GHI	So với mô hình cũ sai số MAPE giảm 6,059% và sai số RMSE giảm 6,710%

Số TT	Tên bài báo	Tên tác giả	Mô hình dự báo	Kết quả thu được
4	Photovoltaic Power Generation Forecasting Utilizing Long Short Term Memory [6]	Nguyễn Đức Tuyên, Vũ Xuân Sơn Hữu, Lê Viết Thịnh	GA-LSTM	- Phương án 1: dự báo công suất điện mặt trời trong tháng 9-2006 với RMSE là $4,9 \text{ W/m}^2$ và MAPE là 10,3% khi dự báo trước 1 ngày (thấp hơn mô hình tham khảo RMSE = $6,74 \text{ W/m}^2$, và MAPE = 13,12%. Trong trường hợp dự báo trước 2 ngày, RMSE và MAPE lần lượt là $4,48 \text{ W/m}^2$ và 8,78%, thấp hơn so với mô hình tham khảo (RMSE= $5,08 \text{ W/m}^2$ và MAPE= 12,05 %). - Phương án 2: dự báo công suất điện mặt trời trong tháng 12-2006, cho thấy RMSE là $4,03 \text{ W/m}^2$ và MAPE là 6,92% khi dự báo trước 1 ngày (so với mô hình tham khảo RMSE: $4,52 \text{ W/m}^2$ và MAPE = 10,51%). Đối với dự báo trước 2 ngày, RMSE và MAPE của phương án đề xuất lần lượt là $9,14 \text{ W/m}^2$ và 12,91%, thấp hơn so với mô hình tham khảo (RMSE = $10,7 \text{ W/m}^2$, MAPE = 13,86%). - Kết luận mô hình GA-LSTM hoạt động hiệu quả hơn mô hình tham khảo dựa trên so sánh kết quả RMSE và MAPE.
5	A Novel Forecasting Model for Solar Power Generation by a Deep Learning Framework With Data Preprocessing and Postprocessing [7]	Phan Quốc Thắng, Yuan-Kang Wu, Phan Quốc Dũng, Hsin-Yen Lo	KPCA-XGB-GRU	- Kết quả thực nghiệm cho thấy mô hình KPCA-XGB-GRU có sai số NMAPE và NRMSE trong phần dự báo lần lượt là 1,52% và 2,92% chính xác dự báo tốt hơn các mô hình điển hình khác (ANN, GRU, XGBoost).

Số TT	Tên bài báo	Tên tác giả	Mô hình dự báo	Kết quả thu được
				- Việc tiền xử lý dữ liệu và hậu xử lý dữ liệu đóng vai trò quan trọng vì thu thập các đặc trưng quan trọng nhất của tập dữ liệu và cải thiện chất lượng của tập dữ liệu để đào tạo mô hình.

2. XÂY DỰNG MÔ HÌNH DỰ BÁO BiGRU

Mô hình BiGRU được phát triển như một biến thể của mô hình nút có cổng hồi tiếp (GRU), BiGRU nổi bật với khả năng kết hợp thông tin từ cả hai hướng của dữ liệu đầu vào, tạo ra một công cụ mạnh mẽ cho việc dự báo chuỗi thời gian, xử lý ngôn ngữ tự nhiên, và nhiều ứng dụng khác trong lĩnh vực học sâu. Điều này giúp BiGRU vượt trội trong việc nắm bắt các mối quan hệ phức tạp trong dữ liệu và làm cho mô hình này trở thành một lựa chọn phổ biến trong cộng đồng nghiên cứu và ứng dụng.


2.1. Xây dựng mô hình nút có cổng hồi tiếp hai chiều BiGRU

Do mô hình BiGRU là một biến thể của mô hình GRU do đó quá trình xây dựng mô hình này dựa trên các đặc điểm cơ bản của GRU, đồng thời mở rộng và tối ưu hóa chúng để đáp ứng nhu cầu của các ứng dụng phức tạp hơn.

*) Mô hình GRU

Mô hình GRU được Kyunghyun Cho và

các cộng sự [8] giới thiệu vào năm 2014 nhằm giải quyết các vấn đề về giá trị đạo hàm quá nhỏ (vanishing gradient). Cấu trúc của GRU bao gồm các cổng cập nhật và cổng khôi phục, giúp mô hình hiệu quả hóa quá trình truyền ngược gradient và giảm thiểu tình trạng mất mát thông tin trong quá trình đào tạo. Hình 1 cho thấy cấu trúc của một mạng GRU bao gồm cổng cập nhật z_j (update gate) và cổng khôi phục r_j (reset gate).



Hình 1. Cấu trúc của GRU [8]

Cổng cập nhật (update gate) z_j : được tính bởi công thức [8]:

$$z_j = \sigma \left([W_z X]_j + [U_z h_{(t-1)}]_j \right) \quad (1)$$

Trong đó:

W_z và U_z : các ma trận trọng số cho cổng cập nhật;

σ : hàm sigmoid logistic để chuyển đổi giá trị đầu ra thành một giá trị nằm trong khoảng (0, 1);

X: đầu vào tại bước thời gian hiện tại;

$h_{(t-1)}$: trạng thái ẩn ở bước thời gian trước đó.

Cổng cập nhật quyết định mức độ thông tin mới sẽ được cập nhật vào trạng thái ẩn. Cổng này giúp mô hình quyết định xem thông tin mới có nên được giữ lại hay không, dựa trên thông tin cũ và thông tin đầu vào mới.

Cổng khôi phục (reset gate) r_j : có công thức như sau [8]:

$$r_j = \sigma \left([W_r X]_j + [U_r h_{(t-1)}]_j \right) \quad (2)$$

Trong đó:

W_r và U_r : các ma trận trọng số cho cổng khôi phục;

σ : hàm sigmoid logistic để chuyển đổi giá trị đầu ra thành một giá trị nằm trong khoảng (0, 1);

X: đầu vào tại bước thời gian hiện tại;

$h_{(t-1)}$: trạng thái ẩn ở bước thời gian trước đó.

Cổng khôi phục quyết định mức độ thông tin cần phải được quên từ trạng thái ẩn trước đó. Cổng này giúp mô hình quyết định việc có cần phải đặt lại trạng thái ẩn để làm mới thông tin hoặc không

Nội dung nhớ hiện tại (current memory content): thông tin nội dung của bộ nhớ mới sẽ sử dụng cổng reset để lưu trữ

thông tin có liên quan đến quá khứ được tính như sau [8]:

$$\tilde{h}_j^{(t)} = f([WX]_j + r_j[Uh_{(t-1)}]) \quad (3)$$

Trong đó:

$\tilde{h}_j^{(t)}$: nội dung nhớ hiện tại;

W và U: các ma trận trọng số;

f: hàm kích hoạt (tanh,...);

X: đầu vào tại bước thời gian hiện tại;

$h_{(t-1)}$: trạng thái ẩn ở bước thời gian trước đó.

Bộ nhớ tại thời điểm hiện tại (final memory at current time step): trạng thái ẩn được cập nhật dựa trên cả thông tin cũ và thông tin mới. Quá trình cập nhật được điều chỉnh bởi cổng cập nhật và cổng khôi phục. Công thức tính toán trạng thái ẩn mới $h_j^{(t)}$ là [8]:

$$h_j^{(t)} = z_j h_j^{(t-1)} + (1 - z_j) \tilde{h}_j^{(t)} \quad (4)$$

Trong đó:


$h^{(t)}$: vector chứa toàn bộ thông tin ở tại thời điểm t và truyền thông tin này đi;

$h_j^{(t-1)}$: bộ nhớ trước đó;

z_j : cổng cập nhật.

***) Mô hình BiGRU một lớp ẩn**

BiGRU là sự kết hợp của hai lớp GRU đơn hướng độc lập. Một lớp duy trì các trạng thái ẩn phía trước, trong khi lớp kia duy trì các trạng thái ẩn phía sau. Cấu trúc của một mô hình BiGRU như sau [9]:




Hình 2. Cấu trúc của mô hình BiGRU một lớp ẩn [9]

Mô hình BiGRU với một lớp ẩn sử dụng cả hai chiều (thuận và nghịch) của mạng nơron GRU để xử lý dữ liệu đầu vào. Lớp GRU thuận của mô hình xử lý thông tin theo chiều thuận từ thời điểm trước đến thời điểm hiện tại (thông tin đầu vào theo các bước thời gian $T_1, T_2, \dots, T_n$), trong khi lớp GRU nghịch xử lý theo chiều nghịch từ thời điểm hiện tại đến thời điểm trước đó ($T_n, \dots, T_2, T_1$). Mỗi lớp GRU bao gồm các cổng cập nhật và cổng khôi phục, giúp điều chỉnh thông tin được truyền đi và quên thông tin không cần thiết.

Lớp GRU thuận và lớp GRU nghịch sử dụng các tham số (trọng số và độ lệch) để tính toán đầu ra và trạng thái ẩn cho mỗi thời điểm. Kết quả từ hai chiều được tích hợp bằng cách sử dụng các phép toán như cộng, trung bình, hoặc các kỹ thuật kết hợp khác tùy thuộc vào mục tiêu của mô hình. Quá trình này giúp mô hình BiGRU hiểu được ngữ cảnh từ cả hai phía của mỗi thời điểm, làm tăng khả năng học và mô hình hóa các mối quan hệ phức tạp trong dữ liệu đầu vào.

*) Mô hình BiGRU hai lớp ẩn

Mô hình BiGRU với hai lớp ẩn có các đặc điểm giống với mô hình một lớp ẩn, tuy nhiên số lớp ẩn trong mô hình tăng thêm một lớp. Cấu trúc của mô hình BiGRU hai lớp ẩn như hình 3 [9]:



Hình 3. Cấu trúc mô hình BiGRU hai lớp ẩn [9]

- Lớp ẩn thứ nhất (Forward GRU): Lớp này chịu trách nhiệm xử lý dữ liệu theo chiều từ trái sang phải ($T_1, T_2, \dots, T_n$). Lớp này nhận đầu vào từ bước thời gian hiện tại và trạng thái ẩn của lớp trước đó. Quá trình này giúp lớp ẩn thứ nhất nắm bắt thông tin quan trọng từ quá khứ và tiếp tục truyền thông tin đó qua chuỗi.
- Lớp ẩn thứ hai (Backward GRU): Lớp này xử lý dữ liệu theo chiều từ phải sang trái ($T_n, \dots, T_2, T_1$). Tương tự như lớp ẩn thứ nhất, lớp này cũng nhận đầu vào từ bước thời gian hiện tại và trạng thái ẩn của lớp trước đó. Quá trình này giúp lớp ẩn thứ hai nắm bắt thông tin tương lai và truyền ngược lại qua chuỗi.

Kết hợp thông tin từ cả hai lớp ẩn:

- Tổng hợp trạng thái: trạng thái ẩn của mỗi lớp được tổng hợp lại để tạo ra trạng thái ẩn cuối cùng cho mỗi bước thời gian.
- Thông tin đầu ra: là quá trình kết hợp các trạng thái ẩn cuối cùng của một hay nhiều lớp ẩn để tạo ra kết quả dự báo.

2.2. Các thông số của mô hình BiGRU một lớp ẩn và hai lớp ẩn

- Thuật toán tối ưu hóa: adam

Chức năng: thuật toán tối ưu Adam được sử dụng để điều chỉnh trọng số của mô hình dựa trên độ lớn của gradient. Adam giúp mô hình hội tụ nhanh hơn so với các thuật toán tối ưu truyền thống và giảm nguy cơ rơi vào các điểm cực tiểu cục bộ.

- Hàm kích hoạt: Tanh

Chức năng: hàm kích hoạt Tanh được sử dụng để giới hạn đầu ra của mô hình trong khoảng $[-1, 1]$. Giới hạn đầu ra giúp mô hình học được mối quan hệ phức tạp và chủ động trong việc xử lý dữ liệu đầu vào.

- Hàm sai số (Loss function): MSE

Chức năng: MSE được sử dụng để đo lường độ lớn của sai số giữa dự báo của mô hình và giá trị thực tế. MSE là một hàm phổ biến trong các nhiệm vụ dự báo, giúp mô hình học được các thay đổi nhỏ và đồng thời giảm độ lớn của sai số.

- Số lần huấn luyện (epochs): 30

Chức năng: epochs là số lần huấn luyện trên toàn bộ dữ liệu. Số lượng epochs lớn giúp mô hình có cơ hội học được nhiều


hơn từ dữ liệu, tăng khả năng hiểu biết và dự báo.

- Kích thước dữ liệu cập nhật trọng số (batch size): 64

Chức năng: batch size là số lượng mẫu dữ liệu được sử dụng trong mỗi lần cập nhật trọng số (iteration). Việc sử dụng batch size giúp tăng tốc độ huấn luyện và giảm áp lực tính toán, đồng thời duy trì tính đại diện của dữ liệu trong quá trình cập nhật trọng số.

3. KẾT QUẢ VÀ THẢO LUẬN

3.1. Sơ đồ thuật toán dự báo của mô hình BiGRU một lớp ẩn và hai lớp ẩn được đề xuất



Hình 4. Sơ đồ thuật toán dự báo với mô hình BiGRU một lớp ẩn và hai lớp ẩn

3.1.1. Các bước thực hiện thuật toán

- Tập dữ liệu đầu vào: tập dữ liệu được thu thập từ một nhà máy điện mặt trời với công suất lắp đặt là 40 MW tại miền Trung Việt Nam trong khoảng thời gian một năm (01/01/2022-31/12/2022), với

bước thời gian 5 phút. Tập dữ liệu bao gồm các thông số quan trọng: công suất phát điện từ nguồn năng lượng mặt trời, chỉ số bức xạ mặt trời, nhiệt độ môi trường và nhiệt độ của tấm pin mặt trời.

- Phân chia tập dữ liệu theo tỷ lệ 70% huấn luyện (train) và 30% kiểm tra (test).
- Chuẩn hóa dữ liệu: để đảm bảo tính đồng nhất và sử dụng hiệu quả, phương pháp chuẩn hóa được áp dụng để đưa dữ liệu về khoảng từ 0 đến 1. Quá trình chuẩn hóa dựa trên xác định giá trị tối đa (max) và giá trị tối thiểu (min) của tập dữ liệu. Việc này giúp cải thiện hiệu suất của các thuật toán như hồi quy tuyến tính và hồi quy logistic. Công thức chuẩn hóa được biểu diễn như sau [10]:

$$P_n = \frac{P - P_{\min}}{P_{\max} - P_{\min}} \quad (5)$$

Trong đó: P_n là công suất sau khi được chuẩn hóa, P là công suất đầu vào trước khi chuẩn hóa dữ liệu, $P_{\max}$ là công suất lớn nhất trong khoảng thời gian lấy dữ liệu và $P_{\min}$ là công suất nhỏ nhất trong cùng thời gian. Dữ liệu đầu vào sau khi được chuẩn hóa theo công thức (5) thì các dữ liệu sau khi được chuẩn hóa sẽ nằm trong khoảng $[0,1]$, khi mô hình BiGRU được huấn luyện với dữ liệu nằm trong khoảng $[0,1]$ sẽ có khả năng học được mối quan hệ phức tạp giữa các biến đầu vào và đầu ra trong khoảng giá trị chuẩn hóa đó. Các mô hình học máy thường hoạt động tốt hơn khi dữ liệu được chuẩn hóa vì giúp giảm độ lớn của các trọng

số và làm cho quá trình học trở nên ổn định hơn.

- Huấn luyện mô hình với tập dữ liệu đã được chuẩn hóa.
- Đánh giá kết quả nhận được từ mô hình dự báo.

3.1.2. Các sai số áp dụng trong mô hình

- Sai số phần trăm tuyệt đối trung bình (MAPE): có tác dụng đánh giá hiệu suất của mô hình dự báo trong việc đo lường độ chênh lệch tương đối giữa giá trị dự báo và giá trị thực tế. MAPE giúp đánh giá mức độ chính xác của mô hình bằng cách biểu thị sai khác dự báo dưới dạng phần trăm so với giá trị thực tế. Điều này giúp hiểu rõ hơn về độ chính xác của mô hình dự báo, MAPE càng thấp, mô hình dự báo càng chính xác [11]:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (6)$$

Trong đó:

MAPE: sai số phần trăm tuyệt đối trung bình %;

$\hat{y}_i$: giá trị dự báo của công suất phát dự báo thứ i (kW);

y_i : giá trị công suất trong thực tế thứ i (kW); n là số lượng điểm dữ liệu.

- Sai số trung bình bình phương gốc (RMSE): là một thước đo đánh giá độ lệch giữa giá trị dự báo và giá trị thực tế trong một chuỗi dữ liệu. Được sử dụng rộng rãi trong lĩnh vực dự báo và thống kê, RMSE giúp đo lường mức độ chính xác của mô hình dự báo [11]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

Trong đó:

$\hat{y}_i$: công suất dự báo (kW);

y_i : công suất thực tế (kW);

n : số lượng điểm dữ liệu.

- Sai số trung bình bình phương gốc đã chuẩn hóa NRMSE (Normalized Root Mean Squared Error): là thước đo đánh giá hiệu suất của mô hình dự báo, tương tự như sai số RMSE nhưng sai số này đã được chuẩn hóa để so sánh hiệu suất trên các tập dữ liệu có đơn vị đo khác nhau. Công thức tính NRMSE như sau [7]:

$$NRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{P_{dm}} \times 100 \quad (8)$$

Trong đó:

$\hat{y}_i$: công suất dự báo (kW);

y_i : công suất thực tế (kW);

n : số lượng điểm dữ liệu;

P_{dm} : tổng công suất lắp đặt của nhà máy (kW).

3.2. Kết quả khi áp dụng mô hình BiGRU một lớp ẩn và hai lớp ẩn với tập dữ liệu thực tế

Trong các kịch bản so sánh hiệu suất dự báo giữa hai mô hình BiGRU một lớp ẩn và hai lớp ẩn, nhóm nghiên cứu thực hiện chạy hai mô hình với tập dữ liệu đầy đủ và không đầy đủ (bằng cách loại bỏ từng lớp dữ liệu theo các mức công suất khác nhau). Kết quả cho thấy rằng việc loại bỏ các điểm công suất có thể ảnh hưởng đáng kể đến hiệu suất dự báo của mô hình. Các kết quả của mô hình dự báo với tập dữ liệu lịch sử được trình bày trong bảng 2.

Bảng 2. Kết quả của mô hình BiGRU một lớp ẩn và hai lớp ẩn

Tập dữ liệu	Thời gian hoàn thành (s)		RMSE (kW)		NRMSE (%)		MAPE (%)	
	1 lớp ẩn	2 lớp ẩn	1 lớp ẩn	2 lớp ẩn	1 lớp ẩn	2 lớp ẩn	1 lớp ẩn	2 lớp ẩn
Đầy đủ dữ liệu	823,34	1448,41	2247,421	2248,367	5,618	5,620	Không xác định	Không xác định
Bỏ điểm dữ liệu công suất bằng 0 kW	345,28	819,54	3200,353	3240,641	8,0008	8,101	2762,37	2546,04
Bỏ điểm dữ liệu công suất dưới 100 kW	335,44	561,73	3262,817	4491,345	8,1570	11,228	27,92	35,99
Bỏ điểm dữ liệu công suất dưới 1000 kW	276,56	515,02	3516,641	3704,501	8,791	9,261	23,21	22,83

Tập dữ liệu	Thời gian hoàn thành (s)		RMSE (kW)		NRMSE (%)		MAPE (%)	
	1 lớp ẩn	2 lớp ẩn	1 lớp ẩn	2 lớp ẩn	1 lớp ẩn	2 lớp ẩn	1 lớp ẩn	2 lớp ẩn
Bỏ điểm dữ liệu công suất bằng 0 kW và trên 1000 kW	37,62	88,51	165,355	164,412	0,413	0,411	3240,44	1960,48

Từ bảng 2 ta thấy với tập dữ liệu lịch sử đầy đủ thì RMSE và NRMSE đều cho kết quả sai số giữa 2 mô hình BiGRU một lớp ẩn và hai lớp ẩn gần như tương đương nhau. Điều này thể hiện rằng cả hai mô hình đều có khả năng dự báo tương đương với tập dữ liệu cụ thể này.

Khi sử dụng tập dữ liệu này để tính sai số MAPE thì kết quả là không xác định, nguyên nhân là do có các điểm dữ liệu bằng 0 gây ra, đây là nhược điểm của cách tính MAPE theo công thức (6). Một nhược điểm nữa của MAPE là khi dự báo cho các điểm công suất nhỏ (trong khoảng lớn hơn 0 tới 1000kW) thì chênh lệch sai số rất lớn trong khi chênh lệch công suất rất bé cho thấy sự nhạy cảm của MAPE đối với các giá trị nhỏ. Khi tính với các điểm công suất nhỏ trên thì sai số MAPE của mô hình BiGRU hai lớp ẩn thấp hơn khá nhiều so với mô hình một lớp ẩn. Điều này cho thấy mô hình BiGRU hai lớp ẩn xử lý điểm dữ liệu có giá trị nhỏ tốt hơn mô hình BiGRU một lớp ẩn.

Thời gian tính toán của mô hình BiGRU hai lớp ẩn lâu hơn rất nhiều so với mô hình BiGRU một lớp ẩn. Điều này cho

thấy mô hình hai lớp ẩn tiêu tốn tài nguyên và chi phí cao hơn đáng kể cho quá trình tính toán trong khi sai số gần như tương đương với mô hình một lớp ẩn. Như vậy, mô hình BiGRU một lớp ẩn không chỉ có cấu trúc đơn giản hơn mà trong quá trình tính toán còn tốn ít tài nguyên và chi phí hơn so với mô hình BiGRU hai lớp ẩn.

4. KẾT LUẬN

Hai mô hình BiGRU một lớp ẩn và hai lớp ẩn đều có kết quả dự báo tốt cho bài toán dự báo công suất điện mặt trời. Việc quyết định lựa chọn giữa mô hình BiGRU một lớp ẩn và hai lớp ẩn cần phải xem xét cân nhắc giữa hiệu suất dự báo và tài nguyên tính toán. Việc tiêu tốn tài nguyên và chi phí cao hơn của mô hình hai lớp ẩn đối với quá trình tính toán nên được cân nhắc kỹ lưỡng, đặc biệt khi sai số không có sự cải thiện đáng kể so với mô hình một lớp ẩn điều này cho thấy khả năng dự báo của mô hình BiGRU một lớp ẩn không thua kém quá nhiều so với mô hình hai lớp ẩn. Nếu sự cải thiện về hiệu suất dự báo của mô hình hai lớp ẩn không

đáng kể và thời gian tính toán là yếu tố quan trọng thì mô hình một lớp ẩn là lựa chọn hiệu quả hơn.

Sai số MAPE thường gặp nhiều khó khăn trong việc ước lượng chính xác cho các điểm công suất bằng 0 và các giá trị nhỏ. MAPE trở nên không ổn định do sự xuất hiện của các điểm dữ liệu bằng 0 và đồng thời tăng chênh lệch lớn trong sai số MAPE khi xử lý các giá trị công suất nhỏ. Trong khi đó, sai số RMSE và NRMSE mang lại sự cải thiện bằng cách khắc phục nhược điểm của MAPE. Đối với các trường hợp có biến động lớn trong dữ liệu hoặc thường xuyên xuất hiện các giá trị công suất nhỏ hoặc bằng 0, việc xem xét sử dụng các phép đo sai số như RMSE hoặc NRMSE là khá hợp lý. Những phép

đo này có khả năng cung cấp cái nhìn tổng quan và cân bằng hơn về hiệu suất của mô hình trong bài toán dự báo công suất phát điện mặt trời.

Với tập dữ liệu lịch sử đầy đủ, mô hình BiGRU một lớp ẩn là lựa chọn hợp lý do cấu trúc đơn giản hơn, khả năng dự báo tương đương và thời gian tính toán thấp hơn. Mặc dù mô hình hai lớp ẩn giảm thiểu chênh lệch trong sai số MAPE tại các điểm công suất nhỏ, nhưng thời gian tính toán lâu và chi phí cao làm cho sự lựa chọn vào mô hình này không hiệu quả. Tóm lại, trong trường hợp này, lựa chọn mô hình BiGRU một lớp ẩn là phù hợp với yêu cầu về hiệu suất và chi phí tính toán.

TÀI LIỆU THAM KHẢO

- [1] Chính phủ, "Quy hoạch phát triển điện lực quốc gia thời kỳ 2021-2030, tầm nhìn đến năm 2050 (Quy hoạch điện VIII - Vietnam Eight Power Development Plan)." 2023.
- [2] MOIT, "Quyết định 67 QĐ/ ĐTĐL-Qui trình dự báo công suất, điện năng phát của các nguồn điện năng lượng tái tạo," pp. 1–22, 2021.
- [3] N. Quang, L. Duy, B. Van, and Q. Dinh, "Applying Artificial Intelligence in Forecasting the Output of Industrial Solar Power Plant in Vietnam," *EAI Endorsed Trans. Energy Web*, p. 169166, 2018, doi: 10.4108/eai.29-3-2021.169166.
- [4] N. Q. Nguyen, L. D. Bui, B. Van Doan, E. R. Sanseverino, D. Di Cara, and Q. D. Nguyen, "A new method for forecasting energy output of a large-scale solar power plant based on long short-term memory networks a case study in Vietnam," *Electr. Power Syst. Res.*, vol. 199, no. June, p. 107427, 2021, doi: 10.1016/j.epsr.2021.107427.
- [5] L. D. Bui, N. Q. Nguyen, B. Van Doan, and E. R. Sanseverino, "Forecasting energy output of a solar power plant in curtailment condition based on LSTM using P/GHI coefficient and validation in training process, a case study in Vietnam," *Electr. Power Syst. Res.*, vol. 213, 2022, doi: 10.1016/j.epsr.2022.108706.
- [6] N. D. Tuyen, V. Xuan, S. Huu, and L. V. Thinh, "Photovoltaic Power Generation Forecasting Utilizing Long Short Term Memory," *Meas. Control Autom.*, vol. 1, no. April, pp. 2–7, 2021.

- [7] Q. T. Phan, Y. K. Wu, Q. D. Phan, and H. Y. Lo, "A Novel Forecasting Model for Solar Power Generation by a Deep Learning Framework With Data Preprocessing and Postprocessing," *IEEE Trans. Ind. Appl.*, vol. 59, no. 1, pp. 220–231, 2023, doi: 10.1109/TIA.2022.3212999.
- [8] K. Cho *et al.*, "Learning phrase representations using RNN encoder-decoder for statistical machine translation," *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.*, no. June, pp. 1724–1734, 2014, doi: 10.3115/v1/d14-1179.
- [9] L. Kumar and S. Sarkar, *Neural Search: Learning Query and Product Representations in Fashion E-commerce*, vol. 1, no. 1. Association for Computing Machinery, 2021.
- [10] S. R, J. Singh, A. Ali, A. Khan, and M. F. Hoda, "A comparative study of different deep learning models for mid-term solar power prediction," in *2021 International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, Mar. 2021, vol. 7, pp. 519–524, doi: 10.1109/ICACITE51222.2021.9404630.
- [11] B. Liu, C. Fu, A. Bielefield, and Y. Q. Liu, "Forecasting of Chinese Primary Energy Consumption in 2021 with GRU artificial neural network," *Energies*, vol. 10, no. 10, pp. 1–15, 2017, doi: 10.3390/en10101453.

Giới thiệu tác giả:



Tác giả Nguyễn Tuấn Anh tốt nghiệp đại học ngành kỹ thuật điện tại Học viện Nông nghiệp Việt Nam năm 2012, nhận bằng Thạc sĩ ngành kỹ thuật điện tại Trường Đại học Điện lực năm 2017. Hiện nay tác giả là giảng viên Khoa Kỹ thuật điện, Trường Đại học Điện lực.

Lĩnh vực nghiên cứu: khí cụ điện, năng lượng tái tạo, dự báo điện mặt trời, DCS và SCADA.



Tác giả Phạm Mạnh Hải tốt nghiệp đại học ngành hệ thống điện tại Đại học Bách khoa Hà Nội năm 2006; nhận bằng Thạc sĩ ngành kỹ thuật điện tại Đại học Paul Sabatier, Toulouse, Pháp năm 2008, bảo vệ Luận án Tiến sĩ ngành hóa hữu cơ ứng dụng - Pplasma cho năng lượng tại Đại học Poitiers (ENSIP), Poitiers, Pháp năm 2011. Hiện nay tác giả công tác tại Khoa Công nghệ năng lượng, Trường Đại học Điện lực.

Lĩnh vực nghiên cứu: thuật toán tối ưu, dự báo phụ tải điện, thuật toán trí tuệ nhân tạo, dự báo điện gió và điện mặt trời, năng lượng tái tạo, sản xuất Biomass-Biogas, độ tin cậy trong hệ thống điện.



Tác giả Vũ Thị Anh Thơ tốt nghiệp đại học ngành hệ thống điện tại Đại học Bách khoa Hà Nội năm 2006; nhận bằng Thạc sĩ, Tiến sĩ ngành kỹ thuật điện tại Đại học Grenoble Alpes (Pháp) năm 2007 và 2011. Hiện nay tác giả công tác tại Khoa Kỹ thuật điện, Trường Đại học Điện lực.

Lĩnh vực nghiên cứu: tự động hóa hệ thống điện, dự báo phụ tải.



Tác giả Nguyễn Đăng Toàn tốt nghiệp đại học ngành hệ thống điện tại Đại học Bách khoa Hà Nội năm 2001; nhận bằng Thạc sĩ ngành quản lý hệ thống điện (EPSM) tại AIT - Thái Lan năm 2004, Tiến sĩ tại Grenoble - INP - Pháp năm 2008. Hiện nay tác giả công tác tại Khoa Công nghệ năng lượng - Trường Đại học Điện lực.

Lĩnh vực nghiên cứu: ổn định hệ thống điện, HVDC/FACTS, năng lượng mới.



Tác giả Vũ Minh Pháp tốt nghiệp đại học tại Học viện Kỹ thuật quân sự năm 2007; nhận bằng Thạc sĩ ngành kỹ thuật điện tử tại Trường Đại học Giao thông vận tải năm 2012, bằng Tiến sĩ ngành kỹ thuật hệ thống điện – điện tử tại Đại học Mie, Nhật Bản năm 2018.

Lĩnh vực nghiên cứu: chẩn đoán hư hỏng trong máy điện, ước lượng thông số của máy điện, điều khiển máy điện và các bộ biến đổi sử dụng thiết bị điện tử công suất, ứng dụng của các bộ biến đổi trong lưới điện thông minh.

