

# ĐÁNH GIÁ CÁC MÔ HÌNH DỰ BÁO BỨC XẠ MẶT TRỜI: LIGHTGBM, LSTM VÀ GRU

## EVALUATION OF SOLAR RADIATION FORECAST MODELS: LIGHTGBM, LSTM AND GRU

Nguyễn Tuấn Anh<sup>1,\*</sup>, Phạm Mạnh Hải<sup>2</sup>, Lê Thành Doanh<sup>3</sup>,  
Nguyễn Ngọc Trung<sup>4</sup>, Vũ Thị Anh Thơ<sup>1</sup>, Vũ Minh Pháp<sup>5</sup>, Trần Trọng Tuấn<sup>6</sup>

DOI: <http://doi.org/10.57001/huiv5804.2024.256>

### TÓM TẮT

Dự báo bức xạ mặt trời chính xác là yếu tố kỹ thuật quan trọng trong việc tối ưu hóa hiệu suất các hệ thống điện mặt trời. Bài báo này đánh giá hiệu suất của ba mô hình học máy tiên tiến là Light Gradient Boosting Machine (LightGBM), Long Short-Term Memory (LSTM) và Gated Recurrent Unit (GRU) trong việc dự báo bức xạ mặt trời. Các mô hình được huấn luyện và kiểm tra thử trên một bộ dữ liệu thực tế, bao gồm các thông số khí tượng và bức xạ mặt trời đo được. Các tiêu chí đánh giá như sai số trung bình bình phương gốc (RMSE), và sai số tuyệt đối trung bình (MAE) được sử dụng để so sánh hiệu suất của các mô hình. Kết quả cho thấy mỗi mô hình có những ưu điểm và nhược điểm riêng. Mô hình LightGBM khi huấn luyện thể hiện hiệu suất vượt trội với thời gian huấn luyện nhanh hơn và độ chính xác cao hơn ( $0,5s$ ;  $RMSE = 54,8W/m^2$  và  $MAE = 27,6W/m^2$ ) so với LSTM ( $456,5s$ ;  $RMSE = 59,2W/m^2$ ;  $MAE = 34,8W/m^2$ ) và GRU ( $397,2s$ ;  $RMSE = 59,3W/m^2$ ;  $MAE = 34,7W/m^2$ ). Trong các kịch bản dự báo, ba mô hình có độ chính xác khá tương đương nhưng LightGBM có thời gian dự báo thấp hơn LSTM và GRU khá nhiều. LSTM và GRU, mặc dù phức tạp hơn và đòi hỏi thời gian huấn luyện lâu hơn, nhưng cũng cho thấy khả năng dự báo tốt với những đặc điểm dữ liệu thời gian phức tạp. Bài báo cung cấp cái nhìn toàn diện về hiệu suất của các mô hình này và đưa ra các khuyến nghị cho việc lựa chọn mô hình phù hợp trong các ứng dụng dự báo bức xạ mặt trời.

**Từ khóa:** Dự báo bức xạ mặt trời, LightGBM, LSTM, GRU.

### ABSTRACT

Accurate solar radiation forecasting is a crucial technical factor in optimizing the performance of solar power systems. This paper evaluates the performance of three advanced machine learning models: Light Gradient Boosting Machine (LightGBM), Long Short-Term Memory (LSTM), and Gated Recurrent Unit (GRU) in solar radiation forecasting. The models were trained and tested on a real-world dataset, including meteorological parameters and measured solar radiation. Evaluation criteria such as Root Mean Square Error (RMSE) and Mean Absolute Error (MAE) were used to compare the models' performance. Results show that each model has its strengths and weaknesses. The LightGBM model demonstrated superior performance during training with faster training times and higher accuracy ( $0,5s$ ;  $RMSE = 54.8 W/m^2$  và  $MAE = 27.6 W/m^2$ ) so với LSTM ( $456,5s$ ;  $RMSE = 59.2W/m^2$ ;  $MAE = 34.7W/m^2$ ) và GRU ( $397,2s$ ;  $RMSE = 59.3W/m^2$ ;  $MAE = 34.7W/m^2$ ). The three models showed comparable accuracy in forecasting scenarios, but LightGBM had significantly lower prediction times than LSTM and GRU. LSTM and GRU, although more complex and requiring longer training times, also demonstrated good forecasting capabilities with complex time series data characteristics. The paper provides a comprehensive view of these models' performance and recommends selecting appropriate models in solar radiation forecasting applications.

**Keywords:** Forecasting of solar radiation, LightGBM, LSTM, GRU.

<sup>1</sup>Khoa Kỹ thuật điện, Trường Đại học Điện lực

<sup>2</sup>Khoa Công nghệ Năng lượng, Trường Đại học Điện lực

<sup>3</sup>Phòng Đào tạo sau Đại học, Trường Đại học Điện lực

<sup>4</sup>Phòng Tổ chức cán bộ, Trường Đại học Điện lực

<sup>5</sup>Viện Khoa học công nghệ Năng lượng và Môi trường, Viện Hàn lâm Khoa học và Công nghệ Việt Nam

<sup>6</sup>Trung tâm Điều độ hệ thống điện Quốc gia

\*Email: anhnt88@epu.edu.vn

Ngày nhận bài: 01/7/2024

Ngày nhận bài sửa sau phản biện: 23/8/2024

Ngày chấp nhận đăng: 27/8/2024

**KÝ HIỆU**

Ký hiệu	Ý nghĩa
$f_t$	Cổng quên (forget gate)
$i_t$	Cổng vào (input gate)
$C_t$	Cổng cập nhật trạng thái
$h_t$	Cổng ra (output gate)
$r_t$	Cổng khôi phục (reset gate)
$z_t$	Cổng cập nhật (update gate)
$\tilde{h}_j$	Nội dung nhớ hiện tại
$h_t$	Bộ nhớ tại thời điểm hiện tại

**TỪ VIẾT TẮT**

LightGBM	Light Gradient Boosting Machine (máy tăng cường gradient)
LSTM	Long Short-Term Memory (bộ nhớ dài ngắn hạn)
BiLSTM	Bidirectional Long Short-Term Memory (bộ nhớ dài ngắn hạn hai chiều)
GRU	Gated Recurrent Unit (nút hồi tiếp có cổng)
MLP	Multi-layer Perceptron (mạng nơ-ron nhiều lớp)
GB	Gradient boosting (tăng cường gradient hoặc gia tăng gradient)
MSE	Mean Square Error (sai số trung bình bình phương)
RMSE	Root Mean Square Error (sai số trung bình bình phương gốc)
MAE	Mean Absolute Error (sai số tuyệt đối trung bình)
MAPE	Mean Absolute Percentage Error (sai số tuyệt đối trung bình phần trăm)
MBE	Mean Bias Error (lỗi sai lệch trung bình)
MASE	Mean Absolute Scaled Error (lỗi tỷ lệ tuyệt đối trung bình)
$R^2$	Hệ số xác định
NWP	Numerical Weather Prediction (mô hình dự báo thời tiết số)
SIM	Sky Image Models (mô hình hình ảnh bầu trời)
GOSS	Gradient-based One-Side Sampling (lấy mẫu dựa trên gradient)
EFB	Exclusive Feature Bundling (gom nhóm đặc trưng loại trừ)
ARIMA	Autoregressive Integrated Moving Average (mô hình tự hồi quy tích hợp trung bình trượt)

**1. GIỚI THIỆU**

Năng lượng mặt trời được kỳ vọng là nguồn năng lượng sạch và đóng vai trò quan trọng trong chiến lược phát triển năng lượng bền vững trong tương lai [1]. Việc sử dụng điện mặt trời ngày càng phổ biến đã làm tăng nhu cầu dự báo bức xạ mặt trời, vì dự báo này đóng vai trò quan trọng trong việc dự báo công suất phát điện mặt trời do mối tương quan chặt chẽ giữa hai yếu tố này [2]. Ngoài ra dự báo bức xạ mặt trời còn góp phần lập kế hoạch vận hành, chuyển đổi nguồn điện, lập kế hoạch dự phòng, mua điện trong ngắn hạn, cũng như lập kế hoạch sử dụng nguồn dự trữ và điều chỉnh phụ tải vào giờ cao điểm [3].

Hiện nay, nhiều mô hình dự báo bức xạ mặt trời đang được áp dụng trên thế giới. Mô hình vật lý phổ biến là mô hình hình ảnh bầu trời (Sky Image Models-SIM) [4] và mô hình dự báo thời tiết số (Numerical Weather Prediction - NWP) [5]. Các mô hình này dựa trên các phương trình vật lý mô tả quá trình truyền bức xạ qua khí quyển, sử dụng các yếu tố như thành phần khí quyển, nhiệt độ, và độ ẩm. Ưu điểm của các mô hình vật lý là có cơ sở khoa học vững chắc và hiệu quả trong dự báo dài hạn, đặc biệt trong các điều kiện khí quyển phức tạp. Tuy nhiên, nhược điểm là yêu cầu dữ liệu đầu vào phức tạp và tốn nhiều tài nguyên tính toán, thường phải được thực hiện trên siêu máy tính [6].

Bên cạnh các mô hình vật lý thì các mô hình thống kê cũng được sử dụng rộng rãi. Các mô hình thống kê sử dụng các phương pháp thống kê để phân tích dữ liệu lịch sử như là mô hình ARIMA, mô hình hồi quy tuyến tính... Chúng có ưu điểm là đơn giản, hiệu quả cho dự báo ngắn hạn nhưng có nhược điểm là khó nắm bắt các mối quan hệ phi tuyến phức tạp [6].

Trong những năm gần đây, các phương pháp học máy và học sâu đã chứng tỏ tiềm năng to lớn trong việc dự báo bức xạ mặt trời. Nhiều nghiên cứu trước đây đã chỉ ra rằng các mô hình học máy có hiệu suất vượt trội so với các phương pháp thống kê trong lĩnh vực dự báo bức xạ mặt trời [7, 8]. Trong lĩnh vực dự báo bức xạ mặt trời, ba mô hình học máy tiên tiến đã được sử dụng rộng rãi và chứng minh hiệu quả trong nhiều nghiên cứu gần đây: LightGBM, LSTM, và GRU [9-14]. Các nghiên cứu đã chỉ ra rằng mỗi mô hình đều có những ưu điểm riêng trong việc xử lý dữ liệu khí tượng phức tạp và dự báo bức xạ mặt trời. LightGBM [15] là một mô hình Gradient Boosting tiên tiến, nổi tiếng với tốc độ xử lý nhanh và hiệu quả cao trong việc xử lý dữ liệu có độ phức tạp lớn. LightGBM có khả năng tự động xử lý các đặc trưng phi tuyến và tương tác giữa các biến, điều này đặc biệt hữu ích trong việc

nắm bắt các mối quan hệ phức tạp giữa các yếu tố khí tượng và bức xạ mặt trời. Mô hình LSTM [16] là một loại mạng nơ-ron hồi quy và được thiết kế đặc biệt để xử lý dữ liệu chuỗi thời gian. Khả năng ghi nhớ thông tin dài hạn của LSTM làm cho mô hình trở thành một lựa chọn lý tưởng cho việc dự báo bức xạ mặt trời, nơi các đặc trưng và xu hướng trong dài hạn đóng vai trò quan trọng. Mô hình GRU [17] cũng là một biến thể của mạng nơ-ron hồi quy giống như LSTM nhưng có cấu trúc đơn giản hơn. GRU có khả năng học các mẫu phụ thuộc trong thời gian ngắn hạn và dài hạn, tuy nhiên mô hình này cần ít tài nguyên tính toán hơn so với LSTM.

Nghiên cứu này nhằm mục đích so sánh hiệu suất của các mô hình LightGBM, LSTM, và GRU trong dự báo bức xạ mặt trời. Nhóm nghiên cứu đánh giá các mô hình dựa trên độ chính xác dự báo, tốc độ xử lý và khả năng áp dụng cho các khoảng thời gian dự báo khác nhau. Bằng cách phân tích chi tiết ưu và nhược điểm của mỗi phương pháp, nghiên cứu này cung cấp những hiểu biết quý giá cho việc lựa chọn và triển khai mô hình dự báo bức xạ mặt trời trong các ứng dụng thực tế tại Việt Nam.

Kết quả của nghiên cứu này không chỉ góp phần vào sự phát triển của lĩnh vực dự báo năng lượng tái tạo mà còn có ý nghĩa thực tiễn đối với các nhà quản lý lưới điện, nhà phát triển dự án điện mặt trời, và các nhà hoạch định chính sách. Thông qua việc cải thiện độ chính xác của dự báo bức xạ mặt trời, chúng ta có thể nâng cao hiệu quả và độ tin cậy của việc dự báo công suất phát điện mặt trời.

Nghiên cứu được chia thành 4 phần: phần 1 là giới thiệu chung về việc dự báo và ba mô hình dự báo bức xạ mặt trời đã nói ở trên, phần 2 trình bày cụ thể các mô hình áp dụng, phần 3 trình bày các kết quả và thảo luận, phần 4 là kết luận.

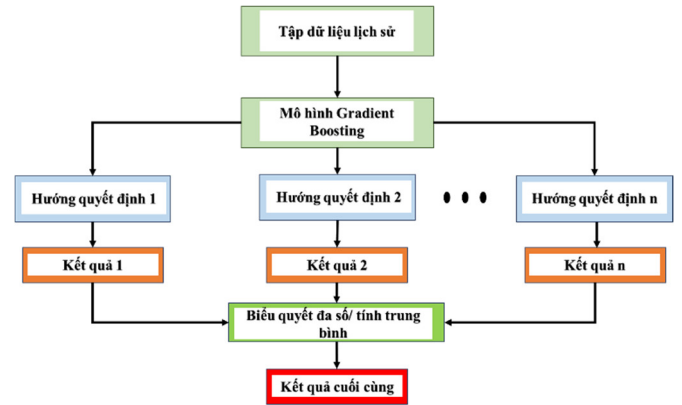
## 2. PHƯƠNG PHÁP LUẬN VÀ TRIỂN KHAI CÁC MÔ HÌNH DỰ BÁO

### 2.1. Mô hình lightgbm

LightGBM là một thuật toán Gradient Boosting (GB) dựa trên cây quyết định, được phát triển bởi Microsoft [15]. Cấu trúc của một GB được thể hiện trong hình 1.

LightGBM sử dụng hai kỹ thuật chính để cải thiện hiệu suất là GOSS và EFB [15, 19]. GOSS giúp cải thiện tốc độ huấn luyện bằng cách huấn luyện trên các mẫu có gradient lớn và chỉ chọn ngẫu nhiên một phần các mẫu có gradient nhỏ để huấn luyện, điều này giúp giảm lượng dữ liệu cần xử lý mà vẫn duy trì độ chính xác của mô hình. EFB giải quyết vấn đề dữ liệu có nhiều đặc trưng bằng cách kết hợp các đặc trưng tương đồng thành một nhóm

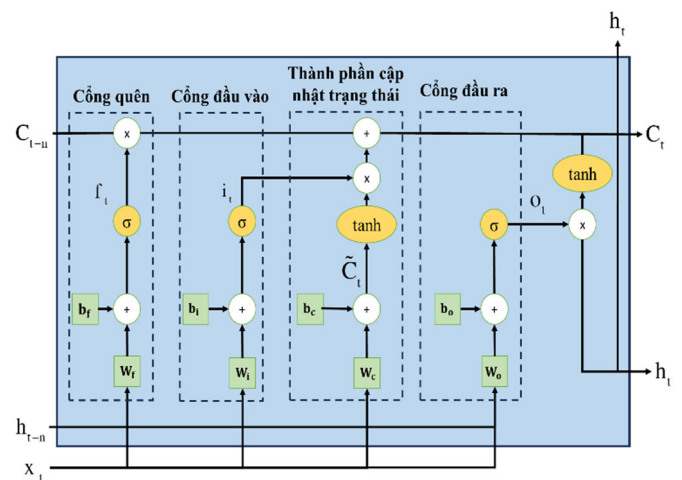
đặc trưng duy nhất. Trong nhiều tập dữ liệu thực tế, nhiều đặc trưng thường là thưa thớt (sparse) và hiếm khi có giá trị khác không cùng lúc. EFB tận dụng đặc điểm này để gom nhóm các đặc trưng lại, giúp giảm đáng kể chiều của không gian đặc trưng. Do vậy, EFB tăng tốc độ huấn luyện và giảm sử dụng bộ nhớ mà không ảnh hưởng đáng kể đến độ chính xác của mô hình.



Hình 1. Cấu trúc của một mô hình Gradient boosting [18]

### 2.2. Mô hình LSTM

LSTM được thiết kế bởi Sepp Hochreiter và các cộng sự [16] và là một loại mạng nơ-ron hồi quy sâu để giải quyết vấn đề gradient biến mất và gradient bùng nổ trong các mô hình nơ-ron hồi quy truyền thống. LSTM sử dụng các cổng (gates) để kiểm soát luồng thông tin và duy trì trạng thái trong một khoảng thời gian dài.



Hình 2. Cấu trúc của mô hình LSTM [20]

Một đơn vị LSTM bao gồm ba cổng chính: cổng vào (input gate), cổng quên (forget gate) và cổng ra (output gate). Các cổng này được xác định bởi các công thức sau [21]:

1) Cổng quên (forget gate)  $f_t$ :

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

2) Cổng vào (input gate)  $i_t$ :

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \tag{2}$$

3) Thành phần cập nhật trạng thái  $C_t$ :

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \tag{3}$$

$$C_t = i_t \odot C_{t-1} \oplus \tilde{C}_t$$

4) Cổng ra (output gate)  $h_t$ :

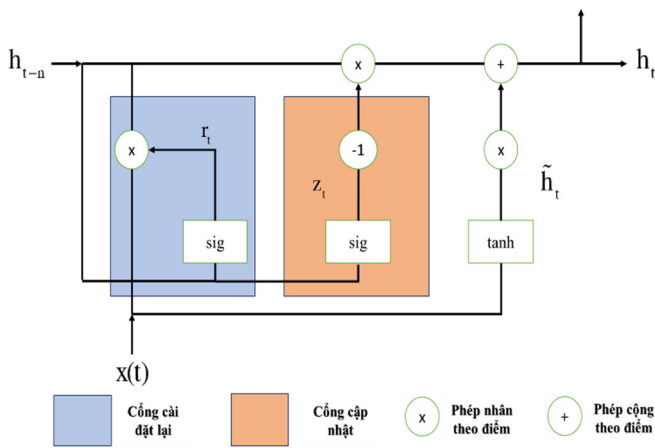
$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \tag{4}$$

$$h_t = o_t \odot \tanh(C_t)$$

Trong đó:  $\sigma$  là hàm sigmoid,  $\tanh$  là hàm hyperbolic tangent,  $W_f, W_i, W_C, W_o$  và  $b_f, b_i, b_C, b_o$  là các tham số của mô hình,  $x_t$  là đầu vào tại thời điểm  $t$ ,  $h_{t-1}$  là trạng thái ẩn từ thời điểm trước đó,  $C_t$  là trạng thái của tế bào nơ-ron tại thời điểm  $t$ ,  $\tilde{C}_t$  là giá trị cập nhật trạng thái của tế bào nơ-ron,  $\oplus$  là phép cộng hadamard,  $\odot$  là phép nhân hadamard.

### 2.3. Mô hình GRU

GRU [17] là một biến thể của LSTM, đơn giản hơn và có ít tham số hơn so với LSTM. GRU cũng sử dụng các cổng để kiểm soát luồng thông tin, nhưng mô hình này kết hợp cổng quên và cổng vào thành một cổng gọi là cổng cập nhật (update gate).



Hình 3. Cấu trúc mô hình GRU [22]

Một đơn vị GRU bao gồm hai cổng chính: cổng cập nhật (update gate) và cổng cài đặt lại (reset gate). Các cổng này được xác định bởi các công thức sau [22]:

1) Cổng khôi phục (reset gate)  $r_t$ :

$$r_t = \sigma(W_{xr}x_t + W_{hr}h_{t-1} + b_r) \tag{5}$$

2) Cổng cập nhật (update gate)  $z_t$ :

$$z_t = \sigma(W_{xt}x_t + W_{hz}h_{t-1} + b_z) \tag{6}$$

3) Nội dung nhớ hiện tại  $\tilde{h}_t$ :

$$\tilde{h}_t = \tanh(W_{xh}x_t + W[r_j \odot h_{t-1}]) \tag{7}$$

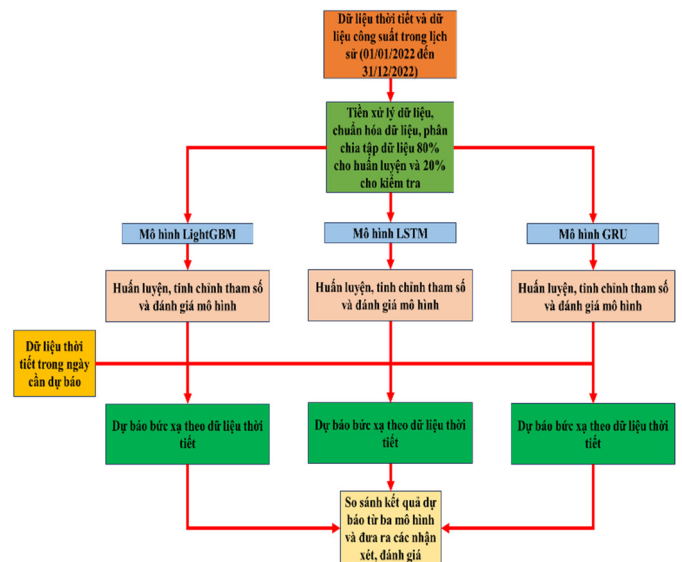
4) Bộ nhớ tại thời điểm hiện tại  $h_t$ :

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \tag{8}$$

Trong đó:  $\sigma$  là hàm sigmoid,  $\tanh$  là hàm hyperbolic tangent,  $W_{xr}$  là trọng số giữa đầu vào của nơ-ron hiện tại và cổng reset,  $W_{hr}$  là trọng số giữa trạng thái ẩn và cổng reset,  $W_{xz}$  là trọng số giữa cổng cập nhật và trạng thái ẩn,  $W_{xh}$  là trọng số giữa đầu vào của nơ-ron hiện tại và trạng thái ẩn,  $W$  là trọng số tạm thời sau khi nhân từng phần tử,  $b_r, b_z$  là độ lệch của cổng khôi phục và cổng cập nhật,  $x_t$  vector đặc trưng đầu vào tại bước thời gian  $t$ ,  $h_{t-1}$  là trạng thái từ thời điểm trước đó,  $h_t$  là trạng thái tại thời điểm  $t$ ,  $\odot$  là phép nhân hadamard.

### 2.4. Sơ đồ thuật toán so sánh ba mô hình LightGBM, LSTM, GRU trong dự báo bức xạ mặt trời

Nghiên cứu này áp dụng một phương pháp tiếp cận có hệ thống để so sánh hiệu suất của ba mô hình học máy tiên tiến là LightGBM, LSTM và GRU trong việc dự báo bức xạ mặt trời. Quy trình nghiên cứu được thiết kế để đảm bảo tính nhất quán và công bằng trong việc đánh giá các mô hình, bao gồm các bước chính được thể hiện trong sơ đồ hình 4.



Hình 4. Sơ đồ thuật toán so sánh ba mô hình LightGBM, LSTM, GRU trong dự báo bức xạ mặt trời

#### 2.4.1. Các bước thực hiện thuật toán

\*) **Tập dữ liệu dùng để huấn luyện:** tập dữ liệu huấn luyện là tập dữ liệu được thu thập từ 01/01/2022 đến

31/12/2022 tại một nhà máy điện mặt trời có công suất 49,5MW tại Miền trung Việt Nam. Các thông số trong tập dữ liệu lịch sử bao gồm: Bức xạ mặt trời, nhiệt độ môi trường, nhiệt độ tấm pin và các tháng trong năm. Quá trình tiền xử lý bao gồm việc làm sạch dữ liệu, xử lý giá trị thiếu và chuẩn hóa các đặc trưng. Dữ liệu sau đó được chia thành tập huấn luyện (80%) và tập kiểm tra (20%) để đảm bảo đánh giá công bằng. Để đảm bảo tính khách quan và đánh giá khả năng tổng quát hóa của các mô hình, nhóm tác giả đã sử dụng hai tập dữ liệu độc lập không thuộc các tập dữ liệu huấn luyện và kiểm tra để kiểm tra hiệu suất dự báo. Tập dữ liệu ngắn hạn là dữ liệu thời tiết của ngày 15/02/2021, mục đích nhằm đánh giá khả năng dự báo ngắn hạn của mô hình đồng thời kiểm tra hiệu suất mô hình trong điều kiện dự báo hàng ngày, phản ánh ứng dụng thực tế trong vận hành hệ thống năng lượng mặt trời. Tập dữ liệu trung hạn là dữ liệu thời tiết từ ngày 01/3 đến ngày 03/3/2021, mục đích là đánh giá khả năng dự báo trung hạn và tính ổn định của mô hình, kiểm tra hiệu suất mô hình trong khoảng thời gian dài hơn, phản ánh khả năng dự báo cho kế hoạch vận hành và bảo trì. Mỗi tập dữ liệu dự báo bao gồm dự báo cho toàn bộ 24 giờ trong một ngày (ngày 15/02/2021) và 72 giờ (từ 01 đến 03/3/2021), với các lần dự báo được thực hiện đều đặn cứ sau mỗi 5 phút. Điều này có nghĩa là trong suốt một ngày, mô hình sẽ dự báo bức xạ mặt trời liên tục tại các khoảng thời gian 5 phút một lần, giúp phản ánh chi tiết và chính xác sự biến động của bức xạ mặt trời trong ngày, từ đó hỗ trợ tối ưu hóa quá trình vận hành và điều chỉnh hệ thống năng lượng mặt trời.

**\*) Xây dựng và huấn luyện mô hình:** ba mô hình LightGBM, LSTM và GRU được xây dựng và huấn luyện song song trên cùng một bộ dữ liệu. Quá trình này bao gồm việc tinh chỉnh các siêu tham số để tối ưu hóa hiệu suất của từng mô hình.

**\*) Đánh giá mô hình:** Các mô hình được huấn luyện trên tập dữ liệu huấn luyện và đánh giá ban đầu dựa trên tập dữ liệu kiểm tra. Sau đó, hiệu suất dự báo của chúng được đánh giá sâu hơn trên dữ liệu thời tiết của ngày 15/02/2021 và từ 01 - 03/3/2021. Quá trình đánh giá tập trung vào các yếu tố là độ chính xác của dự báo, thời gian thực hiện việc huấn luyện và dự báo, khả năng áp dụng cho các khoảng thời gian dự báo khác nhau. Kết quả từ các bước trên được phân tích kỹ lưỡng để xác định ưu và nhược điểm của từng mô hình. Các chỉ số đánh giá cụ thể và lý do lựa chọn chúng sẽ được trình bày chi tiết trong phần tiếp theo.

### 2.4.2. Các chỉ số đánh giá

Các chỉ số đánh giá độ chính xác của các mô hình dự báo thường được các nhóm nghiên cứu sử dụng trong dự báo bức xạ mặt trời được thể hiện trong bảng 1.

Bảng 1. Các chỉ số đánh giá thường được sử dụng trong dự báo bức xạ mặt trời

Các nghiên cứu	Mô hình dự báo	Các chỉ số đánh giá được sử dụng
Multistep-ahead solar radiation forecasting scheme based on the light gradient boosting machine: A case study of Jeju Island [9]	Mô hình LightGBM	MBE, MAE, RMSE, NRMSE
Solar Radiation Forecasting Using Ensemble-Based Hybrid LGBM-GB-MLP Model: A Novel Stacked Generalization Method [10]	Mô hình LightGBM-GB-MLP	RMSE, MAE, R <sup>2</sup>
Long-term solar radiation forecasting based on LSTM and attention mechanism: a case study in Algeria [11]	Mô hình LSTM, BiLSTM, MLP	RMSE, MAE, MAPE, MASE
Forecasting Hourly Solar Irradiance Using Long Short-Term Memory (LSTM) Network [12]	Mô hình LSTM	MSE, RMSE, MAE
Long-term Solar Radiation Forecasting using a Deep Learning Approach-GRUs [13]	Mô hình GRUs	RMSE
Predicting day-ahead solar irradiance through gated recurrent unit using weather forecasting data [14]	Mô hình GRU	RMSE

Dựa trên các nghiên cứu từ bảng 1, nhóm nghiên cứu quyết định sử dụng các chỉ số RMSE và MAE để đánh giá độ chính xác của các mô hình dự báo.

#### a) Sai số RMSE

RMSE là sai số trung bình bình phương gốc giữa giá trị dự báo và giá trị thực tế. Công thức tính RMSE như sau [10]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{9}$$

Trong đó:  $\hat{y}_i$  là bức xạ dự báo ( $W/m^2$ ),  $y_i$  là bức xạ thực tế ( $W/m^2$ ),  $n$  là số lượng điểm dữ liệu.

RMSE đo lường độ lớn trung bình của lỗi dự báo và nhạy cảm với các lỗi lớn do việc bình phương sai số. Đơn vị của RMSE giống với đơn vị của biến được dự báo, giúp dễ dàng diễn giải. RMSE thấp hơn chỉ ra dự báo chính xác hơn.

b) Sai số MAE

MAE là sai số tuyệt đối trung bình giữa giá trị dự báo và giá trị thực tế. Công thức tính MAE như sau [10]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{10}$$

Trong đó:  $\hat{y}_i$  giá trị bức xạ dự báo ( $W/m^2$ ),  $y_i$  là giá trị bức xạ thực tế ( $W/m^2$ ),  $n$  là số lượng điểm dữ liệu.

MAE đo lường độ chính xác của dự báo bằng cách tính toán sai số tuyệt đối trung bình giữa giá trị dự báo và giá trị thực tế. MAE xử lý tốt với các điểm dữ liệu có giá trị 0 và gần 0, điều này đặc biệt hữu ích trong dự báo bức xạ mặt trời khi có những thời điểm bức xạ rất thấp hoặc bằng 0.

3. KẾT QUẢ VÀ THẢO LUẬN

3.1. Kết quả

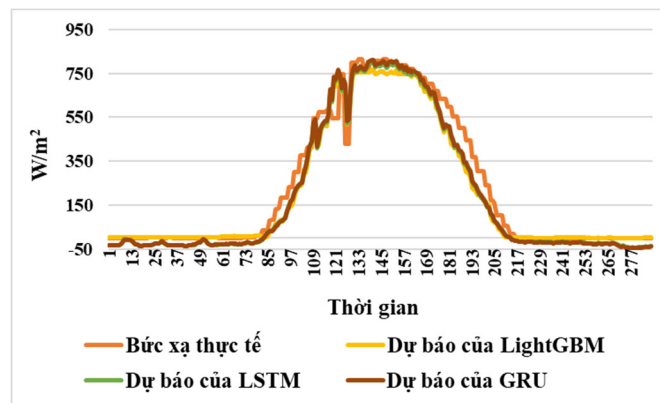
Nhóm nghiên cứu tiến hành quá trình đánh giá mô hình qua hai giai đoạn chính. Đầu tiên là giai đoạn huấn luyện và đánh giá ban đầu, các mô hình được huấn luyện trên tập dữ liệu huấn luyện, hiệu suất của quá trình huấn luyện được đánh giá thông qua các chỉ số trên tập kiểm tra. Tiếp theo là giai đoạn đánh giá hiệu suất dự báo, nhóm nghiên cứu tiến hành dự báo bức xạ mặt trời cho ngày 15/02/2021 và từ ngày 01 đến 03/3/2021. Việc thực hiện hai kịch bản dự báo này nhằm đánh giá sự tác động của miền dự báo tới hiệu suất làm việc của các mô hình. Kết quả dự báo của cả hai kịch bản được trình bày chi tiết trong bảng 2.

Bảng 2. Kết quả dự báo bức xạ mặt trời của ba mô hình LightGBM, LSTM, GRU với các tập dữ liệu kiểm tra và dự báo

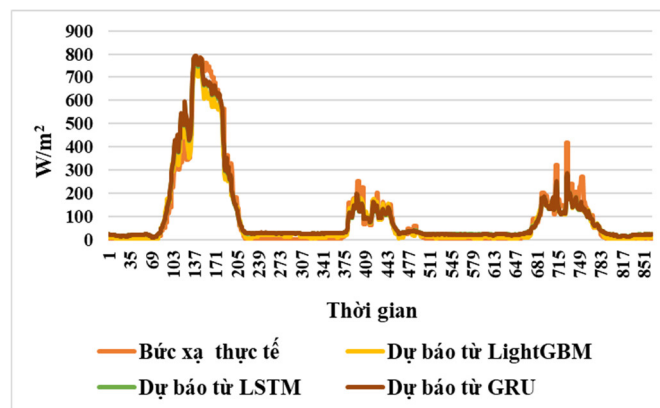
Các chỉ số		Mô hình LightGBM	Mô hình LSTM	Mô hình GRU
Tập kiểm tra	Thời gian thực hiện (s)	0,534	456,571	397,197
	RMSE ( $W/m^2$ )	54,817	59,164	59,331
	MAE ( $W/m^2$ )	27,599	34,788	34,749
Tập dữ liệu thời tiết ngày 15/02/2021	Thời gian thực hiện (s)	0,121	1,454	1,762
	RMSE ( $W/m^2$ )	60,099	58,837	57,452
	MAE ( $W/m^2$ )	36,219	44,446	42,753
Tập dữ liệu thời tiết các ngày từ 01-03/3/2021	Thời gian thực hiện (s)	0,210	2,479	1,566
	RMSE ( $W/m^2$ )	36,274	38,239	38,136
	MAE ( $W/m^2$ )	21,048	27,478	26,973

Kết quả ở bảng 2 cho thấy: xét trên tập kiểm tra thì LightGBM có RMSE thấp nhất ( $54,817W/m^2$ ), nên độ chính

xác tổng thể là tốt nhất, LSTM và GRU có RMSE tương đương nhau nhưng cao hơn LightGBM một chút. LightGBM có MAE thấp nhất ( $27,599W/m^2$ ), trong khi LSTM và GRU có MAE tương đương nhau ( $34,788 W/m^2$  và  $34,747 W/m^2$ ) và cao hơn LightGBM. Về thời gian thực hiện, LightGBM là mô hình nhanh nhất ( $0,534s$ ), trong khi LSTM và GRU chậm hơn nhiều ( $456,571s$  và  $397,197s$ ). Về kết quả dự báo ngày 15/02/2021 thì cả ba mô hình LightGBM, LSTM và GRU có RMSE gần như tương đương nhau ( $60,099; 58,837; 57,452W/m^2$ ), mô hình LightGBM có MAE thấp nhất ( $36,219W/m^2$ ) trong khi hai mô hình LSTM và GRU có sai số MAE cao hơn một chút ( $44,446W/m^2$  và  $42,753W/m^2$ ), LightGBM vẫn là mô hình cho kết quả nhanh nhất ( $0,121s$ ). Với kết quả dự báo trong khoảng thời gian 01 - 03/3/2021 thì mô hình LightGBM, LSTM và GRU cũng có RMSE xấp xỉ tương đương nhau ( $36,274; 38,239; 38,136W/m^2$ ) và LightGBM vẫn là mô hình có MAE thấp nhất ( $21,048 W/m^2$ ), và tiếp tục là mô hình nhanh nhất ( $0,21s$ ).



Hình 5. Biểu đồ giá trị dự báo của ba mô hình LightGBM, LSTM, GRU so với giá trị bức xạ thực tế ngày 15/02/2021



Hình 6. Biểu đồ giá trị dự báo của ba mô hình LightGBM, LSTM, GRU so với giá trị bức xạ thực tế ngày 01 - 03/3/2021

Để minh họa rõ hơn sự so sánh giữa bức xạ dự báo và bức xạ thực tế cho các ngày dự báo, nhóm nghiên cứu xây dựng hai biểu đồ được thể hiện trong hình 5 và 6. Trong

mỗi hình, trục hoành biểu thị thời gian trong ngày được chia thành các khoảng thời gian dự báo cách nhau 5 phút, trong khi trục tung biểu thị các giá trị bức xạ mặt trời.

Kết quả trong đồ thị hình 5 và 6 cho thấy, trong cả hai kịch bản dự báo ngắn hạn và trung hạn thì cả ba mô hình dự báo đều bám sát đường bức xạ thực tế, điều này thể hiện cả ba mô hình đều nắm bắt tốt xu hướng tăng và giảm của bức xạ trong ngày. Ngoài ra, có các sự sụt giảm đột ngột trong bức xạ thực tế của cả hai biểu đồ và các mô hình vẫn nắm bắt được tốt xu hướng giảm đột ngột này, điều này cho thấy khả năng phản ứng của các mô hình với những thay đổi nhanh chóng trong điều kiện bức xạ. Tuy nhiên, mức độ thay đổi của các mô hình dự báo không sát với thực tế, điều này cho thấy một hạn chế của các mô hình trong việc dự báo chính xác mức độ của những biến động đột ngột và cực đoan.

### 3.2. Thảo luận

Với các kết quả thu được, mô hình LightGBM thể hiện là mô hình có tốc độ tính toán nhanh nhất, cân bằng nhất về độ chính xác và hiệu suất tính toán. LightGBM phù hợp cho các dự báo ngắn hạn, trung hạn và các ứng dụng yêu cầu thời gian xử lý nhanh. Hai mô hình LSTM và GRU tuy có độ chính xác tương đương LightGBM nhưng thời gian tính toán lâu hơn rất nhiều so với LightGBM.

LightGBM có lợi thế rõ rệt trong việc xử lý dữ liệu nhanh chóng và hiệu quả. Cụ thể, thời gian thực hiện trên tập kiểm tra của LightGBM chỉ mất 0,534s so với 456,571s của LSTM và 397,197s của GRU. Trên tập dữ liệu dự báo, thời gian thực hiện của LightGBM cũng chỉ là 0,121s và 0,21s, vượt trội so với 1,454s và 2,479s của LSTM; 1,762s và 1,566s của GRU. Điều này cho thấy LightGBM là lựa chọn tối ưu khi yêu cầu về thời gian tính toán là quan trọng.

Mặc dù LSTM và GRU có thể mô hình hóa tốt các đặc điểm phức tạp của dữ liệu thời gian, nhưng chúng đòi hỏi thời gian huấn luyện và dự báo lâu hơn. Đối với các ứng dụng mà thời gian xử lý không phải là yếu tố quyết định, các mô hình này vẫn có thể là lựa chọn tốt nhờ khả năng học hỏi và mô hình hóa các quan hệ phức tạp trong dữ liệu.

Tuy nhiên, vấn đề của cả ba mô hình LightGBM, LSTM và GRU là mức độ chênh lệch trong dự báo bức xạ còn cách khá xa so với thực tế, điều này đặt ra một vấn đề rằng các mô hình này dựa trên tập dữ liệu lịch sử hạn chế của nhà máy nên khó có thể đạt được độ chính xác ngang bằng với các dịch vụ dự báo chuyên nghiệp từ các tổ chức chuyên về dự báo bức xạ và thời tiết. Vì các tổ chức chuyên nghiệp này được trang bị công nghệ tối tân, bao gồm các siêu máy tính và mô hình dự báo tiên tiến, nên cho phép họ cung cấp dự báo chính xác hơn đáng kể.

## 4. KẾT LUẬN

LightGBM thể hiện hiệu suất tổng thể vượt trội đặc biệt trong dự báo trung hạn. Các mô hình học sâu LSTM và GRU có ưu thế trong dự báo ngắn hạn, cho thấy khả năng nắm bắt tốt các mẫu dữ liệu trong thời gian ngắn hạn. LightGBM cũng nổi bật với thời gian thực hiện nhanh nhất trong mọi kịch bản, phù hợp cho ứng dụng thời gian thực. LSTM và GRU đòi hỏi thời gian xử lý đáng kể, có thể gây thách thức trong môi trường có giới hạn tài nguyên tính toán.

Độ chính xác của các mô hình thay đổi tùy theo khoảng thời gian dự báo, cho thấy không có một mô hình nào là phù hợp tất cả. Mỗi mô hình có ưu điểm riêng trong các kịch bản dự báo khác nhau, nhấn mạnh tầm quan trọng của việc lựa chọn mô hình phù hợp cho từng ứng dụng cụ thể.

Như vậy đối với các ứng dụng yêu cầu dự báo nhanh và dự báo trung hạn thì mô hình LightGBM là một lựa chọn tốt với độ chính xác cao và tiêu tốn ít tài nguyên tính toán. Cần nhắc sử dụng mô hình LSTM hoặc GRU cho dự báo ngắn hạn khi độ chính xác là ưu tiên hàng đầu và có đủ tài nguyên tính toán.

Trong lĩnh vực dự báo bức xạ mặt trời, việc chỉ sử dụng các mô hình dự báo dựa trên tập dữ liệu lịch sử hạn chế của một nhà máy cụ thể thường không thể đạt được độ chính xác ngang bằng với các dịch vụ dự báo chuyên nghiệp từ các tổ chức chuyên về khí tượng và bức xạ mặt trời. Do đó, để nâng cao độ chính xác trong dự báo bức xạ mặt trời, việc tích hợp thông tin dự báo từ các tổ chức chuyên ngành này vào quy trình dự báo của nhà máy là một bước đi quan trọng và cần thiết.

### TÀI LIỆU THAM KHẢO

- [1]. J. Cao, X. Lin, "Application of the diagonal recurrent wavelet neural network to solar irradiation forecast assisted with fuzzy technique," *Eng. Appl. Artif. Intell.*, 21, 8, 1255-1263, 2008. doi: 10.1016/j.engappai.2008.02.003.
- [2]. R. Ahmed, V. Sreeram, Y. Mishra, M. D. Arif, "A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization," *Renew. Sustain. Energy Rev.*, 124, no. February, 109792, 2020. doi: 10.1016/j.rser.2020.109792.
- [3]. G. Reikard, "Predicting solar radiation at high resolutions: A comparison of time series forecasts," *Sol. Energy*, 83, 3, 342-349, 2009. doi: 10.1016/j.solener.2008.08.007.
- [4]. E. Lorenz, J. Hurka, D. Heinemann, H. G. Beyer, "Irradiance Forecasting for the Power Prediction of Grid-Connected Photovoltaic Systems," *IEEE J. Sel.*

*Top. Appl. Earth Obs. Remote Sens.*, 2, 1, 2-10, 2009. doi: 10.1109/JSTARS.2009.2020300.

[5]. Vincent E. Larson, *Forecasting Solar Irradiance with Numerical Weather Prediction Models*. Elsevier, 2013.

[6]. E. Chodakowska, J. Nazarko, Ł. Nazarko, H. S. Rabayah, R. M. Abende, R. Alawneh, "ARIMA Models in Solar Radiation Forecasting in Different Geographic Locations," *Energies*, 16, 13, 2023. doi: 10.3390/en16135029.

[7]. M. A. Ali, A. Elsayed, I. Elkabani, M. Akrami, M. E. Youssef, G. E. Hassan, "Optimizing Artificial Neural Networks for the Accurate Prediction of Global Solar Radiation: A Performance Comparison with Conventional Methods," *Energies*, 16, 17, 2023. doi: 10.3390/en16176165.

[8]. A. Inanloungani, T. A. Reddy, S. Katiamula, "Evaluation of Time-Series, Regression and Neural Network Models for Solar Forecasting: Part I: One-Hour Horizon," *arXiv Prepr. arXiv1708.08376*, 1-20, 2017.

[9]. J. Park, J. Moon, S. Jung, E. Hwang, "Multistep-ahead solar radiation forecasting scheme based on the light gradient boosting machine: A case study of Jeju Island," *Remote Sens.*, 12, 14, 2020. doi: 10.3390/rs12142271.

[10]. E. Nziyumva, R. Hu, Y. Xu, J. Niyogisubizo, Z. Li, P. C. Nshimyumukiza, "Solar Radiation Forecasting Using Ensemble-Based Hybrid LGBM-GB-MLP Model: A Novel Stacked Generalization Method," *SSRN Electron. J.*, no. October, 2022. doi: 10.2139/ssrn.4076358.

[11]. A. Teta, M. Medkour, A. Rabehi, B. Korich, D. Bakria, "Long-term solar radiation forecasting based on LSTM and attention mechanism: a case study in Algeria," *Stud. Eng. Exact Sci.*, 5, 1, 1117-1134, 2024. doi: 10.54021/seesv5n1-058.

[12]. C. N. Obiora, A. Ali, A. N. Hasan, "Forecasting Hourly Solar Irradiance Using Long Short-Term Memory (LSTM) Network," *11th Int. Renew. Energy Congr. IREC 2020*, no. Irec, 2020. doi: 10.1109/IREC48820.2020.9310449.

[13]. M. Aslam, K. H. Seung, S. Jae Lee, J. M. Lee, S. Hong, E. H. Lee, "Long-term Solar Radiation Forecasting using a Deep Learning Approach-GRUs," *APAP 2019 - 8th IEEE Int. Conf. Adv. Power Syst. Autom. Prot.*, 917-920, 2019. doi: 10.1109/APAP47170.2019.9224661.

[14]. B. Gao, X. Huang, J. Shi, Y. Tai, R. Xiao, "Predicting day-ahead solar irradiance through gated recurrent unit using weather forecasting data," *J. Renew. Sustain. Energy*, 11, 4, 2019. doi: 10.1063/1.5110223.

[15]. G. Ke, I. Y. Meng, Qi Finely, Thomas Wang, Taifeng Chen, Wei Ma, Weidong Ye, Qiwei T Liu, "LightGBM: A Highly Efficient Gradient Boosting Decision Tree," *31st Conf. Neural Inf. Process. Syst. (NIPS 2017)*, Long Beach, CA, USA, no. Nips, 2017.

[16]. S. Hochreiter, J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, 9, 8, 1735-1780, 1997. doi: 10.1162/neco.1997.9.8.1735.

[17]. 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, 1724-1734, 2014. doi: 10.3115/v1/d14-1179.

[18]. M. Y. Khan, A. Qayoom, M. S. Nizami, M. S. Siddiqui, S. Wasi, S. M. K. U. R. Raazi, "Automated Prediction of Good Dictionary EXamples (GDEX): A Comprehensive Experiment with Distant Supervision, Machine Learning, and Word Embedding-Based Deep Learning Techniques," *Complexity*, 2021. doi: 10.1155/2021/2553199.

[19]. Y. Peng, S. Wang, W. Chen, J. Ma, C. Wang, J. Chen, "LightGBM-Integrated PV Power Prediction Based on Multi-Resolution Similarity," *Processes*, 11, 4, 2023. doi: 10.3390/pr11041141.

[20]. K. Zarzycki, M. Ławryńczuk, "LSTM and GRU neural networks as models of dynamical processes used in predictive control: A comparison of models developed for two chemical reactors," *Sensors*, 21, 16, 2021. doi: 10.3390/s21165625.

[21]. M. Aslam, S. J. Lee, S. H. Khang, S. Hong, "Two-Stage Attention over LSTM with Bayesian Optimization for Day-Ahead Solar Power Forecasting," *IEEE Access*, 9, 107387-107398, 2021. doi: 10.1109/ACCESS.2021.3100105.

[22]. M. Sabri, M. El Hassouni, "A Novel Deep Learning Approach for Short Term Photovoltaic Power Forecasting Based on GRU-CNN Model," *E3S Web Conf.*, 336, 2022. doi: 10.1051/e3sconf/202233600064.

#### AUTHORS INFORMATION

**Nguyen Tuan Anh<sup>1</sup>, Pham Manh Hai<sup>2</sup>, Le Thanh Doanh<sup>3</sup>,  
Nguyen Ngoc Trung<sup>4</sup>, Vu Thi Anh Tho<sup>1</sup>, Vu Minh Phap<sup>5</sup>,  
Tran Trong Tuan<sup>6</sup>**

<sup>1</sup>Faculty of Electrical Engineering, Electric Power University, Vietnam

<sup>2</sup>Faculty of Energy Technology, Electric Power University, Vietnam

<sup>3</sup>Department of Postgraduate Studies, Electric Power University, Vietnam

<sup>4</sup>Department of Personnel and Organization, Electric Power University, Vietnam

<sup>5</sup>Institute of Science and Technology for Energy & Environment, Vietnam Academy of Science and Technology, Vietnam

<sup>6</sup>National Load Dispatch Center, Vietnam