

NGHIÊN CỨU SỬ DỤNG MÔ HÌNH HỌC MÁY TĂNG CƯỜNG ĐỘ ĐỐC VÀO DỰ ĐOÁN NĂNG LƯỢNG PIN MẶT TRỜI SỬ DỤNG CÔNG NGHỆ QUANG ĐIỆN

Nguyễn Hữu Năm, Trần Quốc Thanh

Viện Thủy điện và Năng lượng tái tạo

Trần Văn Quân

Đại học Công nghệ Giao thông vận tải

Tóm tắt: Nhu cầu năng lượng toàn cầu ngày càng tăng, cùng với nhu cầu về các nguồn năng lượng sạch và bền vững, đã dẫn đến sự gia tăng đáng kể các dự án điện mặt trời trên toàn thế giới nói chung và Việt Nam nói riêng. Tại Việt Nam, công nghệ, kỹ thuật và khả năng phát triển dự án điện mặt trời còn đang phụ thuộc rất nhiều vào nước ngoài, dẫn đến việc triển khai điện mặt trời với quy mô lớn còn gặp nhiều khó khăn, đặc biệt là về giá thành. Điều này khiến điện mặt trời khó có khả năng cạnh tranh với những nguồn điện truyền thống khác. Tuy nhiên việc đánh giá, thiết kế năng lượng pin mặt trời bằng công nghệ quang điện Solar photovoltaic ở Việt Nam còn nhiều hạn chế, chủ yếu do các đơn vị tư vấn nước ngoài. Sẽ hết sức có ý nghĩa nếu có thể đánh giá sơ bộ ban đầu nguồn năng lượng pin mặt trời. Việc sử dụng công cụ học máy ML trong dự báo năng lượng mặt trời đã thu hút được sự chú ý đáng kể trong những năm gần đây, với một số nghiên cứu chứng minh tiềm năng của các mô hình dựa trên ML trong việc cải thiện độ chính xác và độ tin cậy của dự báo năng lượng mặt trời. Do vậy, nghiên cứu này sẽ nghiên cứu đưa ra một ứng dụng cụ thể của một mô hình học máy hiện đại là tăng cường độ dốc (Gradient Boosting) trong việc dự báo năng lượng pin mặt trời từ nhiệt độ môi trường, lượng bức xạ nhiệt và nhiệt độ pin mặt trời.

Từ khóa: Năng lượng pin mặt trời, công nghệ quang điện, học máy, tăng cường độ dốc, dữ liệu lớn

Summary: The increasing global energy demand, along with the need for clean and sustainable energy sources, has led to a significant increase in solar power projects worldwide in general and Vietnam in particular. In Vietnam, technology and the ability to develop solar power projects are still heavily dependent on foreign countries, leading to large-scale solar panel power deployment facing many difficulties, especially about price. This makes it difficult for solar power to compete with other traditional power sources. However, the evaluation and design of solar panel power using Solar photovoltaic technology in Vietnam still has many limitations, mainly due to foreign consulting units. It would be extremely meaningful if we could make a preliminary assessment of the solar cell energy source. The use of ML machine learning in solar panel power forecasting has attracted significant attention in recent years, with several studies demonstrating the potential of ML-based models to improve accuracy and reliability of solar forecasts. Therefore, this study will research and present a specific application of a modern machine learning model, Gradient Boosting, in predicting solar cell energy from environmental temperature, heat radiation and solar cell temperature.

Keywords: Solar panel power, photovoltaic technology, machine learning, Gradient Boosting, big data

1. ĐẶT VẤN ĐỀ

Nhu cầu năng lượng toàn cầu ngày càng tăng, cùng với nhu cầu về các nguồn năng lượng sạch và bền vững, đã dẫn đến sự gia tăng đáng kể các dự án điện mặt trời trên toàn thế giới.

Tuy nhiên, một trong những thách thức lớn mà ngành năng lượng mặt trời phải đối mặt là khả năng sản xuất năng lượng mặt trời không thể đoán trước được, phụ thuộc nhiều vào điều kiện thời tiết như mây che phủ, mưa và cường độ ánh sáng mặt trời. Do đó, việc phát triển các mô hình chính xác và đáng tin cậy để dự báo sản lượng điện của các dự án điện mặt trời là rất cần thiết, điều này rất quan trọng để quản

Ngày nhận bài: 19/9/2023

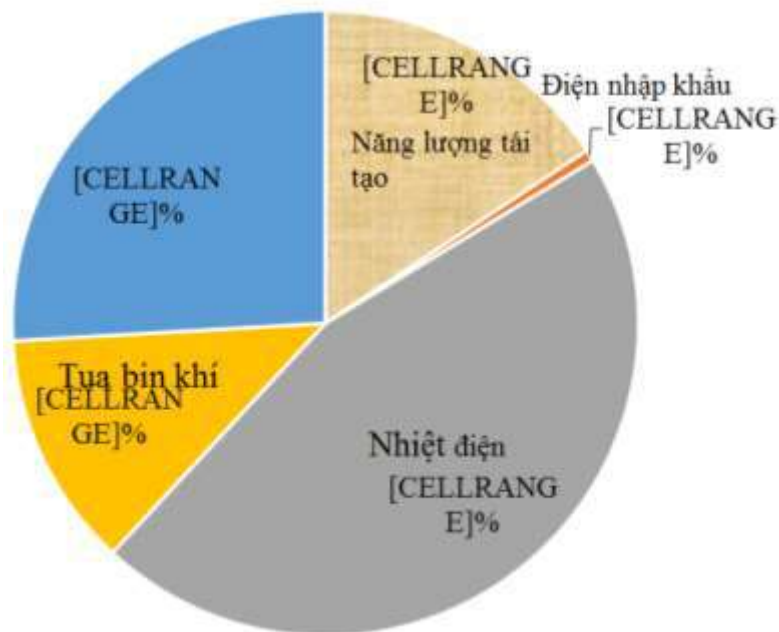
Ngày thông qua phản biện: 05/10/2023

Ngày duyệt đăng: 16/10/2023

lý hiệu quả các hệ thống năng lượng. Thực tế là năng lượng mặt trời dự kiến sẽ đóng một vai trò quan trọng trong quá trình chuyển đổi toàn cầu sang các nguồn năng lượng sạch và tái tạo. Cơ quan Năng lượng Quốc tế (IEA) ước tính rằng năng lượng mặt trời có thể cung cấp tới 30% điện năng của thế giới vào năm 2050 [1]. Dự báo này nhấn mạnh sự cần thiết của các mô hình dự báo năng lượng mặt trời mạnh mẽ có thể hỗ trợ tích hợp hiệu quả năng lượng mặt trời vào lưới điện và tối ưu hóa các hệ thống năng lượng. Hơn nữa, nhu cầu dự báo năng lượng mặt trời đặc biệt cấp thiết ở các nước đang phát triển như Việt Nam, nơi các dự án điện mặt trời đang gia tăng và nhu cầu năng lượng đang tăng nhanh. Theo báo cáo của Ngân hàng Thế giới, nhu cầu năng lượng của Việt Nam dự kiến sẽ tăng trung bình 10% mỗi năm cho đến năm 2030 [2]. Sự tăng trưởng này dự kiến chủ yếu nhờ vào sự mở rộng kinh tế mạnh mẽ, dân số ngày càng tăng và tốc độ đô thị hóa ngày càng tăng của đất nước. Tuy nhiên, quốc gia này hiện đang phụ thuộc rất nhiều vào nhiên liệu hóa thạch, không chỉ góp

phần phát thải khí nhà kính mà còn khiến quốc gia này phải đối mặt với sự biến động của giá dầu toàn cầu. Do đó, nhu cầu đa dạng hóa cơ cấu năng lượng của đất nước ngày càng tăng, trong đó năng lượng mặt trời là một giải pháp thay thế đầy hứa hẹn.

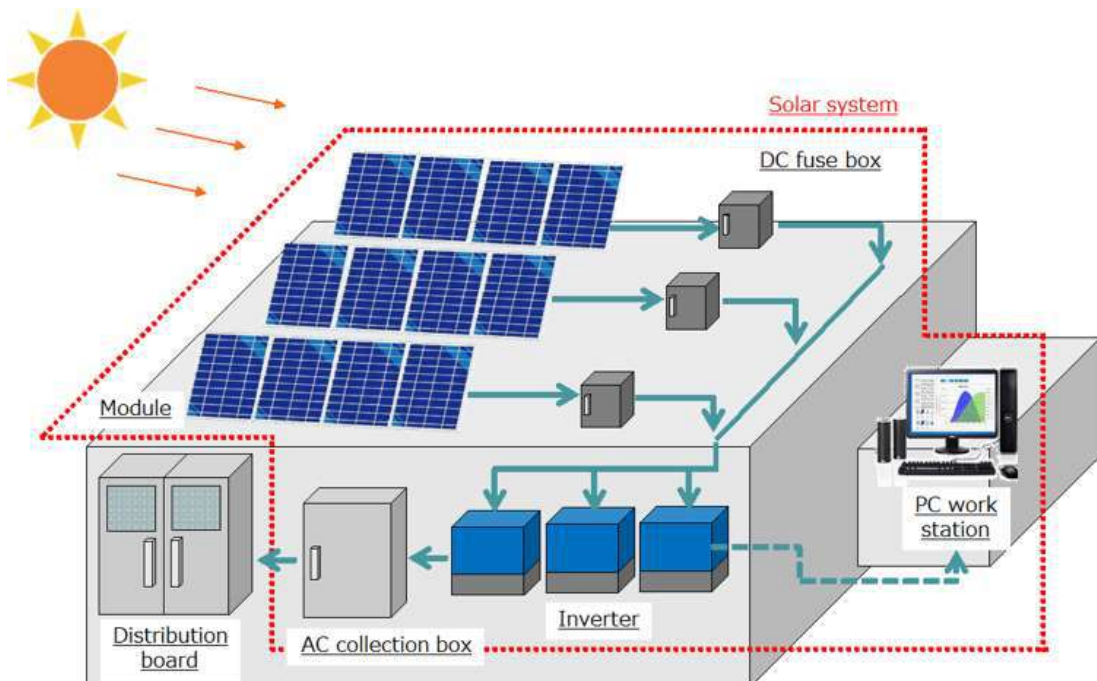
Tập đoàn Điện lực Việt Nam (EVN) cho biết, trong tháng 04/2022 sản lượng điện sản xuất toàn hệ thống đạt 22,62 tỷ kWh, tăng 1,9% so với cùng kỳ. Lũy kế 4 tháng đầu năm, sản lượng điện sản xuất toàn hệ thống đạt 85,65 tỷ kWh, tăng 6,2% so với cùng kỳ năm 2021. Trong đó, mức huy động một số nguồn chính được mô tả trong Hình 1 như sau: (i) thủy điện đạt 22,22 tỷ kWh, chiếm 25,9% tổng sản lượng điện sản xuất toàn hệ thống, (ii) nhiệt điện than đạt 39,09 tỷ kWh, chiếm 45,6%, (iii) tua bin khí đạt 10,42 tỷ kWh, chiếm 12,2%, (iv) điện nhập khẩu đạt 536 triệu kWh, chiếm 0,6%. Đáng chú ý, (v) năng lượng tái tạo gồm điện gió, điện mặt trời, điện sinh khối đạt 13,15 tỷ kWh, chiếm 15,4% tổng sản lượng điện sản xuất toàn hệ thống.



Hình 1: Cơ cấu tổ chức nguồn điện tại Việt Nam thống kê đến tháng 4/2022 theo số liệu của Tập đoàn Điện lực Việt Nam

Trong những năm gần đây, Việt Nam đã có những bước tiến đáng kể trong việc thúc đẩy năng lượng mặt trời, với việc chính phủ thực hiện các chính sách khuyến khích phát triển các dự án điện mặt trời. Năm 2019, Việt Nam đã khởi công nhà máy điện mặt trời lớn nhất Đông Nam Á, công suất 688 MW. Nhà máy dự kiến sẽ sản xuất khoảng 1,2 tỷ kWh điện hàng năm, đủ cung cấp điện cho 1,3 triệu hộ gia đình và giảm 1,2 triệu tấn khí thải carbon mỗi năm. Thành công của dự án này nhấn mạnh tiềm năng của năng lượng mặt trời tại Việt Nam và sự cần thiết của các mô hình dự báo chính xác để hỗ trợ quản lý hiệu quả các hệ thống năng lượng. Theo Dự thảo quy hoạch điện VIII, dự kiến công suất lắp đặt điện mặt trời sẽ tăng từ 17 GW (giai đoạn 2020-2025) lên khoảng 20 GW (năm 2030). Tỷ trọng điện mặt trời được kỳ vọng sẽ chiếm 17% (năm 2025), 14% (năm 2030) trong cơ cấu các nguồn điện. Tại Việt Nam, công nghệ, kỹ thuật và khả năng phát triển dự án điện mặt trời còn đang phụ thuộc rất nhiều vào nước ngoài, dẫn đến việc triển khai điện mặt trời với quy mô

lớn còn gặp nhiều khó khăn, đặc biệt là về giá thành. Điều này khiến điện mặt trời khó có khả năng cạnh tranh với những nguồn điện truyền thống khác. Ứng dụng quan trọng nhất của năng lượng mặt trời hiện nay và trong tương lai vẫn là sản xuất điện năng. Hai loại công nghệ sản xuất điện mặt trời được phát triển rộng rãi là: công nghệ quang điện (SPV - Solar photovoltaic) và công nghệ điện mặt trời hội tụ (CSP - Concentrated solar power). Công nghệ SPV phổ biến nhất hiện nay bao gồm: pin mặt trời tinh thể (chiếm khoảng 90% thị phần), còn lại là pin mặt trời màng mỏng (thị phần khoảng 10%). Hiện nay ở Việt Nam, các dự án đầu tư phát triển điện mặt trời sử dụng phần lớn công nghệ quang điện Solar photovoltaic như được mô tả trong Hình 2. Tuy nhiên việc đánh giá, thiết kế năng lượng pin mặt trời bằng công nghệ quang điện Solar photovoltaic ở Việt Nam còn nhiều hạn chế, chủ yếu do các đơn vị tư vấn nước ngoài. Sẽ hết sức có ý nghĩa nếu có thể đánh giá sơ bộ ban đầu nguồn năng lượng pin mặt trời.



Hình 2 : Công nghệ quang điện (SPV - Solar photovoltaic)

Hiện nay, các mô hình dựa trên công cụ học máy (ML) đã chứng minh thành công đáng kể trong việc dự đoán đầu ra của các dự án năng lượng mặt trời, tận dụng các thuật toán tiên tiến để phân tích nhiều biến số như điều kiện thời tiết, hiệu suất của tấm pin mặt trời và vị trí địa lý [3]. Bằng cách tận dụng dữ liệu lịch sử và dữ liệu thời tiết theo thời gian thực, các mô hình học máy có thể đưa ra dự báo chính xác và đáng tin cậy về sản lượng năng lượng mặt trời, cho phép các nhà quản lý năng lượng tối ưu hóa hệ thống năng lượng và giảm chi phí vận hành.

Việc sử dụng ML trong dự báo năng lượng mặt trời đã thu hút được sự chú ý đáng kể trong những năm gần đây, với một số nghiên cứu chứng minh tiềm năng của các mô hình dựa trên ML trong việc cải thiện độ chính xác và độ tin cậy của dự báo năng lượng mặt trời. Một nghiên cứu được công bố trên tạp chí Năng lượng tái tạo vào năm 2019 đã đề xuất một mô hình dự báo dựa trên ML, sử dụng các thuật toán học máy để dự đoán sản lượng năng lượng mặt trời hàng giờ của hệ thống quang điện. Mô hình đạt độ chính xác 94,9% trong việc dự đoán sản lượng năng lượng mặt trời, vượt trội so với các phương pháp dự báo truyền thống [4]. Một nghiên cứu khác được công bố trên tạp chí Năng lượng ứng dụng vào năm 2022 đã đề xuất một mô hình dựa trên ML sử dụng thuật toán học sâu để dự báo sản lượng điện của nhà máy điện mặt trời [5]. Mô

hình tận dụng dữ liệu thời tiết thời gian thực, dữ liệu sản lượng năng lượng mặt trời trong lịch sử và dữ liệu vận hành nhà máy để đưa ra dự báo chính xác và đáng tin cậy về sản lượng năng lượng mặt trời. Mô hình đạt được độ chính xác hơn 90% trong việc dự đoán sản lượng năng lượng mặt trời, cho thấy tiềm năng của các mô hình dựa trên ML trong việc cải thiện hiệu quả và độ tin cậy của các hệ thống năng lượng. Tại Việt Nam, việc sử dụng các mô hình học máy hay các mô hình trí tuệ nhân tạo (AI) trong dự báo năng lượng mặt trời vẫn còn ở giai đoạn sơ khai, với các nghiên cứu và ứng dụng thực tế còn hạn chế. Do vậy, nghiên cứu này sẽ nghiên cứu đưa ra một ứng dụng cụ thể của một mô hình học máy hiện đại là tăng cường độ dốc (Gradient Boosting) trong việc dự báo năng lượng pin mặt trời từ nhiệt độ môi trường, lượng bức xạ nhiệt và nhiệt độ pin mặt trời.

2. MÔ TẢ CƠ SỞ DỮ LIỆU

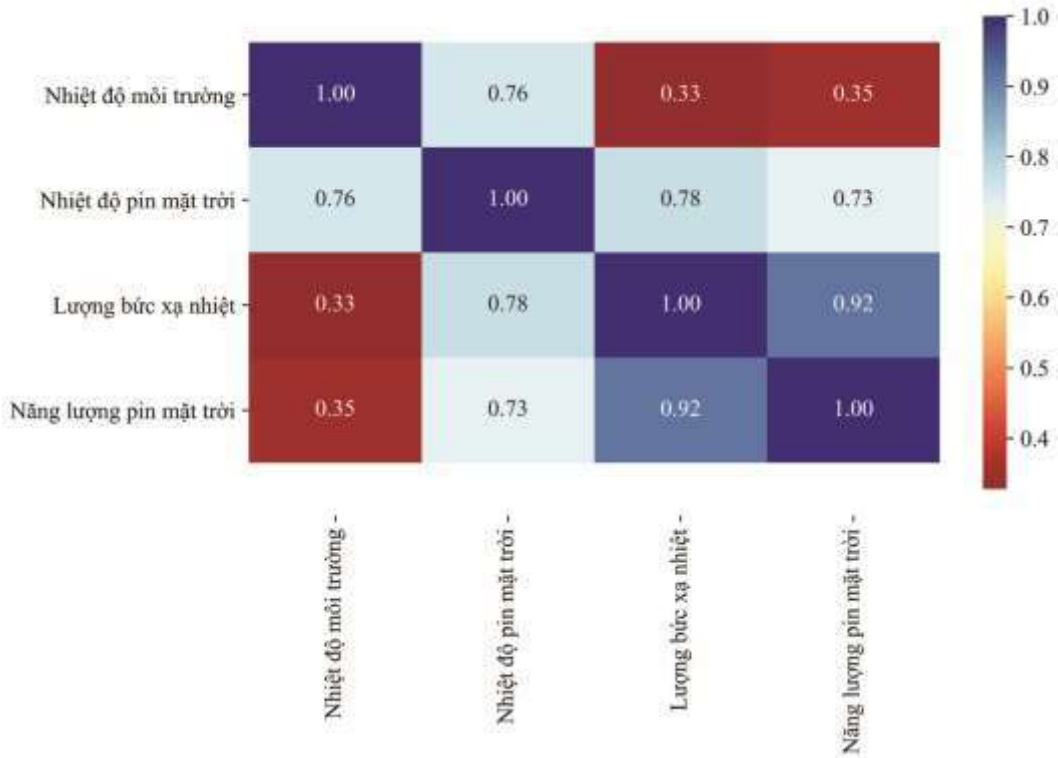
Trong nghiên cứu này, bộ dữ liệu dùng cho việc xây dựng mô hình học máy bao gồm 13206 mẫu năng lượng pin mặt trời phụ thuộc vào 3 biến đầu vào là nhiệt độ môi trường, nhiệt độ pin mặt trời và lượng bức xạ nhiệt đã được thu thập từ thư viện dữ liệu mở Kaggle [6]. Giá trị thống kê của các biến này bao gồm giá trị trung bình, giá trị nhỏ nhất, phân vị 25%, giá trị trung vị, phân vị 75% và giá trị lớn nhất của bộ dữ liệu được mô tả chi tiết trong Bảng 1. Năng lượng pin mặt trời thu được thay đổi từ 582.093 W đến 1420.933 W.

Bảng 1: Giá trị thống kê của các biến bao gồm 3 biến đầu vào và 1 biến đầu ra

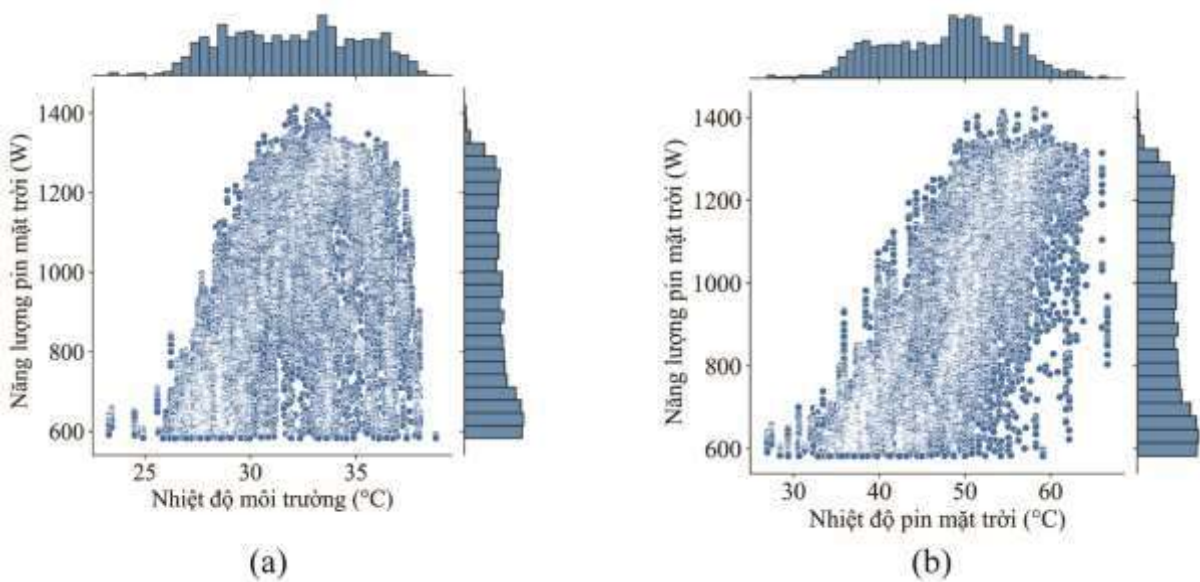
	Nhiệt độ môi trường (°C)	Nhiệt độ pin mặt trời (°C)	Lượng bức xạ nhiệt (W/m ²)	Năng lượng pin mặt trời (W)
Trung bình	32.016	47.833	0.669	914.135
Độ lệch chuẩn	3.115	7.328	0.178	220.111
Min	23.301	26.915	0.317	582.093
Q25%	29.427	42.103	0.509	711.435
Trung vị	32.090	48.680	0.670	896.213
Q75%	34.525	53.147	0.820	1101.208
Max	38.775	66.636	1.099	1420.933

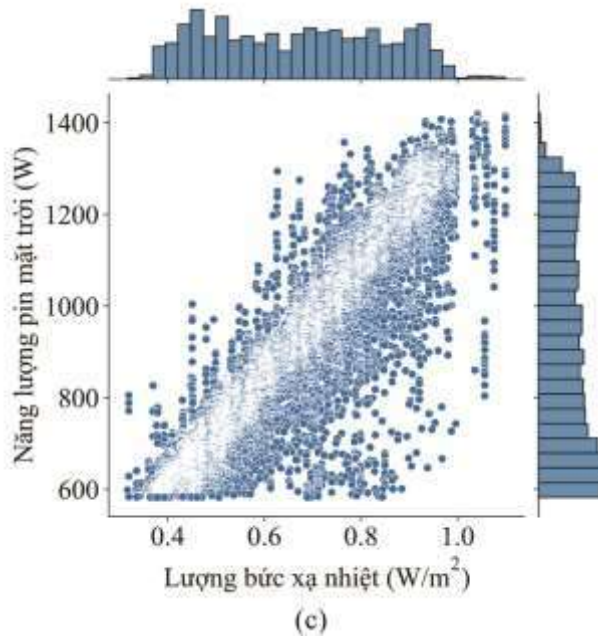
Hình 3 mô tả mối tương quan tuyến tính giữa các biến của bộ dữ liệu được sử dụng. Trong đó có thể thấy với các biến đầu vào, nhiệt độ pin mặt trời có mối tương quan tương đối lớn với nhiệt độ môi trường cũng như lượng

bức xạ nhiệt, điều này có thể dễ hiểu do đây là 2 yếu tố môi trường có ảnh hưởng lớn đến nhiệt độ của pin mặt trời trong quá trình hấp thụ photon từ mặt trời để chuyển hóa thành điện năng.



Hình 3: Ma trận tương quan của các biến của bộ dữ liệu sử dụng





Hình 4: Phân bố số mẫu biến đầu vào với biến đầu ra là năng lượng pin mặt trời
(a) Nhiệt độ môi trường, (b) Nhiệt độ pin mặt trời và (c) Lượng bức xạ nhiệt

Hình 4 mô tả chi tiết sự phân bố miền dữ liệu của các biến đầu vào với biến đầu ra là lượng bức xạ nhiệt. Hình 4 và Hình 3 cho thấy lượng bức xạ nhiệt có ảnh hưởng lớn nhất đến năng lượng pin mặt trời thu được.

3. THUẬT TOÁN HỌC MÁY TĂNG CƯỜNG ĐỘ ĐỐC (GB)

Thuật toán học máy tăng cường độ dốc Gradient Boosting (GB) là một trong số các thuật toán rất mạnh mẽ trong lĩnh vực máy học, được sử dụng rộng rãi cho các vấn đề hồi quy và phân loại [7]. Nó tạo ra một mô hình dự đoán dưới dạng mô hình kết hợp các mô hình dự đoán yếu, điển hình là các cây quyết định (decision tree). Nó xây dựng mô hình theo kiểu từng bước giống như các phương pháp boosting khác, và nó khái quát hóa chúng bằng cách cho phép tối ưu hóa một hàm mất mát (loss function).

Thuật toán Gradient Boosting huấn luyện nhiều mô hình theo cách thêm tham số dần dần, và tuần tự. Ý tưởng chính của boosting là thêm các mô hình mới vào nhóm liên tục. Ở mỗi lần bổ sung như vậy, một mô hình huấn

luyện yếu mới được đào tạo liên quan đến lỗi của toàn bộ đoàn đã học cho đến nay.

Gradient Boosting thực hiện huấn luyện bằng cách sử dụng độ dốc của hàm mất mát ($y = ax + b + e$, e là tham số lỗi). Trong đó, Hàm mất mát là thước đo cho biết các hệ số mô hình phù hợp như thế nào với dữ liệu phân tích. Ví dụ: Nếu chúng ta đang cố gắng dự đoán giá bán bằng cách sử dụng hồi quy, thì hàm mất mát sẽ được dựa trên lỗi giữa giá thực tế và giá dự đoán. Tương tự, nếu mục tiêu của chúng ta là phân loại tín dụng, thì hàm mất mát sẽ là thước đo mức độ dự báo tốt của mô hình dự đoán trong việc phân loại các khoản nợ xấu. Một ví dụ điển hình cho mô hình dự báo Gradient Boosting là việc kết hợp các thuật toán Random Forest [8] với neutra network - mạng lưới thần kinh [9]. Về cơ bản, Gradient boosting liên quan đến ba yếu tố:

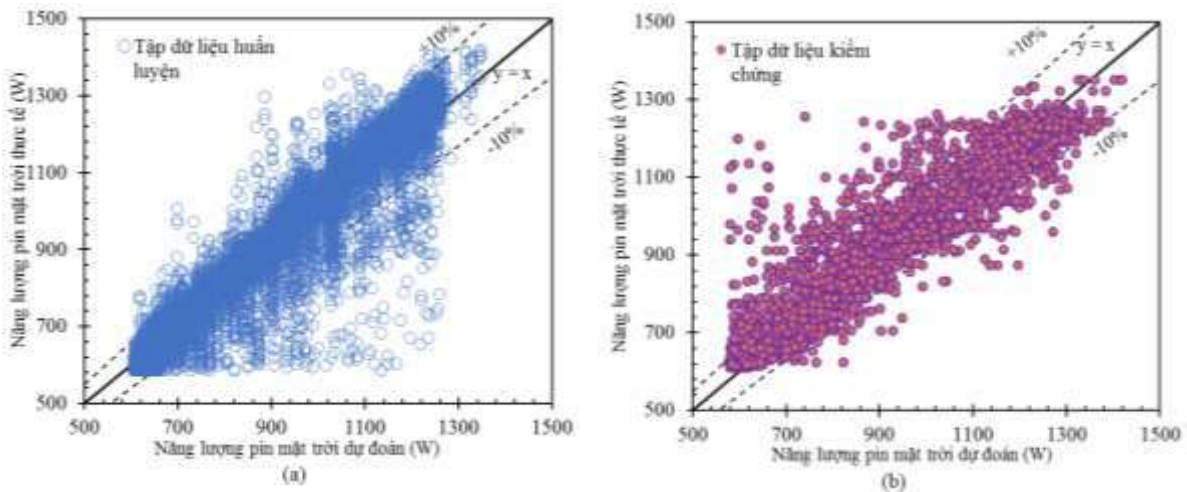
- (1) Một chức năng mất mát được tối ưu hóa.
- (2) Một người học yếu (weak learner) để đưa ra dự đoán.

(3) Mô hình cộng thêm để bổ sung những người học yếu để giảm thiểu hàm mất mát.


Trong nghiên cứu này, thuật toán GB được triển khai trên cơ sở ngôn ngữ lập trình Python, các giá trị của siêu tham số của thuật toán này được định nghĩa trong thư viện mã nguồn mở Sklearn [10]. Ưu điểm của việc sử dụng các giá trị mặc định của thư viện này giúp người sử dụng mô hình học máy trong việc giải quyết các vấn đề hồi quy một cách thuận tiện.

4. KẾT QUẢ DỰ ĐOÁN NĂNG LƯỢNG PIN MẶT TRỜI BẰNG MÔ HÌNH HỌC MÁY

Bộ dữ liệu gồm 13206 mẫu sẽ được chia theo tỷ lệ 70%/30% cho 2 tập tương ứng là tập dữ liệu huấn luyện và tập dữ liệu kiểm chứng. Tập dữ liệu kiểm chứng sẽ giúp thuật toán GB xây dựng mô hình học máy GB dựa trên các giá trị mặc định của siêu tham số có sẵn trong thư viện Sklearn. Tập dữ liệu kiểm chứng giúp xác định độ chính xác của mô hình học máy được xây dựng.



Hình 5: So sánh giá trị năng lượng pin mặt trời trong thực tế đo được với giá trị năng lượng pin mặt trời được dự đoán bởi mô hình học máy GB (a) tập dữ liệu huấn luyện và (b) tập dữ liệu kiểm chứng



Hình 6: Sai số dự đoán giữa giá trị dự đoán bằng mô hình và giá trị năng lượng pin mặt trời thực tế

Hình 5 mô tả sự so sánh giá trị năng lượng pin mặt trời trong thực tế đo được với giá trị năng lượng pin mặt trời được dự đoán bởi mô hình học máy GB (Hình 5a) tập dữ liệu huấn luyện và (Hình 5b) tập dữ liệu kiểm chứng. Kết quả so sánh cho thấy mô hình học máy GB dự báo năng lượng pin mặt trời với độ chính xác cao cho tập dữ liệu huấn luyện gồm 9244 mẫu, Hình 5a cho thấy các điểm so sánh giữa năng lượng pin mặt trời dự đoán và năng lượng pin mặt trời thực tế được phân bố chủ yếu trong miền sai số $\pm 10\%$, với số lượng lớn các điểm nằm trên đường $y=x$. Do vậy, giá trị sai số dự đoán giữa giá trị dự đoán bằng mô hình GB và giá trị năng lượng pin mặt trời thực tế của tập dữ liệu huấn luyện được mô tả trong Hình 6a chủ yếu phân bố trong khoảng ± 200 W, sai số này so với miền giá trị của năng lượng pin mặt trời trong khoảng 582.093 W đến 1420.933 W là tương đối nhỏ có thể chấp nhận được. Để định lượng độ chính xác của mô hình học máy GB đối với tập dữ liệu kiểm chứng trong việc dự đoán năng lượng pin mặt trời, 3 chỉ số hiệu suất đã được sử dụng là hệ số tương quan giữa dự đoán và thực tế $R=0.9338$, sai số căn quân phương $RMSE=78.7251$ W và sai số tuyệt đối $MAE=52.2306$ W.

Sử dụng mô hình học máy GB này cho tập dữ liệu kiểm chứng gồm 3962 mẫu, theo phân tích từ việc so sánh giá trị năng lượng pin mặt trời trong thực tế đo được với giá trị năng lượng pin mặt trời được dự đoán bởi mô hình học máy GB (Hình 5b) và sai số dự đoán giữa giá trị dự đoán bằng mô hình và giá trị năng lượng pin mặt trời thực tế được mô tả trong Hình 6b, kết quả cho thấy rằng mô hình học máy GB có độ chính xác rất cao, khi mà các điểm so sánh phần lớn nằm trong miền sai số $\pm 10\%$, với sai số dự đoán trong khoảng ± 200 W. Hệ số tương quan của giá trị dự đoán và giá trị thực tế về năng lượng pin mặt trời có giá trị cao với $R=0.9398$, các chỉ số đánh giá độ chính xác khác của mô hình gồm sai số

căn quân phương $RMSE$ của toàn tập dữ liệu kiểm chứng cho giá trị dự đoán và giá trị thực tế thấp hơn giá trị $RMSE$ của tập huấn luyện và đạt 75.3522 W. Sai số trung bình tuyệt đối MAE của tập dữ liệu kiểm chứng cũng tương tự thấp hơn so với tập huấn luyện với $MAE=51.0322$ W.

Điều này chứng tỏ mô hình tăng cường độ dốc GB có thể đạt độ chính xác cao trong việc dự đoán năng lượng pin mặt trời sử dụng công nghệ quang điện với 3 biến sử dụng là nhiệt độ môi trường, nhiệt độ pin mặt trời và lượng bức xạ nhiệt.

5. KẾT LUẬN

Nghiên cứu này đã chỉ ra được khả năng ứng dụng của công cụ hiện đại bằng việc kết hợp công cụ học máy và dữ liệu lớn để dự đoán năng lượng pin mặt trời sử dụng công nghệ quang điện. Với việc sử dụng bộ dữ liệu chứa 13206 mẫu gồm 3 biến đầu vào là nhiệt độ môi trường, nhiệt độ pin mặt trời và lượng bức xạ nhiệt và 1 biến đầu ra là năng lượng pin mặt trời vào, mô hình học máy tăng cường độ dốc sử dụng các giá trị tham số mặc định có trong thư viện mã nguồn mở Sklearn viết trên nền tảng ngôn ngữ lập trình Python đã được huấn luyện thành công. Độ chính xác của mô hình học máy tăng cường độ dốc GB đã được thể hiện qua các chỉ số hiệu suất là hệ số tương quan $R=0.9338$, sai số căn quân phương $RMSE=78.7251$ W và sai số tuyệt đối $MAE=52.2306$ W cho tập dữ liệu huấn luyện và hệ số tương quan $R=0.9398$, sai số căn quân phương $RMSE=75.3522$ W và sai số tuyệt đối $MAE=51.0322$ W cho tập dữ liệu kiểm chứng.

Tuy nhiên mặt hạn chế của nghiên cứu là mới chỉ nghiên cứu trên một đối tượng pin mặt trời sử dụng công nghệ quang điện, do vậy tính khái quát của mô hình cần được cải thiện với nhiều loại pin mặt trời sử dụng công nghệ quang điện có các thông số kỹ thuật khác nhau.

TÀI LIỆU THAM KHẢO

- [1] S. Kabir, A. Shufian, and Md. S. R. Zishan, “Isolation Forest Based Anomaly Detection and Fault Localization for Solar PV System,” in *2023 3rd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*, Jan. 2023, pp. 341–345. doi: 10.1109/ICREST57604.2023.10070033.
- [2] “Vietnam is leading the transition to clean energy in South-East Asia,” *The Economist*. Accessed: Apr. 27, 2023. [Online]. Available: https://www.economist.com/asia/2022/06/02/vietnam-is-leading-the-transition-to-clean-energy-in-south-east-asia?utm_medium=cpc.adword.pd&utm_source=google&ppccampaignID=18151738051&ppcadID=&utm_campaign=a.22brand_pmax&utm_content=conversion.direct-response.anonymous&gclid=CjwKCAjwuqiiBhBtEiwATgvixILqxyEwErLLytjeqkFYs1KHuRHKYq0IRj5FJcYXs44Q0Lt3aSiAcxoCvt4QAvD_BwE&gclsrc=aw.ds
- [3] C. Pasion, T. Wagner, C. Koschnick, S. Schuldt, J. Williams, and K. Hallinan, “Machine Learning Modeling of Horizontal Photovoltaics Using Weather and Location Data,” *Energies*, vol. 13, no. 10, p. 2570, May 2020, doi: 10.3390/en13102570.
- [4] J. M. Barrera, A. Reina, A. Maté, and J. C. Trujillo, “Solar Energy Prediction Model Based on Artificial Neural Networks and Open Data,” *Sustainability*, vol. 12, no. 17, Art. no. 17, Jan. 2020, doi: 10.3390/su12176915.
- [5] A. Ortiz *et al.*, “An Artificial Intelligence Dataset for Solar Energy Locations in India,” *Sci Data*, vol. 9, no. 1, Art. no. 1, Aug. 2022, doi: 10.1038/s41597-022-01499-9.
- [6] “Solar power generation forecast with 99% AUC.” <https://kaggle.com/code/pythonafroz/solar-power-generation-forecast-with-99-auc> (accessed Sep. 17, 2023).
- [7] J. Friedman, “Stochastic gradient boosting,” 2002, doi: 10.1016/S0167-9473(01)00065-2.
- [8] L. Breiman, “Random Forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [9] L. K. Hansen and P. Salamon, “Neural network ensembles,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 10, pp. 993–1001, Oct. 1990, doi: 10.1109/34.58871.
- [10] F. Pedregosa *et al.*, “Scikit-learn: Machine Learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.