

DETECT PV CELL DEFECTION BASED ON ELECTROLUMINESCENCE LIGHT USING DEEP LEARNING

Nguyen Quoc Minh*, Le Thi Minh Chau, Nguyen Dang Tien, Le Minh Hieu

Hanoi University of Science & Technology

ARTICLE INFO		ABSTRACT
Received:	17/5/2021	PV cell surface defects inspection is essential to maintain safety, reliability and optimal efficiency of the solar plant. Cell surface deflection is the most popular type of fault and it can be hardly detected by normal visual inspection. Defected cells without detection and maintainane can affect the performance of other normal cells since they are connected in series and parallel in large number. In this research, we present a method to automatically detect PV cell surface deflection using image processing technique by deep learning model. The input data include 2146 high resolution electroluminescence images of mono and poly PV cells. This type of image is usually captured by drones. The images are then fed into convolutional neural network (CNN) for feature extraction and support vector machine (SVM) for image classification. The results show that the proposed deep learning model can classify the normal and surface defect cells with the accuracy of 91.63%.
Revised:	15/7/2021	
Published:	21/7/2021	
KEYWORDS		
PV cell		
Electroluminescence light		
Convolutional neural network		
Support vector machine		
Deep learning		

NHẬN DẠNG TẮM PIN MẶT TRỜI BỊ LỖI DỰA TRÊN HÌNH ẢNH ĐIỆN PHÁT QUANG BẰNG DEEP LEARNING

Nguyễn Quốc Minh*, Lê Thị Minh Châu, Nguyễn Đăng Tiến, Lê Minh Hiếu

Trường Đại học Bách Khoa Hà Nội


THÔNG TIN BÀI BÁO		TÓM TẮT
Ngày nhận bài:	17/5/2021	Việc xác định tấm pin mặt trời bị hỏng có vai trò rất quan trọng trong việc đảm bảo vận hành an toàn, tin cậy và hiệu suất tối đa của các nhà máy điện mặt trời. Trong nghiên cứu này, chúng tôi đề xuất sử dụng mô hình deep learning để tự động hoá việc phân loại tấm pin mặt trời bị lỗi. Mô hình này bao gồm mạng nơron tích chập được dùng để trích xuất đặc trưng và thuật toán máy học véc tơ hỗ trợ để nhận dạng. Mô hình được huấn luyện và kiểm tra trên tập dữ liệu bao gồm 2.146 hình ảnh điện phát quang có độ phân giải cao của các tấm pin mặt trời loại mono và loại poly. Kết quả phân loại cho thấy mô hình đề xuất có thể phân loại được tấm pin mặt trời bị hỏng với độ chính xác đạt được là 91,63%.
Ngày hoàn thiện:	15/7/2021	
Ngày đăng:	21/7/2021	
TỪ KHÓA		
Pin mặt trời		
Hình ảnh điện phát quang		
Mạng nơron tích chập		
Véc tơ hỗ trợ máy học		
Deep learning		

DOI: <https://doi.org/10.34238/tnu-jst.4511>

* Corresponding author. Email: minh.nguyenquoc@hust.edu.vn

1. Giới thiệu

Sử dụng các nguồn năng lượng mới và tái tạo như điện gió, điện mặt trời, điện sinh khối để thay thế cho các dạng năng lượng hóa thạch đang là xu hướng tất yếu trên thế giới. Việc tiếp cận các nguồn năng lượng mới này không chỉ có tác dụng trong việc đảm bảo an ninh năng lượng quốc gia, mà còn giúp tiết kiệm điện năng và giảm thiểu ô nhiễm môi trường. Việc phát triển các nguồn năng lượng tái tạo, đặc biệt là điện gió và điện mặt trời đang là chính sách được ưu tiên của chính phủ Việt Nam. Với vị trí địa lý nằm trong khu vực phân bố bức xạ mặt trời lớn, số giờ nắng nhiều, Việt Nam được đánh giá là quốc gia có tiềm năng rất lớn về điện mặt trời. Do cơ chế giá FIT của chính phủ (được thể hiện trong quy định 11 và 13 của Thủ tướng về việc khuyến khích phát triển dự án điện mặt trời), cũng như giá công nghệ của điện mặt trời giảm mạnh trong 10 năm gần đây. Tính riêng trong 3 năm 2018 đến 2020, công suất đặt của các nhà máy điện mặt trời mới đã tăng lên từ 0 đến 10GW [1]. Hình 1 thể hiện tổng công suất đặt của các nhà máy điện mặt trời hòa lưới, tính riêng trong 26 tuần đầu tiên của năm 2019.



Hình 1. Tổng công suất đặt của các nhà máy điện mặt trời hòa lưới trong 26 tuần đầu năm 2019
(Source: EVN-NLDC)


Các nhà máy điện mặt trời được đưa vào gần đây đã phần nào làm giảm áp lực nguồn điện, đặc biệt vào các thời điểm nắng nóng, phụ tải đạt cực đại. Trong quá trình vận hành, các nhà máy điện mặt trời có thể xảy ra các dạng hư hỏng, sự cố như sự cố ở phía DC, tia lửa điện hư hỏng bộ biến tần, nứt vỡ, hư hỏng bề mặt các tấm pin mặt trời v.v... Trong các dạng sự cố này thì sự cố hư hỏng bề mặt các tấm pin mặt trời chiếm tỉ trọng lớn. Nguyên nhân dẫn đến tình trạng này thường do tấm pin bị lỗi sản xuất, hết tuổi thọ, bị vật thể lạ rơi vào, sét đánh, hoặc do điều kiện thời tiết khí hậu khắc nghiệt dẫn đến tình trạng nứt, vỡ pin. Khi một hay nhiều tấm pin bị nứt, vỡ bề mặt không những công suất phát bị suy giảm, đặc tính làm việc bị thay đổi mà còn ảnh hưởng dây chuyền đến các tấm pin bên cạnh do các tấm pin thường được mắc nối tiếp và song song với nhau với số lượng lớn [2]. Hình 2 là dự án điện mặt trời Dầu Tiếng tại khu vực Tây Ninh. Đây là một nhà máy điện mặt trời lớn, với tổng công suất lắp đặt là 420MW trên diện tích 504 ha, với hơn 1,3 triệu tấm pin mặt trời, sản lượng điện hòa lưới quốc gia hàng năm đạt khoảng 688 triệu kWh. Các tấm pin năng lượng mặt trời thường được bảo vệ bởi khung nhôm và tấm kính bề mặt để tránh khỏi các tác động của môi trường. Tuy nhiên, các biện pháp bảo vệ này không phải lúc nào cũng có thể ngăn ngừa được các hư hỏng do cơ học như tác động từ mưa đá, các cành cây rơi, rơi khi lắp đặt, thậm chí có những vết nứt nhỏ không nhìn thấy được, hoặc các khuyết tật khi sản xuất dẫn tới các tấm pin mặt trời bị hỏng. Điều này làm giảm hiệu suất năng lượng được chuyển hoá thành điện năng của các mô-đun năng lượng mặt trời. Do đó, việc cần phải theo dõi tình trạng của các mô-đun năng lượng mặt trời và thay thế hoặc sửa chữa các đơn vị tấm pin mặt trời bị lỗi là cần thiết để đảm bảo hiệu suất tối đa cho các nhà máy điện mặt trời.



Hình 2. Nhà máy điện mặt trời Dầu Tiếng tại Tây Ninh (Source: Vũ Phong Solar)

Việc xác định và phân loại các tấm pin mặt trời bị lỗi là khó khăn, thách thức lớn ngay cả với các chuyên gia được đào tạo cũng khó có thể phát hiện ra những vết nứt hỏng, bởi một số khuyết tật này không thể nhìn thấy được bằng mắt thường. Ngược lại, một số khuyết tật khác có thể nhìn thấy bằng mắt thường nhưng lại không hề làm giảm hiệu quả của mô-đun. Hình ảnh điện phát quang (Electroluminescence - EL) là một phương thức hữu ích để kiểm tra tình trạng các tấm pin mặt trời [3]. EL cung cấp hình ảnh có độ phân giải cao có thể giúp phát hiện các vết nứt, khuyết tật trên bề mặt của các tấm pin. Tuy nhiên, việc phân tích thủ công sẽ tiêu tốn rất nhiều thời gian, tiền bạc, công sức và còn đòi hỏi kiến thức chuyên môn về các loại khuyết tật khác nhau.


Ngày nay, với sự phát triển của trí tuệ nhân tạo nói chung và máy học nói riêng, việc nhận dạng và phân loại hình ảnh trở nên ngày càng chính xác, thậm chí một số tác vụ có thể vượt qua con người. Việc ứng dụng máy học vào việc phân loại tấm pin mặt trời cũng được quan tâm và nghiên cứu [4]-[9]. Ưu điểm vượt trội của máy học là không cần hiểu quá nhiều về các loại khuyết tật, các đặc trưng này sẽ được trích xuất tự động trong quá trình huấn luyện. Trong nghiên cứu này, chúng tôi đề xuất mô hình máy học kết hợp giữa mạng nơ-ron tích chập (Convolutional Neural Network - CNN) với véc-tơ hỗ trợ (Support Vector Machine - SVM) để phân loại tấm pin mặt trời hỏng. Hình 3 là các bức ảnh tấm pin mặt trời dạng thường, dạng hồng ngoại và dạng hình ảnh điện phát quang. Trong các dạng ảnh này thì dạng hình ảnh điện phát quang (Hình 3.c) sẽ được sử dụng trong nghiên cứu để phát hiện các tấm pin mặt trời bị lỗi bề mặt.




Hình 3. Hình ảnh tấm pin mặt trời: (a) ảnh chụp bình thường; (b) ảnh hồng ngoại; (c) hình ảnh điện phát quang (Source: Phòng Lab Diagnostic Imaging, Đại học Aalborg, Đan Mạch)

2. Mô hình nhận dạng tấm pin bị lỗi dựa trên deep learning


Mô hình nhận dạng tấm pin bị lỗi được thể hiện ở hình 4. Trong mô hình này, dữ liệu ảnh chụp tấm pin bị lỗi được đưa vào khối EfficientNet B0. Khối này thực chất là một mạng nơ-ron tích chập (Convolutional Neural Network) nhằm trích xuất các đặc trưng của bức ảnh đầu vào. Mạng nơ-ron tích chập là một kiến trúc mạng mô phỏng hệ thần kinh của con người. Đây là một mô hình deep learning được sử dụng rất phổ biến trong các bài toán nhận dạng ảnh. Kiến trúc mạng nơ-ron tích chập được thể hiện ở Hình 5. Kiến trúc này bao gồm lớp dữ liệu đầu vào, lớp dữ liệu đầu ra và nhiều lớp ẩn, các lớp ẩn có thể là lớp tích chập (convolution), hoặc lớp gộp (pooling).



Hình 4. Mô hình nhận dạng tấm pin bị lỗi dựa trên deep learning



Hình 5. Kiến trúc mạng nơ-ron tích chập



Hình 6. Hàm kích hoạt phổ biến trong mạng nơ-ron tích chập: (a) hàm sigmoid; (b) hàm ReLU

(Source: [9])


Mỗi lớp tích chập sẽ được sử dụng các bộ lọc khác nhau, số lượng thường đến hàng trăm, hàng nghìn bộ lọc, sau đó sẽ kết hợp kết quả của chúng lại với nhau. Lớp tích chập này sẽ được đi qua một hàm kích hoạt để tạo ra các thông tin trừu tượng hơn cho các lớp tiếp theo. Hàm kích hoạt được áp dụng vào giá trị của một nơ-ron để cho ra giá trị của một nơ-ron liên kết với nơ-ron ban đầu. Các hàm này là các hàm phi tuyến, thể hiện cho mối quan hệ phức tạp của dữ liệu.

Hình 6 thể hiện 2 hàm kích hoạt được sử dụng phổ biến trong mạng nơ-ron tích chập: hàm sigmoid (Eq.1) và hàm ReLU (Eq.2).

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (1)$$

$$R(x) = \max(0, x) \quad (2)$$

Hàm sigmoid là hàm kích hoạt được sử dụng rất phổ biến trong các mô hình deep learning. Đây là một hàm phi tuyến với giá trị đầu vào là số thực và giá trị đầu ra là một số nằm trong khoảng (0,1). Chính vì vậy, hàm này thường được xem là xác suất cho một vài bài toán nhận dạng. Tuy nhiên, nhược điểm của hàm sigmoid là đạo hàm gần như bằng không tại các giá trị đầu vào có biên độ lớn, do đó ảnh hưởng đến tốc độ hội tụ của thuật toán. Để khắc phục nhược điểm đạo hàm bị triệt tiêu thì những năm gần đây người ta thường sử dụng hàm kích hoạt ReLU (Rectified Linear Unit). Hàm này có tốc độ tính toán nhanh hơn hàm sigmoid do có biểu thức toán học đơn giản và tránh được vấn đề đạo hàm bị triệt tiêu khi giá trị đầu vào lớn.



Hình 7. Mô hình máy vectơ hỗ trợ trên không gian hai chiều (a) và ba chiều (b)


Bên cạnh các lớp tích chập, mạng nơ-ron tích chập còn sử dụng một vài lớp khác như các loại lớp gộp dùng để chắt lọc lại các thông tin hữu ích. Trong quá trình huấn luyện, mạng nơ-ron sẽ tự động học qua các lớp tích chập để trích xuất đặc trưng. Lớp cuối cùng sẽ được dùng để phân loại. Trong nghiên cứu này, mạng nơ-ron tích chập được sử dụng trong mô hình nhận dạng pin mặt trời bị lỗi là kiến trúc mô hình EfficientNet-B0 [7]. Kiến trúc này đã được huấn luyện trên bộ dữ liệu Imagenet với hơn 1,3 triệu bức ảnh cho 1000 lớp hình ảnh khác nhau. Trong kiến trúc này, chúng tôi loại bỏ các lớp phân nhóm hình ảnh ở cuối kiến trúc mô hình, giữ lại trọng số tại các lớp tích chập để từ đó sử dụng mạng nơ-ron tích chập như một phương pháp trích xuất đặc trưng.

Sau khi các bức ảnh được đưa qua mạng nơ-ron tích chập để trích xuất đặc trưng thì sẽ được đưa vào mô hình máy học vectơ hỗ trợ (Support Vector Machine). SVM là một thuật toán máy học rất mạnh trong các bài toán phân loại dữ liệu thành các nhóm riêng biệt (hình 7). Trong thuật toán này, dữ liệu được ánh xạ vào không gian nhiều chiều hơn để từ đó tìm ra siêu mặt phẳng để phân chia các nhóm cần phân loại. Sau khi sử dụng thuật toán tìm kiếm các tham số tối ưu cho SVM chúng tôi thu được tham số điều chuẩn C là 100, hàm nhân của thuật toán là radial basis function có hệ số nhân gamma là 0,001.

3. Kết quả và bàn luận

Mô hình được huấn luyện và kiểm thử trên bộ dữ liệu bao gồm 2146 bức ảnh điện phát quang của

các tấm pin mặt trời loại mono và poly có độ phân giải cao được đưa về kích thước 300 x 300, được trích xuất từ 44 mô-đun năng lượng mặt trời [8], cụ thể hình ảnh các loại tấm pin mặt trời được mô tả tại Hình 8.



Hình 8. Hình ảnh điện phát quang. a) pin mặt trời loại mono bị hỏng; b) pin mặt trời loại mono bình thường; c) pin mặt trời loại poly bị hỏng; d) pin mặt trời loại poly bình thường

Trong tập dữ liệu bao gồm 717 bức ảnh tấm pin mặt trời bị hỏng và 1429 bức ảnh tấm pin mặt trời bình thường. Tập dữ liệu được chia thành 2 phần là tập huấn luyện và tập kiểm thử với tỉ lệ 80-20. Để kiểm tra kết quả phân loại của mô hình, chúng tôi sử dụng các chỉ số Accuracy, Recall, Precision và F1-score để đánh giá các dự đoán của mô hình với các nhãn thật được gán sẵn trên tập dữ liệu kiểm thử. Các chỉ số đó được thể hiện qua công thức dưới đây:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} = \frac{2TP}{2TP + FP + FN} \quad (6)$$

Trong đó:

TP (True Positive): Số dự đoán dương tính thật.

TN (True Negative): Số dự đoán âm tính thật.

FP (False Positive): Số dự đoán dương tính giả.

FN (False Negative): Số dự đoán âm tính giả

Bảng 1. Kết quả của mô hình trên tập kiểm thử

Chỉ số	%
Accuracy	91,63
Recall	80,71
Precision	92,62
F1-score	86,26

Dữ liệu trên tập kiểm thử được cách ly khỏi tập huấn luyện, sau đó được đưa vào mô hình để phân loại, kết quả được mô tả ở Bảng 1. Dữ liệu có sự mất cân bằng ở 2 nhóm tấm pin mặt trời bị hỏng và tấm pin mặt trời bình thường với tỉ lệ lần lượt là 33,41% và 66,59%. Vì thế, bên cạnh độ chính xác Accuracy đạt được 91,63%, được hiểu là tỉ lệ dự đoán đúng là hỏng trên tổng số dự đoán, chúng tôi sử dụng thêm chỉ số F1-score. Dựa trên các chỉ số Accuracy, Precision và F1-score có thể cho thấy mô hình máy học có tỉ lệ tìm thấy tấm pin mặt trời bị hỏng trong tổng số các tấm pin thực sự hỏng là 86,26%, trong khi tỉ lệ phân loại đúng tấm pin mặt trời bị hỏng trong tổng số các tấm pin được phân loại bị hỏng là 92,62%. Các mô hình mạng nơron và mô hình

thuật toán SVM được xây dựng trên ngôn ngữ Python. Với các mô hình đã được xây dựng thì thời gian huấn luyện mạng nơ-ron là 110 giây, thời gian thuật toán SVM đưa ra kết quả nhận dạng là 2,1 giây. Như vậy, tổng thời gian của mô hình là 112,1 giây.

Bảng 2 thể hiện kết quả so sánh giữa mô hình chỉ dùng mạng nơ-ron (VGG16) và mô hình kết hợp mạng nơ-ron và SVM (Efficientnet-B0 + SVM). Kết quả cho thấy việc sử dụng mạng nơ-ron để trích xuất đặc trưng kết hợp với SVM để phân loại không những cải thiện được các chỉ số về độ chính xác mà còn giảm thiểu đáng kể thời gian huấn luyện mô hình từ 564,6 giây xuống còn 112,1 giây.

Bảng 2. Kết quả so sánh giữa mô hình chỉ dùng mạng nơ-ron (VGG16) và mô hình kết hợp mạng nơ-ron và SVM (Efficientnet-B0 + SVM)

Mô hình	Accuracy(%)	Precision(%)	Recall(%)	F1_Score(%)	Thời gian huấn luyện(s)
VGG16	91,16	92,40	80,22	85,40	564,6
Efficientnet-B0 + SVM	91,63	92,62	80,71	86,26	112,1

4. Kết luận

Nghiên cứu này đề xuất một cách tiếp cận để phân loại tự động tấm pin mặt trời bị hỏng từ hình ảnh điện phát quang dựa trên mô hình mạng nơ-ron tích chập, kết hợp với thuật toán máy học vectơ hỗ trợ. Mạng nơ-ron tích chập đóng vai trò trích xuất các đặc trưng từ hình ảnh điện phát quang của tấm pin mặt trời, còn thuật toán máy học vectơ hỗ trợ đóng vai trò phân loại tấm pin bị hỏng từ các đặc trưng trích xuất được. Từ kết quả nghiên cứu đã chỉ ra rằng mô hình này cho kết quả nhận dạng tấm pin hỏng với độ chính xác đạt được 91,63%. Trong tương lai, nhóm nghiên cứu sẽ tập trung vào các thuật toán mạnh hơn để cải thiện độ chính xác.

TÀI LIỆU THAM KHẢO/ REFERENCES

- [1] Q. K. Nguyen, *Annual Report on Electric Power Generation Development Scenerios in Vietnam*, Green Innovation and Delelopment Centre of Vietnam, 2019.
- [2] M. Köntges, S. Kurtz, C. Packard, U. Jahn, K. Berger, K. Kato, T. Friesen, H. Liu, and M. Iseghem, "Review of Failures of Photovoltaic Modules," *IEA-PVPS Report, International Energy Agency*, Paris, France, 2014.
- [3] J. S. Fada, M. A. Hossain, J. L. Braid, S. Yang, T. J. Peshek, and R. H. French, "Electroluminescent Image Processing and Cell Degradation Type Classification via Computer Vision and Statistical Learning Methodologies," *2017 IEEE 44th Photovoltaic Specialist Conference (PVSC)*, Washington, DC, USA, 2017, pp. 3456-3461.
- [4] A. Bartler, L. Mauch, B. Yang, M. Reuter, and L. Stoicescu, "Automated Detection of Solar Cell Defects with Deep Learning," *2018 26th European Signal Processing Conference (EUSIPCO)*, Rome, Italy, 2018, pp. 2035-2039.
- [5] S. Deitsch et al., "Automatic classification of defective photovoltaic module cells in electroluminescence images," *Solar Energy*, vol. 185, pp. 455-468, 2019.
- [6] V. S. B. Kurukuru, A. Haque, M. A. Khan, and A. K. Tripathy, "Fault classification for Photovoltaic Modules Using Thermography and Machine Learning Techniques," *International Conference on Computer and Information Sciences (ICCIS)*, Saudi Arabia, 2019, pp. 1-6.
- [7] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *International Conference on Machine Learning*, 2019.
- [8] S. Deitsch, Buerhop-Lutz, and C., Sovetkin, "Segmentation of photovoltaic module cells in uncalibrated electroluminescence images," *Machine Vision and Applications*, vol. 84, pp. 1-23, 2021.
- [9] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, 2nd edition, O'Reilly Media, ISBN: 9781492032649, 2019.