

Phát hiện hư hỏng cách điện chuỗi sứ trên đường dây truyền tải dựa trên thị giác máy tính

Nguyễn Quốc Minh^{1*}, Nguyễn Thị Quỳnh²

¹Trường Điện - Điện tử, Đại học Bách Khoa Hà Nội;

²Khoa Công nghệ thông tin, Trường Đại học Công nghiệp Hà Nội.

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

Nhận bài: 28/6/2023; Hoàn thiện: 31/7/2023; Chấp nhận đăng: 10/10/2023; Xuất bản: 25/10/2023.

DOI: <https://doi.org/10.54939/1859-1043.j.mst.90.2023.30-37>

TÓM TẮT

Việc phát hiện nhanh và chính xác các chuỗi sứ cách điện bị hư hỏng đóng một vai trò quan trọng trong việc đảm bảo sự làm việc ổn định và tin cậy của lưới điện truyền tải. Trong nghiên cứu này, nhóm tác giả đề xuất phương pháp phát hiện và phân loại hư hỏng cách điện trên chuỗi sứ đường dây truyền tải điện dựa trên các mô hình thị giác máy tính. Bộ dữ liệu được sử dụng trong nghiên cứu bao gồm 1600 bức ảnh các chuỗi sứ cách điện với 18195 đối tượng được chia thành 03 loại: chuỗi sứ hoạt động bình thường, chuỗi sứ bị nứt vỡ và chuỗi sứ bị hư hỏng do sét đánh, và được chia thành 02 tập huấn luyện và tập kiểm thử với tỉ lệ 80-20. Bộ dữ liệu được huấn luyện trên 02 mô hình thị giác máy tính là YOLOv8 và Faster R-CNN. Kết quả cho thấy, mô hình YOLOv8 có thể phát hiện và phân loại được chuỗi sứ bị hư hỏng do nứt vỡ và sét đánh với độ chính xác lên đến 96.4%.


Từ khóa: Chuỗi sứ cách điện; Đường dây truyền tải; Thị giác máy tính; Faster R-CNN; YOLOv8.

1. MỞ ĐẦU

Hệ thống điện (HTĐ) Việt Nam là hệ thống điện có quy mô lớn nhất trong khu vực Đông Nam Á, và đang trong quá trình phát triển mạnh mẽ trong những năm gần đây. Theo Quy hoạch điện VIII mới được phê duyệt, tổng công suất đặt của HTĐ vào năm 2030 sẽ đạt 150 GW, gấp đôi so với hiện tại. Cùng với sự phát triển của nguồn điện thì hệ thống truyền tải cũng tăng trưởng mạnh mẽ. Trong giai đoạn 2021-2030 sẽ xây dựng mới gần 50 GW trạm biến áp 500 kV và hơn 12 nghìn km đường dây 500 kV. Các đường dây truyền tải trên không sử dụng sứ đỡ cách điện và cố định đường dây về mặt cơ khí. Sứ cách điện đường dây thường được làm bằng thủy tinh hoặc gốm sứ, treo trên đầu cột nối của đường dây. Theo thời gian, sứ cách điện đường dây tải điện trên không trong quá trình làm việc có thể gặp các khuyết tật như hư hỏng, phóng điện bề mặt do ô nhiễm, rò rỉ điện, tự phát nổ [1]. Trong các dạng hư hỏng này, hư hỏng do nứt vỡ sứ cách điện (hình 1) và khuyết tật bề mặt chuỗi sứ do sét đánh (hình 2) là hai dạng hư hỏng phổ biến. Nguyên nhân gây ra hư hỏng sứ cách điện có thể kể đến như sét đánh, tác động của điều kiện thời tiết, mưa đá, nhiệt độ cao do nắng nóng, ăn mòn, do vật thể lạ rơi vào [2]. Chuỗi sứ bị hư hỏng cách điện nếu không được phát hiện chính xác và kịp thời có thể làm suy giảm mức cách điện của đường dây, thông thường sẽ dẫn đến sự cố phóng điện, ngắn mạch và đường dây sẽ bị cắt điện, gây mất điện diện rộng, trong một số trường hợp nghiêm trọng có thể dẫn tới mất ổn định và tan rã hệ thống. Vì vậy, việc phát hiện và phân loại chính xác sứ cách điện bị hư hỏng đóng vai trò quan trọng trong công tác bảo trì, bảo dưỡng, nhằm nâng cao tuổi thọ, độ tin cậy của thiết bị, cũng như ổn định của hệ thống điện [3]. Việc kiểm tra tình trạng làm việc và phát hiện hư hỏng chuỗi sứ cách điện trên các đường dây trên không vẫn chủ yếu dựa vào phương pháp thủ công, kiểm tra bằng mắt thường. Đây là phương pháp tốn kém về chi phí, nhân lực, và độ chính xác không cao.

Việc sử dụng các loại máy bay không người lái (UAV) để thu thập dữ liệu ảnh các chuỗi sứ đã được sử dụng ngày càng phổ biến [4]. Phương pháp chẩn đoán tình trạng chuỗi sứ thông qua ảnh chụp từ UAV có ưu điểm là tiết kiệm thời gian thu thập ảnh so với phương pháp thủ công,

giảm thiểu chi phí, tuy nhiên, lượng dữ liệu rất lớn, đòi hỏi thời gian xử lý lâu. Bên cạnh đó, ảnh chụp từ UAV thường sẽ lẫn cảnh vật xung quanh như nhà cửa, cây cối,... trong khi chi tiết hồng học của chuỗi sứ lại khá nhỏ, dẫn đến sai sót trong việc nhận dạng, phát hiện sớm các hư hỏng. Gần đây, sự phát triển của trí tuệ nhân tạo trong lĩnh vực xử lý hình ảnh, video, hay còn gọi là thị giác máy tính (computer vision) đã đem lại nhiều ứng dụng trong cuộc sống. Thị giác máy tính là một ngành khoa học liên quan đến thu nhận dữ liệu số dạng hình ảnh, video, từ đó phân tích, nhận dạng, trích xuất thông tin từ hình ảnh. Trong những năm gần đây, đã có rất nhiều ứng dụng của thị giác máy tính cho việc phát hiện lỗi trong cách điện đường dây. Vào năm 2022, Zheng, J. [16] đã nghiên cứu để cải tiến mô hình YOLOv7 bằng cách thêm một số module nhằm mục đích nâng cao các đặc trưng hiệu quả, do đó, việc phát hiện lỗi ở chuỗi sứ cách điện đã được cải thiện về độ chính xác. Cho đến đầu năm 2023, Lian, X. [17] đã cải tiến mô hình YOLOv5 bằng cách bổ sung thêm vào phần backbone để cải thiện khả năng trích xuất đặc trưng, ngoài ra còn thay thế cấu trúc PANet thành BiFPN để tận dụng tối đa các đặc trưng tốt nhất. Bên cạnh đó, mạng VGGNet16 trong Faster R-CNN cũng được thay thế bằng ResNet50 để tăng độ chính xác cho nhận diện lỗi bởi một nhóm tác giả vào năm 2022 [18]. Các ứng dụng nổi bật của thị giác máy tính có thể kể đến như xe tự lái [5, 6], chẩn đoán hình ảnh X quang [7, 8], phát hiện sản phẩm lỗi trong dây chuyền sản xuất [9, 10]. Ưu điểm của thị giác máy tính là có thể xử lý lượng dữ liệu lớn, trích xuất các thông tin từ hình ảnh một cách tự động, nhanh chóng với độ chính xác cao so với các phương pháp thủ công. Trong nghiên cứu này, tác giả đề xuất sử dụng hai mô hình thị giác máy tính mới được phát triển gần đây, là mô hình YOLOv8 và Faster R-CNN để phát hiện và phân loại hư hỏng chuỗi sứ cách điện trên đường dây truyền tải điện.



Hình 1. Chuỗi sứ cách điện bị vỡ.



Hình 2. Chuỗi sứ cách điện bị sét đánh.

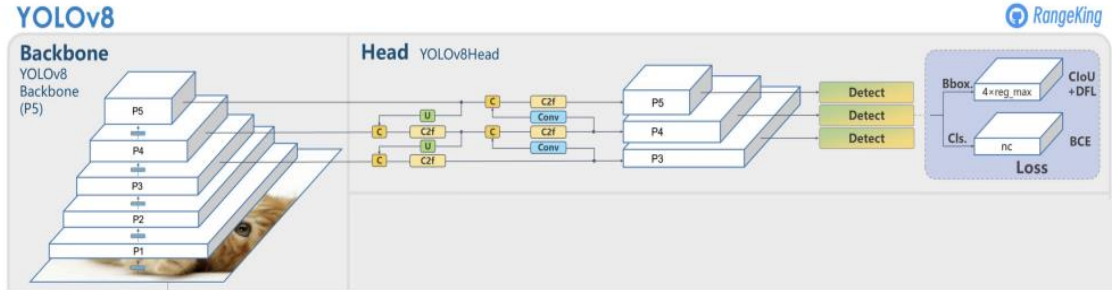
2. CÁC MÔ HÌNH THỊ GIÁC MÁY TÍNH

2.1. YOLOv8

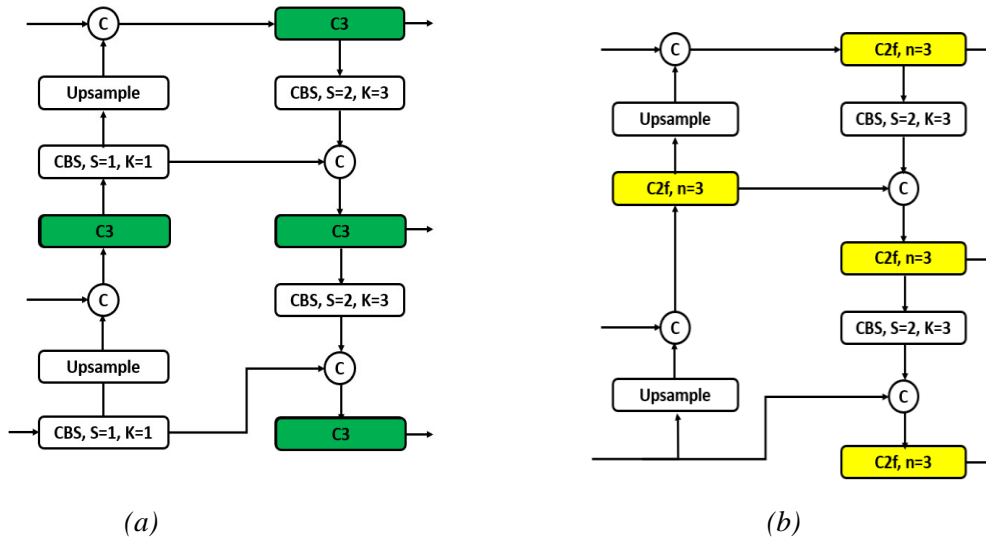
YOLO (You Only Look Once) là một mô hình thị giác máy tính được sử dụng phổ biến trong bài toán nhận dạng hình ảnh. Đây là mô hình có tốc độ tính toán rất nhanh với độ chính xác cao. YOLO được giới thiệu lần đầu bởi Joshep Redmon vào năm 2016. Trải qua nhiều phiên bản cải tiến, YOLOv8 ra mắt vào năm 2022 là phiên bản mới nhất, với sự cải thiện vượt trội về cả độ chính xác lẫn tốc độ xử lý. Tổng quan kiến trúc của mô hình YOLOv8 dùng để phát hiện lỗi trên sứ cách điện được thể hiện ở hình 3, YOLOv8 gồm 3 phần chính đó là Backbone, Neck và Head.

Về phần Backbone, YOLOv8 sử dụng kiến trúc mới đó là sự kết hợp của Feature Pyramid Network (FPN) và Path Aggregation Network (PAN) [13]. FPN được tạo ra để thay thế các bộ lọc đặc trưng được sử dụng như trong Faster R-CNN và tạo ra các bản đồ đặc trưng với chất lượng thông tin tốt hơn bộ lọc đặc trưng thông thường. Mạng nơ ron càng sâu thì càng làm mất

mất thông tin, do đó, để phát hiện được các đối tượng có kích thước nhỏ, các nghiên cứu đã đề xuất nhiều phương pháp như DenseBlock, FPN. Trong đó, PAN là một cải tiến của FPN nhằm cải thiện việc kết hợp thông tin đa tầng trong mô hình phát hiện đối tượng trong thị giác máy tính. YOLOv8 sử dụng Backbone tương tự YOLOv5 với một vài sự thay đổi của CSPLayer, gọi là C2f module [12] (hình 4). Việc thay đổi C3 module thành C2f module nhằm mục đích tăng tốc độ xử lý và cải thiện độ chính xác của YOLOv8 so với YOLOv5, ngoài ra lớp convolutional 6x6 đầu tiên trong backbone được thay bằng convolutional 3x3.



Hình 3. Yolov8 Architecture [13].



Hình 4. (a) Cấu trúc YOLOv5 backbone và (b) YOLOv8 backbone.

Về phần Head, YOLOv8 sử dụng Decoupled-Head để tăng độ chính xác của mô hình. Khi huấn luyện, mô hình sẽ cập nhật hàm lỗi ở mỗi lần huấn luyện cho đến khi hàm lỗi đạt giá trị nhỏ nhất. Hàm lỗi của YOLOv8 bao gồm 3 thành phần: CIOU Loss được sử dụng để đánh giá độ chính xác của bounding box (hộp giới hạn), Distribution Focal Loss (DFL) được dùng cho nhiệm vụ dự đoán các thông số của bounding box bao gồm tọa độ, kích thước và Binary Cross-Entropy Loss được dùng cho nhiệm vụ dự đoán nhãn của đối tượng. Hàm lỗi của YOLOv8 được tính như sau:

$$L_{total} = L_{CIOU} + \alpha L_{DFL} + \beta L_{BCE} \quad (1)$$

Trong đó, α và β là hằng số để cân bằng mức độ quan trọng của các hàm mất mát và được chọn bằng phương pháp thử nghiệm.

CIOU Loss [15] được tính bằng công thức:

$$L_{CIOU} = 1 - IoU + \frac{p^2(b, b^{gt})}{c^2} + \gamma v \quad (2)$$

Trong đó:

$$\gamma = \frac{v}{(1 - IoU) + v} \quad (3)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{n} \right)^2 \quad (4)$$

YOLOv8 sử dụng Soft-NMS [13], là một phương pháp giảm số lượng bounding box trùng lặp trong phát hiện đối tượng bằng cách điều chỉnh điểm số của các bounding box khi chúng trùng lặp với nhau, thay vì loại bỏ chúng hoàn toàn như trong phương pháp NMS truyền thống. Một sự khác biệt khác giữa 2 mô hình đó là quá trình huấn luyện dữ liệu của chúng. YOLOv8 được huấn luyện trên bộ dữ liệu có quy mô lớn hơn và đa dạng hơn so với YOLOv5. Do đó, YOLOv8 có hiệu suất cao hơn do phạm vi hình ảnh rộng hơn. YOLOv8 bao gồm một công cụ gán nhãn mới có tên RoboFlow Annotate, được sử dụng cho chú thích hình ảnh. RoboFlow Annotate giúp việc chú thích hình ảnh và gán nhãn dễ dàng hơn cho việc huấn luyện mô hình. Mô hình định dạng dữ liệu của YOLOv8 có dạng như sau : (class_id, x_center, y_center, width, height). Vì vậy, để đưa dữ liệu về định dạng mà YOLOv8 có thể huấn luyện được, ta cần chuẩn hóa dữ liệu đầu vào như sau:

$$\begin{aligned} x_{center} &= \frac{bbox[0] + bbox[2] / 2}{image_width} \\ x_{center} &= \frac{bbox[1] + bbox[3] / 2}{image_height} \\ width &= \frac{bbox[2]}{image_width} \\ height &= \frac{bbox[3]}{image_height} \end{aligned} \quad (5)$$

Trong đó :


- x_center: Tọa độ x chuẩn hóa của tâm của hộp giới hạn;
- y_center: Tọa độ y chuẩn hóa của tâm của hộp giới hạn;
- width: Chiều rộng chuẩn hóa của hộp giới hạn;
- image_width: Chiều rộng hình ảnh;
- height: Chiều cao chuẩn hóa của hộp giới hạn;
- image_height: Chiều cao hình ảnh.

2.2. Faster R-CNN

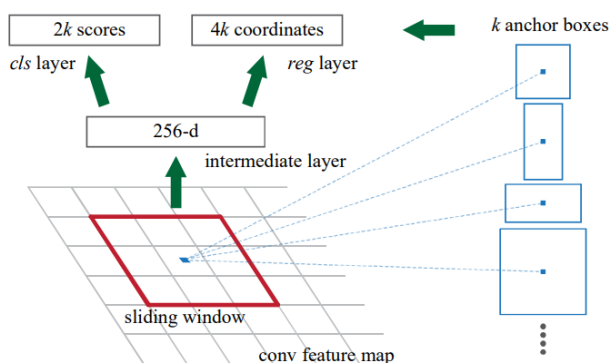
Faster R-CNN là một mô hình nhận dạng và phân loại đối tượng sử dụng trong lĩnh vực thị giác máy tính và trí tuệ nhân tạo. Được công bố lần đầu tiên vào năm 2015 bởi Ross Girshick với tên gọi ban đầu là Fast R-CNN. Faster R-CNN đã dần trở thành một trong những phương pháp tiên tiến cho bài toán nhận dạng và phát hiện đối tượng trong ảnh. Faster R-CNN là 1 phiên bản cập nhật của Fast R-CNN, điểm khác biệt giữa chúng là Fast R-CNN sử dụng thuật toán “Selective Search” để tạo ra Regions Of Interest (ROI), trong khi Faster R-CNN thì sử dụng “Region Proposal Network (RPN)”.

Region Proposal Network (RPN) có nhiệm vụ tạo ra các vùng đề xuất chứa các đối tượng có thể có trong đầu vào. Trong quá trình nhận dạng đối tượng, một trong những việc quan trọng là xác định các vùng quan tâm chứa đối tượng. Trước khi RPN xuất hiện, Fast R-CNN thường sử

dụng các kỹ thuật như Selective Search để trích xuất các vùng đề xuất, tuy nhiên, những phương pháp này sẽ có tốc độ và hiệu suất không cao. RPN đã giải quyết vấn đề này bằng cách sử dụng một mạng nhỏ để dự đoán các vùng đề xuất, RPN có bộ phân loại để trả về xác suất của các vùng (hình 5).



Hình 5. Mô hình Faster R-CNN [11].




Hình 6. Region Proposal Network (RPN) [11].

Faster R-CNN sẽ lấy các feature maps (bản đồ đặc trưng) từ lớp CNN và đưa chúng vào Region Proposal Network. RPN sẽ sử dụng phương pháp sliding window (cửa sổ trượt) ở những feature maps này, sau đó, nó tạo ra k Anchor boxes của các hình dạng và kích cỡ khác nhau. Anchor box chính là một bounding box cơ sở để xác định bounding box bao quanh vật thể dựa trên các phép dịch tâm và scale kích thước chiều dài, rộng. Mỗi loại anchor box sẽ phù hợp để tìm ra bounding box cho một loại vật thể đặc trưng.

Để đánh giá hiệu quả của mô hình Faster R-CNN, ta sẽ đưa bộ dữ liệu về định dạng COCO json để huấn luyện.


3. KẾT QUẢ

Mô hình được huấn luyện trên bộ dữ liệu gồm 1600 hình ảnh với 17108 đối tượng cần nhận diện. Trong tập dữ liệu bao gồm 12148 chuỗi sứ ở dạng bình thường (hình 7a), 1788 chuỗi sứ bị nứt vỡ (hình 7b) và 3172 chuỗi sứ bị hỏng do sét đánh (hình 7c). Phân bố số lượng các nhãn được thể hiện ở hình 8. Tập dữ liệu được chia thành 2 phần là tập huấn luyện và tập kiểm thử với tỉ lệ 80-20.



Hình 7. (a) Chuỗi sứ bình thường; (b) Chuỗi sứ bị nứt vỡ; (c) Chuỗi sứ bị sét đánh.

Để đánh giá độ chính xác của mô hình nhận dạng ảnh thì tiêu chí mAP (mean Average Precise - Độ chính xác trung bình) là tiêu chí được sử dụng phổ biến nhất. Dưới đây là bảng so sánh về kết quả phân loại theo tiêu chí mAP của 2 mô hình YOLOv8 và Faster R-CNN. Qua bảng so sánh ta thấy, đối với nhãn chuỗi sứ bình thường và chuỗi sứ bị nứt vỡ, YOLOv8 có mAP cao hơn so với Faster R-CNN với độ chênh lệch dao động trong khoảng từ 1-2.5%, đối với nhãn chuỗi sứ bị sét đánh thì mAP của Faster R-CNN lại lớn hơn YOLOv8 khoảng 2.5%.



Hình 8. Phân bố số lượng đầu vào của các nhãn.

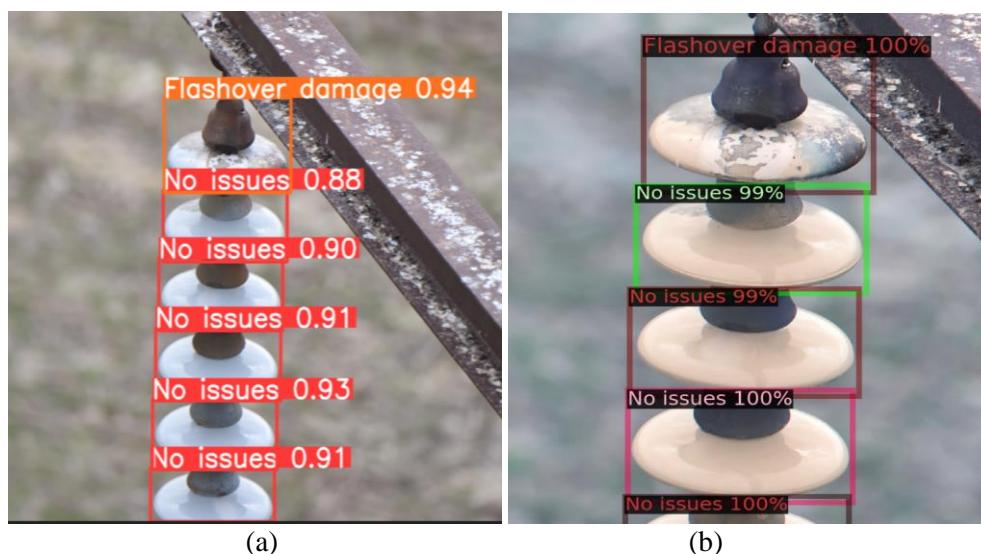
Bảng 1. So sánh độ chính xác trung bình mAP của 02 mô hình.

Nhãn	YOLOv8	Faster RCNN
Tất cả	96.4%	96.33%
Bình thường	98.1%	96.6%
Nứt vỡ	96.5%	95.5%
Sét đánh	94.4%	96.9%

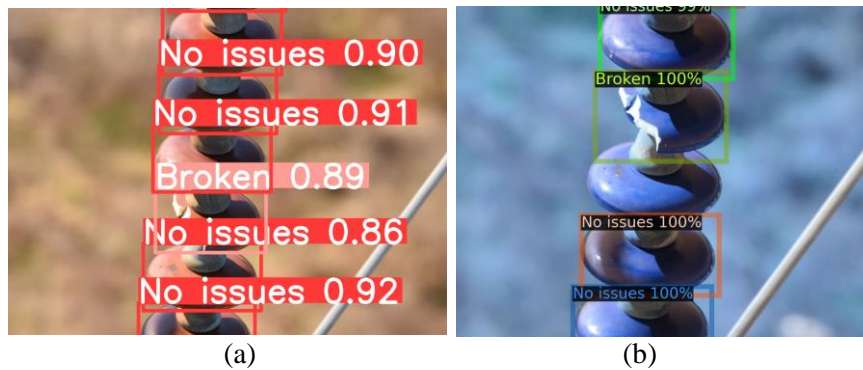
Bảng 2. So sánh thời gian huấn luyện của 02 mô hình.

Mô hình	Thời gian huấn luyện	Thời gian nhận dạng
YOLOv8	2.8 giờ	1.9 mili-giây
Faster R-CNN	4.6 giờ	0.59 giây

Bảng 2 so sánh thời gian huấn luyện và nhận dạng của 02 mô hình. Có thể thấy rằng, YOLOv8 đã được cải thiện cả về thời gian huấn luyện và thời gian nhận dạng, với tốc độ nhanh hơn hẳn so với Faster R-CNN. Điều này cho thấy lợi thế của YOLOv8 đối với các bài toán nhận diện đối tượng trong thời gian thực.



Hình 9. Kết quả nhận dạng từng bát sứ với YOLOv8 (a) và với Faster R-CNN (b) trong trường hợp bị sét đánh.



Hình 10. Kết quả nhận dạng từng bát sứ với YOLOv8 (a) và với Faster R-CNN (b) trong trường hợp bị nứt vỡ.

Hình 9 và 10 thể hiện kết quả nhận dạng cho từng đối tượng là bát sứ trong cả chuỗi sứ với 02 mô hình YOLOv8 và Faster R-CNN trong trường hợp chuỗi sứ bị sét đánh và chuỗi sứ bị nứt vỡ. Có thể thấy, mặc dù Faster R-CNN có mAP thấp hơn một chút so với YOLOv8 nhưng khi đưa vào để nhận diện đối tượng nhỏ trong ảnh thì Faster R-CNN có độ tin cậy của từng đối tượng cao hơn so với YOLOv8. Như vậy, có thể thấy rằng mô hình Faster R-CNN có xu hướng phát hiện nhiều đối tượng nhỏ với độ tin cậy cao.

4. KẾT LUẬN

Nghiên cứu này đề xuất sử dụng 02 mô hình thị giác máy tính là Faster R-CNN và YOLOv8 để phát hiện và phân loại các chuỗi sứ bị hư hỏng. Kết quả cho thấy, cả 2 mô hình đều có khả năng nhận dạng chuỗi sứ bị hỏng hóc với độ chính xác tương đối cao. Mô hình YOLOv8 phù hợp cho các ứng dụng phát hiện đối tượng trong thời gian thực do tốc độ xử lý ảnh và phát hiện đối tượng nhanh, còn mô hình Faster R-CNN tỏ ra phù hợp trong các ứng dụng đòi hỏi có độ chính xác cao như phát hiện vật thể trong y tế, hoặc các bài toán cần nhận diện các đối tượng nhỏ với số lượng lớn. Trong các nghiên cứu tiếp theo, nhóm sẽ tìm hiểu và cải tiến phương pháp xử lý dữ liệu đầu vào để tăng độ chính xác và tốc độ tính toán của các mô hình thị giác máy tính trong bài toán nhận dạng, phân loại ảnh.

TÀI LIỆU THAM KHẢO

- [1]. Li, X.; Su, H.; Liu, G. "Insulator Defect Recognition Based on Global Detection and Local Segmentation," IEEE Access, vol. 8, pp. 59934–59946, (2020).
- [2]. Wang, D.; Sun, J.; Zhang, T. "Self-explosion defect detection method of glass insulator based on improved generative adversarial network". High Volt. Eng., vol. 48, pp. 1096–1103, (2020).
- [3]. Saranya, K.; Muniraj, C. "A SVM Based Condition Monitoring of Transmission Line Insulators Using PMU for Smart Grid," Environment. J. Power Energy Eng., vol. 4, pp. 47–60, (2016).
- [4]. Wang, J.; Liu, G.; Yuan, J.; Wei, "G. Image fusion technology and application in power inspection," Tech. Autom. Appl. 38, 4, (2019).
- [5]. S. Santosh Kumar, K. N. Sunil Kumar, G. Prakasha, H. V. Teja, V. Shrinidhi and Nisarga, "Self-Driving Car Using Neural Networks and Computer Vision," 2022 International Interdisciplinary Humanitarian Conference for Sustainability (IIHC), Bengaluru, India, pp. 1200-1204, (2022).
- [6]. D. Castells-Rufas et al., "A Survey of FPGA-Based Vision Systems for Autonomous Cars," IEEE Access, vol. 10, pp. 132525-132563, (2022).
- [7]. D. Mery, E. Svec, M. Arias, V. Riffo, J. M. Saavedra and S. Banerjee, "Modern Computer Vision Techniques for X-Ray Testing in Baggage Inspection," IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 47, no. 4, pp. 682-692, (2017).
- [8]. C. Mao, L. Yao and Y. Luo, "ImageGCN: Multi-Relational Image Graph Convolutional Networks for Disease Identification With Chest X-Rays," IEEE Transactions on Medical Imaging, vol. 41, no. 8, pp. 1990-2003, (2022).

- [9]. J. Sun, C. Li, X. -J. Wu, V. Palade and W. Fang, “An Effective Method of Weld Defect Detection and Classification Based on Machine Vision,” IEEE Transactions on Industrial Informatics, vol. 15, no. 12, pp. 6322-6333, (2019).
- [10]. N. Zeng, P. Wu, Z. Wang, H. Li, W. Liu and X. Liu, “A Small-Sized Object Detection Oriented Multi-Scale Feature Fusion Approach With Application to Defect Detection,” IEEE Transactions on Instrumentation and Measurement, vol. 71, pp. 1-14, (2022).
- [11]. Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks”, arXiv:1506.01497, (2016).
- [12]. Juan Terven, Diana Cordova-Esparza, “A Comprehensive Review of YOLO: From YOLOv1 and Beyond”, arXiv:2304.00501, (2023).
- [13]. Dillon Reis, Jordan Kupec, Jacqueline Hong, Ahmad Daoudi, “Real-Time Flying Object Detection with YOLOv8”, arXiv: 2305.09972v1, (2023).
- [14]. “YOLOv8.” <https://github.com/ultralytics/ultralytics>
- [15]. Zhaohui Zheng, Ping Wang, Wei Liu, Jinze Li, Rongguang Ye, Dongwei Ren, “Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression”, arXiv: 1911.08287, (2019).
- [16]. Zheng, J.; Wu, H.; Zhang, H.; Wang, Z.; Xu, W. “Insulator-Defect Detection Algorithm Based on Improved YOLOv7”. Sensors, 22, 8801, (2022).
- [17]. Lian, X., & Wang, D. “Insulator defect detection algorithm based on improved YOLOv5”. Frontiers in Computing and Intelligent Systems, 3(2), 44–47, (2023).
- [18]. J. Tang, J. Wang, H. Wang, J. Wei, Y. Wei and M. Qin, “Insulator Defect Detection Based on Improved Faster R-CNN,” 2022 4th Asia Energy and Electrical Engineering Symposium (AEEES), Chengdu, China, pp. 541-546, (2022).

ABSTRACT

Transmission line insulator defect detection based on computer vision

The quick and accurate detection of faults in insulator strings plays a crucial role in ensuring the stability and reliability of the transmission power grid. In this study, the authors propose a method for detecting and classifying insulation faults on transmission line insulator strings based on computer vision models. The dataset used in the study consists of 1,600 images of insulator strings with a total of 18,195 objects categorized into three types: normal functioning strings, cracked strings, and strings damaged by lightning strikes. The dataset is split into a training set and a test set with an 80-20 ratio. The dataset is trained on two computer vision models, YOLOv8 and Faster R-CNN. The results show that the YOLOv8 model can detect and classify cracked and lightning-damaged insulator strings with an accuracy of up to 96.4%.

Keywords: Insulator; Transmission line; Computer vision; Faster R-CNN; YOLOv8.