

## Intelligent monitoring of power transmission line insulators using UAV images and deep learning model

Reza Rahimi Nejadbougar<sup>1</sup> , Ebadat Ghanbari Parmehr<sup>\*2</sup> , Alireza Afary<sup>3</sup> , Samira Mavaddati<sup>4</sup> 

1- MSc student, Faculty of civil engineering, Babol Noshirvani University of Technology, Babol, Iran. Email: samanrahimi.act@stu.nit.ir

2- (\*Corresponding author) Assistant professor, Faculty of civil engineering, Babol Noshirvani University of Technology, Babol, Iran.  
Email: parmehr@nit.ac.ir

3- Assistant professor, Faculty of civil engineering, Babol Noshirvani University of Technology, Babol, Iran. Email: afary@nit.ac.ir

4- Assistant professor, Faculty of engineering and technology, University of Mazandaran, Babolsar, Iran. Email: s.mavaddati@umz.ac.ir

### Article Info

#### Date of receive:

2024/10/11

#### Date of last review:

2024/11/12

#### Date of accept:

2025/01/13

#### Date of online publication:

2025/01/13

#### Keywords:


Power transmission lines,  
Insulator,  
UAV images,  
Deep learning,  
YOLOv8,  
Detection,  
Classification

### Extended Abstract

#### Introduction

Power transmission lines are essential components of modern electrical networks, playing a crucial role in ensuring a continuous and stable supply of electricity to various sectors, including industries, homes, and essential services. Insulators within these systems are responsible for maintaining the necessary separation between electrical conductors and the supporting structures. This separation is vital for the reliability and safety of power networks, as any failure in the insulators can lead to serious issues, such as power outages and safety risks. Insulators are constantly exposed to various stressors, including mechanical wear, harsh environmental conditions, and electrical surges, all of which can degrade their performance over time and lead to faults. Traditional methods for inspecting power transmission line insulators are not only labor-intensive but also costly and risky for workers, as they often involve climbing transmission towers or using ground-based equipment like binoculars or cameras. These approaches are time-consuming, prone to human error, and limited in scope, leading to inefficient maintenance and the potential for missed faults. The increasing complexity of modern electrical networks demands more efficient, reliable, and safer methods for detecting insulator faults. As such, there is a need for advanced solutions that can overcome the limitations of traditional inspection methods and ensure the continuous operation of power transmission systems

#### Materials & Methods

This research proposes a new method for monitoring and detecting faults in power transmission line insulators using aerial imagery captured by Unmanned Aerial Vehicles (UAVs) and analyzed through the YOLOv8 deep learning model. ...  Page 82

### How to Cite:

Rahimi Nejadbougar, R. Ghanbari Parmehr, E. Afary, A. Mavaddati, S. (2025). Intelligent monitoring of power transmission line insulators using UAV images and deep learning model. Scientific - Research Quarterly Geographical Data (SEPEHR). 34(134), 81-100.

UAVs equipped with high-resolution cameras provide a safe, efficient, and non-invasive way to inspect large sections of transmission lines, eliminating the need for workers to scale towers or navigate hazardous environments. The aerial images captured by UAVs are processed using the YOLOv8 model, which detects insulators and classifies them as intact, broken, or arcing. YOLOv8 model is selected for its real-time object detection capabilities, speed, and high accuracy, making it particularly suitable for analyzing large datasets in a short time frame. The method involves capturing aerial images of transmission lines, labeling the insulators within the images, and using this labeled data to train the YOLOv8 model to detect insulators and classify their condition into three categories: intact, broken, or arcing. Once the model is trained, it can automatically analyze new UAV-captured images to identify potential faults, significantly improving the efficiency, accuracy, and cost-effectiveness of power line inspections.

### Results & Discussion

The results of this study demonstrate that the proposed approach is highly effective. The YOLOv8 model achieved an overall accuracy of 93.9% in detecting insulators within the UAV-captured images. Furthermore, the model demonstrated an impressive 99.2% accuracy in classifying the detected insulators into the three predefined categories. These results suggest that the YOLOv8 model is not only capable of accurately identifying and classifying insulators but also of distinguishing between different types of faults, such as broken or arcing insulators. This high level of accuracy ensures that potential issues can be identified early, allowing for timely maintenance and repair before they escalate into more serious problems. In comparison to traditional methods of monitoring power transmission lines, the UAV and deep learning-based approach presents several significant advantages. Firstly, it offers a much faster and more efficient means of inspecting large areas of transmission networks. UAVs can cover vast distances in a short period, and the automated analysis of the captured images further reduces the time required for fault detection. Secondly, the method is highly reliable,

with deep learning models providing a level of accuracy that far exceeds manual inspections. Thirdly, it is more cost-effective, as it reduces the need for manual labor and expensive equipment while minimizing the risk of accidents and injuries.

### Conclusion

In conclusion, the use of UAVs and deep learning models, specifically the YOLOv8 architecture, offers a powerful and efficient solution for monitoring and detecting faults in power transmission line insulators. This approach overcomes the significant challenges posed by traditional inspection methods, such as labor-intensive processes, high costs, and safety risks to personnel. UAVs allow for quick and comprehensive coverage of large transmission networks, while YOLOv8 ensures highly accurate and real-time detection of insulator faults. The combination of these technologies provides substantial benefits in terms of accuracy, speed, and reliability, significantly reducing the likelihood of undetected faults and enabling timely maintenance. Additionally, it is a cost-effective approach, as it minimizes the need for manual inspections and emergency repairs. As electrical networks expand and increase in complexity, integrating such advanced technologies will play a crucial role in maintaining the stability, safety, and security of power supply systems in the future.



صفحات ۱۰۰ - ۸۱

## فصلنامه علمی - پژوهشی

اطلاعات جغرافیایی (سپهر) دوره ۳۴، شماره ۱۳۴، تابستان ۱۴۰۴



مقاله پژوهشی

doi <https://doi.org/10.22131/sepehr.2025.2042614.3099>

## پایش هوشمند مقره‌های خطوط انتقال نیرو با استفاده از تصاویر پهپاد و مدل یادگیری عمیق

رضا رحیمی نژادبوگر<sup>۱</sup>، عبادت قنبری پرمهر<sup>۲\*</sup>، علیرضا آفری<sup>۳</sup>، سمیرا مودّتی<sup>۴</sup>

- ۱- دانشجوی کارشناسی ارشد فتوگرامتری، دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران [samanrahimi.act@stu.nit.ir](mailto:samanrahimi.act@stu.nit.ir)  
 ۲- (\*نویسنده مسئول) استادیار دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران [parmehr@nit.ac.ir](mailto:parmehr@nit.ac.ir)  
 ۳- استادیار دانشکده مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران [afary@nit.ac.ir](mailto:afary@nit.ac.ir)  
 ۴- استادیار دانشکده مهندسی و فناوری، دانشگاه مازندران، بابلسر، ایران [s.mavaddati@umz.ac.ir](mailto:s.mavaddati@umz.ac.ir)

## چکیده

خطوط انتقال نیرو، بخش حیاتی شبکه‌های برق هستند و سلامت آن‌ها به منظور تأمین برق پایدار جامعه ضروری است. مقره‌ها، به‌عنوان عایق بین هادی‌ها نقش اساسی در این شبکه ایفا می‌کنند و عیوب آن‌ها می‌تواند منجر به قطع، اتلاف برق و خطرات جانی شود. پایش و تشخیص به موقع این عیوب، نقشی کلیدی در حفظ پایداری و امنیت شبکه دارد. روش‌های پایش سنتی خطوط انتقال برق نیز زمان‌بر و پرهزینه بوده و احتمال وقوع حوادث در این روند بیشتر می‌شود. پهپاد و پردازش تصاویر هوایی حاصل از آن با استفاده از شبکه‌های عصبی یادگیری عمیق روشی نوین و کارآمد برای پایش خطوط انتقال برق ارائه می‌دهد. هدف این پژوهش، غلبه بر چالش‌های روش‌های سنتی تشخیص عیوب، مانند زمان‌بر بودن، پرهزینه بودن و احتمال وقوع حوادث است. همچنین در تحقیق حاضر، روشی نوین بر مبنای تصویربرداری هوایی و استفاده از وظایف مختلف مدل یادگیری عمیق یولو۸ نانو، برای پایش و تشخیص عیوب مقره‌ها در خطوط انتقال نیرو ارائه می‌شود. در روند این پژوهش مدل یادگیری عمیق یولو۸ طی دو مرحله با در نظر گرفتن دو کلاس سالم و معیوب و سه کلاس سالم، شکستگی و آرک‌زدگی آموزش داده شده که دقت ۹۲/۶٪ در وظیفه تشخیص و دقت ۹۸/۹٪ در وظیفه طبقه‌بندی با دو کلاس و دقت کل ۹۳/۹٪ به‌منظور تشخیص مقره در تصویر و دقت ۹۹/۲٪ به‌منظور طبقه‌بندی تصاویر در سه کلاس مقره سالم، مقره شکسته و آرک‌زدگی مقره برای مدل یولو۸ حاصل شده است. نتایج این مطالعه نشان می‌دهد که روش پیشنهادی مبتنی بر تصویربرداری هوایی با استفاده از مدل‌های عمیق یولو۸، روشی دقیق، کارآمد و مقرون به‌صرفه برای پایش و تشخیص عیوب مقره‌ها در خطوط انتقال برق است. این روش در مقایسه با روش‌های سنتی پایش مقره‌ها، از مزایای قابل توجهی از جمله دقت بالا، سرعت بالای پردازش، قابلیت اطمینان بیشتر و هزینه عملیاتی پایین‌تر برخوردار است.

## اطلاعات مقاله

تاریخ دریافت:

۱۴۰۳/۰۷/۲۰

تاریخ آخرین بازنگری:

۱۴۰۳/۰۸/۲۲

تاریخ پذیرش:

۱۴۰۳/۱۰/۲۴

تاریخ انتشار:

۱۴۰۳/۱۰/۲۴

## واژه‌های کلیدی:

خطوط انتقال نیرو؛

مقره؛

تصاویر پهپاد؛

یادگیری عمیق؛

یولو۸؛

تشخیص؛

طبقه‌بندی

## استناد به این مقاله:

رحیمی نژادبوگر، ر؛ قنبری پرمهر، ع؛ آفری، ع؛ مودّتی، س (۱۴۰۴) پایش هوشمند مقره‌های خطوط انتقال نیرو با استفاده از تصاویر پهپاد و مدل یادگیری عمیق؛ فصلنامه علمی پژوهشی اطلاعات جغرافیایی (سپهر)، ۳۴ (۱۳۴)، ۸۱-۱۰۰

## ۱- مقدمه

از دکل‌های برق فراهم شده است. با این حال به منظور پایش سلامت مقره‌ها نیاز به بازبینی حجم زیادی از تصاویر پهپاد توسط کاربر سیستم وجود دارد. استفاده از روش‌های نوین مانند یادگیری عمیق و الگوریتم‌های شبکه عصبی مصنوعی می‌توانند به‌طور قابل توجهی این فرآیند را ارتقا دهند. با پیشرفت‌های چشمگیر در زمینه یادگیری ماشین و بینایی کامپیوتر، مدل‌های عمیق به ابزاری قدرتمند برای حل

مسائل مختلف تبدیل شده‌اند (Antwi-Bekoe et al., 2020). تشخیص عیوب مقره در شبکه انتقال برق فشار قوی یکی از مسائلی است که می‌تواند با استفاده از مدل‌های عمیق به‌طور مؤثرتری حاصل شود (Bhola et al., 2018). مدل‌های یادگیری عمیق نوعی از شبکه‌های عصبی مصنوعی هستند که به دلیل برخورداری از معماری پیچیده‌تر نسبت به شبکه‌های سنتی، قادر به یادگیری و حل مسائل پیچیده‌تر هستند (Hao, 2019). این مدل‌ها با الهام از ساختار مغز انسان طراحی و از لایه‌های متعددی از نورون‌های مصنوعی تشکیل شده‌اند که به‌صورت سلسله مراتبی به یکدیگر متصل هستند (Hao, 2019). به‌عبارت دیگر، هوش مصنوعی و مدل‌های یادگیری عمیق با استفاده از حجم عظیمی از داده‌ها آموزش داده می‌شوند و می‌توانند الگوهای پیچیده و غیرخطی را در داده‌ها تشخیص دهند (He et al., 2016). این قابلیت، آن‌ها را برای طیف گسترده‌ای از کاربردها، از جمله تشخیص اشیاء، پردازش زبان طبیعی، و... سودمند نموده است (Lin & Kuo, 2024). مدل مورد استفاده در این پژوهش شبکه عمیق یولو۸<sup>۲</sup> نانو است. مدل‌های یولو نوعی از شبکه‌های عصبی عمیق هستند که برای تشخیص اشیاء در تصاویر و ویدیوها در زمان واقعی طراحی شده‌اند (Jiang et al., 2022). این مدل‌ها از یک معماری یکپارچه استفاده می‌کنند که به آن‌ها اجازه می‌دهد تا اشیاء را در یک مرحله واحد تشخیص و طبقه‌بندی نمایند (Hussain, 2023). مدل یولو۸ قابلیت پردازش و شناسایی و ردیابی شیء در زمان واقعی، تخمین وضعیت، شناسایی و طبقه‌بندی را دارا بوده

خطوط انتقال نیرو نقش حیاتی در سیستم‌های قدرت ایفا می‌کنند و عایق‌های الکتریکی در این شبکه از اهمیت زیادی برخوردارند. شرایط پیچیده محیطی مانند آب و هوا می‌تواند باعث خرابی و تأخیر در تعمیرات شده و اهمیت پایش قطعات معیوب دوچندان می‌شود (Silva et al., 2022). همچنین سلامت مقره‌ها به‌عنوان عایق بین هادی‌ها به منظور عملکرد صحیح مقره در شبکه انتقال برق و جوامع صنعتی بسیار ضروری است. نقص‌های احتمالی در مقره‌ها شکستگی و آرک‌زدگی<sup>۱</sup> هستند. مفهوم آرک‌زدگی به حالتی اشاره دارد که جریان برق به‌طور غیرمجاز از یک مسیر ناخواسته عبور می‌کند و باعث نشی الکتریسته و تغییر رنگ سطوح عایق می‌شود. تصاویر با کیفیت بالا به شناسایی نشانه‌های بصری این عیب، مانند تغییر رنگ و سوختگی در مقره‌ها، کمک می‌کنند. هدف این پژوهش ارائه مدل‌های یادگیری عمیق برای شناسایی دقیق آرک‌زدگی و سایر عیوب است. عیوب مقره‌ها می‌تواند منجر به خاموشی، نشت برق و حتی خطرات جانی شود (Ahmed et al., 2024). به همین دلیل، تشخیص و رفع این عیوب در نزدیک‌ترین زمان ممکن ضروری است. عیوب حائز اهمیت در مقره‌ها شامل شکستگی و آسیب‌دیدگی، آرک‌زدگی و آلودگی است که به مرور باعث از بین رفتن خاصیت عایق آن‌ها می‌شود (Xu et al., 2023).

تشخیص عیوب مقره‌ها به‌طور معمول به‌صورت سنتی توسط بازرسان انجام می‌شود که بسیار زمان‌بر، پرهزینه و مستعد خطای انسانی است (Bhola et al., 2018). علاوه بر این، در بازدید میدانی به‌دلیل دید محدود بازرسان از جهات مختلف به مقره‌ها نیز یکی از چالش‌های این روش است. به همین دلیل بازرسی مقره‌ها با پهپاد بسیار مورد توجه قرار گرفته است (Liu et al., 2022). با توجه به توسعه فناوری در سالیان اخیر و توسعه پرنده‌های بدون سرنشین مجهز به دوربین با کیفیت، امکان تصویربرداری در جهات مختلف

الگوریتم پیشنهادی بر روی مجموعه داده‌ای از تصاویر مقره‌های سالم و معیوب، می‌توان به تشخیص عیوب احتمالی مانند شکستگی، آرک‌زدگی و آلودگی پرداخت. تنظیم پارامترهای مدل یولو ۸ به صورت بهینه متناسب با ویژگی‌ها و پیچیدگی‌ها در تشخیص عیوب در تصاویر صورت می‌گیرد و عملکرد تشخیص عیوب مدل آموزش دیده براساس معیارهای دقت، حساسیت و ویژگی مورد ارزیابی قرار می‌گیرد. در نهایت ادغام و استقرار مدل در یک سیستم نرم‌افزاری یا برنامه کاربردی برای تشخیص و دسته‌بندی خودکار عیوب پیشنهاد می‌شود. درخصوص تشخیص خودکار عیوب توسط تصاویر پهپاد و مدل‌های یادگیری عمیق بسیاری از محققان در سراسر جهان از جمله (Chang et al., 2023)، (Sampedro et al., 2019)، (Wang et al., 2023)، (Hu et al., 2022)، (Qiang et al., 2023)، (Qiu et al., 2022)، (Li et al., 2020)، (Miao et al., 2019)، (Lei & Sui, 2019) با مدل‌های مختلفی به این موضوع پرداخته‌اند.

این مطالعه روشی نوین برای پایش و تشخیص عیوب مقره‌ها با استفاده از تصویربرداری هوایی با پهپاد و شبکه‌های عصبی یادگیری عمیق با به‌کارگیری مدل یولو ۸ ارائه می‌دهد. روش پیشنهادی با مزایایی مانند سرعت و دقت بالا، کاهش هزینه‌ها و خطاهای انسانی، رویکردی کارآمد، دقیق و مقرون به صرفه برای پایش و تشخیص عیوب مقره‌ها در خطوط انتقال برق به‌شمار می‌رود و می‌تواند به‌طور گسترده‌ای در صنعت برق برای ارتقای پایداری و امنیت شبکه‌های برق به‌کار گرفته شود.

در جدول (۱)، گزیده‌ای از پژوهش‌های انجام‌شده در سال‌های اخیر به منظور تشخیص عیوب مقره‌های خطوط انتقال برق با استفاده از مدل‌های یادگیری عمیق براساس مدل عمیق به‌کار گرفته شده، اهداف تحقیقاتی، منابع داده و سال انتشار بیان شده‌اند.

و به‌خصوص با توجه به هدف مطالعه برای شناسایی و طبقه‌بندی عیوب مقره‌ها در تصاویر هوایی پهپادها مناسب است. نتایج حاکی از عملکرد قابل اعتماد این مدل در پایش مقره‌ها بوده که دقت و کارایی آن را در مقایسه با روش‌های سنتی به خوبی نشان می‌دهد. مدل‌های یولو به دلیل سرعت و دقت مناسب در کاربردهای مختلفی مانند رباتیک، نظارت تصویری و تشخیص چهره استفاده می‌شوند. از این رو، پایش منظم و دقیق مقره‌ها به کمک این مدل‌های عمیق به افزایش قابلیت اطمینان شبکه برق و کاهش احتمال قطعی برق منجر خواهد شد. این روال نوین، تحولی چشمگیر در حوزه پایش خطوط انتقال برق ایجاد کرده و به‌عنوان یک راه‌حل کارآمد و مقرون به صرفه برای تضمین امنیت و پایداری شبکه برق به‌شمار می‌رود. در مدل یولو ستون فقرات<sup>۱</sup> از شبکه‌های پایه‌ای مانند رزنکست<sup>۲</sup>، رزنت<sup>۳</sup> یا دارکنت<sup>۴</sup> برای استخراج ویژگی‌های تصویر استفاده می‌شود (Reis et al., 2023) همچنین، بخش گردن<sup>۵</sup> در این مدل عمیق از بلوک‌های FPN<sup>۶</sup> و PANET<sup>۷</sup> برای ترکیب ویژگی‌های استخراج شده که در مقیاس‌های مختلف استفاده می‌شوند تشکیل شده است. در نهایت قسمت سر<sup>۸</sup> این مدل عمیق شامل چندین بخش پیش‌بینی برای تخمین کادرهای محصورکننده<sup>۹</sup> اشیاء، طبقه‌بندی و سایر پارامترها است (Sadykova et al., 2019). این مدل عمیق قابلیت انجام وظایف مختلف از جمله تشخیص اشیاء، طبقه‌بندی، قطعه‌بندی تصویر و تخمین شکل را دارد (Hussain, 2023).

روش پیشنهادی در این پژوهش شامل جمع‌آوری و آماده‌سازی داده‌ها، آموزش مدل یولو ۸ به منظور تشخیص عیوب و استقرار مدل در تصاویر جدید است. با آموزش

- 1- Backbone
- 2- ResNext
- 3- ResNet
- 4- CSP - Darknet
- 5- Neck
- 6- Feature Pyramid Network
- 7- Path Aggregation Network
- 8- Dense prediction and sparse prediction
- 9- Bounding boxes

جدول ۱: مروری بر پژوهش‌های صورت گرفته به منظور تشخیص نقص مخره‌ها بر اساس مدل‌های عمیق

سال انتشار	ساختار پایگاه داده	هدف	مدل عمیق	کلاس‌ها	مرجع
۲۰۲۳	---	تشخیص ترک، نوع مخره و لانه پرنده	یولو 7، یولو 5	۵	Chang et al., 2023
۲۰۱۹	---	تشخیص نقص مخره	UP-NET	۱	Sampedro et al., 2019
۲۰۱۹	---	تشخیص نقص و آلودگی مخره	رزنت، شبکه پیشنهاد ناحیه	۴	Wang et al., 2023
۲۰۲۲	DATASETMERGED-COCO	تشخیص مخره	FR-CNN	۱	Hu et al., 2022
۲۰۲۳	DATASSETNINJA-YOLOV8	تشخیص آرک، لانه، شکستگی	یولو 8S	۳	Qiang et al., 2023
۲۰۲۲	---	تشخیص مخره و نقص مخره	یولو 4	۲	Qiu et al., 2022
۲۰۲۰	---	تشخیص نقص مخره	FR-CNN	۲	Li et al., 2020
۲۰۱۹	COCO	تشخیص جنس و نقص	SSD	۲	Miao et al., 2019
۲۰۱۹	---	تشخیص نقص، لانه	FR-CNN	۳	Lei & Sui, 2019
---	Yolov8	تشخیص مخره سالم، شکسته، آرک‌زده	یولو 8	۳	روش پیشنهادی

## ۲- داده‌ها و روش پژوهش

خطوط انتقال نیرو، به‌ویژه تصاویر هوایی با وضوح بالا، این محدودیت محسوس است. عواملی مانند عدم وجود بانک‌های داده تخصصی، محدودیت‌های قانونی و امنیتی برای انتشار داده‌ها، کمبود تجهیزات پیشرفته تصویربرداری هوایی، ضعف در مستندسازی منظم و عدم ثبت سیستماتیک عیوب و همچنین هزینه بالای جمع‌آوری، موانعی مهم در این مسیر هستند. این موانع پژوهشگران را ناچار به استفاده از منابع داده عمومی یا بین‌المللی می‌کند، که می‌تواند بر دقت و کارایی مدل‌ها تأثیر بگذارد. در این پژوهش نیز با بهره‌گیری از داده‌های معتبر بین‌المللی، تلاش شده تا دقت و اعتبار نتایج بهبود یابد. تصویربرداری‌ها باید از زوایای مختلف و با کیفیت بالا انجام شوند و داده‌های جمع‌آوری شده باید قبل از آموزش مدل‌های یادگیری عمیق، پیش‌پردازش شوند. در این پژوهش، اصول تصویربرداری پهبادی برای تشخیص و پایش عیوب مخره‌های خطوط انتقال برق بر پایه فاکتورهای مهمی مانند وضوح تصویر، زاویه تصویربرداری، شرایط نوری، پایداری پرواز و زمان‌بندی منظم جمع‌آوری

در این بخش به معرفی پایگاه داده مورد مطالعه و پیش‌پردازش تصاویر پهباد پرداخته شده و سپس الگوریتم مبتنی بر مدل عمیق تشریح می‌شود. از تصاویر پهباد با کیفیت دوربین ۲۰ مگاپیکسل و تصاویر با رزولوشن ۱۰۸۰ از اینترنت برای آموزش مدل بهره گرفته شده است. تصاویر با کیفیت بالا به شناسایی نشانه‌های بصری عیوب، مانند تغییر رنگ و سوختگی در مخره‌ها، کمک می‌کنند.

### ۲-۱- داده‌ها

در این مقاله، به‌منظور آماده‌سازی پایگاه داده مورد نیاز از تصاویر تهیه شده توسط پهباد از شبکه انتقال برق فشار قوی با پرواز اختصاصی به‌صورت محلی و همچنین داده‌های موجود در اینترنت استفاده شد (*Roboflow, n.d.*). یکی از چالش‌های اساسی در پروژه‌های هوش مصنوعی و یادگیری عمیق در ایران، محدودیت در دسترسی به داده‌های مناسب و کافی است. در حوزه تشخیص و پایش عیوب مخره‌های

تهیه شده و انواع مختلف مقره‌های مورد پایش نشان داده شده‌اند.

## ۲-۱-۱- افزونگی داده<sup>۴</sup>

افزایش داده روالی مؤثر در یادگیری ماشین است که برای غنی‌سازی مجموعه داده‌ها با نمونه‌های جدید و مصنوعی استفاده می‌شود (Atomar et al., 2023). این امر به نوبه خود، مدل‌های یادگیری ماشین را قادر می‌سازد تا با تنوع بیشتری در داده‌ها آموزش ببینند و در نتیجه دقت افزایش یابد.



نگاره ۱: تصاویر نمونه مقره سالم و انواع عیوب مقره مورد تشخیص، ستون الف) مقره سالم، ستون ب) شکستگی در مقره و ستون ج) آرک‌زدگی مقره

در روش پیشنهادی، با توجه به محدودیت عیوب مورد پایش مقره در تصاویر، افزونگی داده برای بهبود دقت مدل و ایجاد توازن بین کلاس‌های تعیین شده در پایگاه داده

تصاویر بنا شده است. وضوح و کیفیت تصاویر با استفاده از دوربین‌های با کیفیت و تنظیمات مناسب فاصله پرواز تضمین می‌شود. همچنین، انتخاب زوایای مناسب و انجام تصویربرداری در شرایط نوری مطلوب به افزایش دقت در شناسایی عیوب کمک می‌کند. پایداری پرواز با استفاده از سیستم‌های پایدارسازی تصویر، به جلوگیری از لرزش تصاویر کمک می‌کند و برنامه‌ریزی منظم برای پوشش کامل مقره‌ها، امکان پایش دقیق‌تری را فراهم می‌کند. رعایت این اصول، به بهبود کیفیت تصاویر پهپادی و در نتیجه دقت و اعتبار نتایج مدل‌های یادگیری عمیق کمک می‌کند. فرآیند پایش پردازش شامل اعمال عملیات مختلفی مانند تغییر اندازه، نرمال‌سازی و حذف نویز بر روی تصاویر است. تصاویر با استفاده از وسایط روباتیک<sup>۱</sup> به منظور تشخیص و طبقه‌بندی به صورت مجزا برچسب‌گذاری شده و خروجی کادرهای محصورکننده برای تشخیص و تصاویر کلاس‌های مختلف به منظور طبقه‌بندی با فرمت‌های یولو<sup>۲</sup> و یولو-CLAS<sup>۲</sup> آماده می‌شوند. روباتیک<sup>۱</sup> یک بستر مبتنی بر پردازش ابری<sup>۳</sup> است که ابزارها و خدماتی را برای کاربرهای حوزه بینایی کامپیوتر و یادگیری ماشین ارائه می‌دهد (Roboflow, n.d.). تصاویر اصلی مورد استفاده ۸۵۳ تصویر بوده است که با اعمال افزونگی داده روی این تصاویر در روباتیک، تعداد بیشتری از تصاویر برای آموزش مدل حاصل شده است. تصاویر پهپاد می‌توانند قدرت تفکیک‌های مختلفی داشته باشند، که ممکن است برای آموزش مدل چالش‌برانگیز باشد. به منظور غلبه بر این مشکل، می‌توان تصاویر را به یک مقدار ثابت، مانند ۶۴۰×۶۴۰، تغییر اندازه داد. این کار به اطمینان از یکسان بودن ابعاد ورودی برای مدل کمک می‌نماید و می‌تواند به بهبود دقت آن مدل منجر شود. تغییر اندازه تصاویر پهپاد فقط یک نمونه از وظایف پیش‌پردازشی است که می‌توان برای آماده‌سازی داده‌ها برای آموزش مدل یادگیری عمیق انجام داد. در نگاره (۱) تصاویر اولیه


1- Roboflow

2- Classification

3- Cloud

4- Data augmentation





نگاره ۳: تصاویر حاصل از افزونگی داده: ردیف اول تصاویر مقره‌های سالم، ردیف دوم تصاویر مقره شکسته و ردیف سوم تصاویر مقره آرک‌زده با چرخش ۹۰ درجه و نسخه افزونه شده آن‌ها براساس چرخش کادر محصورکننده، ایجاد نویز و چرخش تصاویر

در نگاره (۳)، نمونه تصاویر با افزونگی داده و اعمال ۲-۲- روش پیشنهادی تشخیص عیوب مقره‌ها به کمک تصاویر پهپاد و مدل‌های عمیق یکی از کاربردهای مهم یادگیری عمیق و پردازش تصویر در حوزه انرژی است (Sadykova et al., 2019). با به‌کارگیری مدل‌های یادگیری عمیق، تصاویر پهپاد به‌طور خودکار پردازش شده و عیوب و نواقص احتمالی مقره‌ها، مانند ترک خوردگی، شکستگی و آلودگی، تشخیص و دسته‌بندی می‌شوند. این فرایند، روشی کارآمد، دقیق و کم‌هزینه برای پایش وضعیت مقره‌ها و پیشگیری از خاموشی‌های ناگهانی و خطرات جانی و مالی ناشی از آن ارائه می‌دهد. مدل‌های یادگیری عمیق می‌توانند عیوب ظریف و نامحسوس را که ممکن است از چشم بازرسان انسانی پنهان بمانند، به‌طور دقیق تشخیص دهند (Antwi-Bekoe et al., 2020). استفاده از پهپادها به جای گشت‌های زمینی پرهزینه و زمان‌بر، به‌طور قابل توجهی هزینه‌های پایش خطوط انتقال برق را کاهش می‌دهد.

جدول ۲: تعداد تصاویر اخذ شده به همراه افزونگی داده

به‌منظور آموزش مدل یادگیری عمیق با شرح وظایف

موردانتظار مدل

مدل عمیق	وظیفه	تصاویر	کلاس‌ها	نوع تصویر
یولو 8n	تشخیص شیء	۱۷۷۵	۲	رنگی
یولو 8-CLS	طبقه‌بندی	۳۲۰۷	۲	رنگی
یولو 8n	تشخیص شیء	۱۷۷۵	۲	خاکستری
یولو 8-CLS	طبقه‌بندی	۳۲۰۷	۲	خاکستری
یولو 8n	تشخیص شیء	۱۸۴۸	۳	رنگی
یولو 8-CLS	طبقه‌بندی	۳۶۰۱	۳	رنگی
یولو 8n	تشخیص شیء	۱۹۰۲	۳	خاکستری
یولو 8-CLS	طبقه‌بندی	۳۶۰۱	۳	خاکستری

#### ۲-۲-۱- آموزش مدل یادگیری عمیق

در این مرحله، سناریویی مبتنی بر حل مسئله تشخیص عیوب مقره‌ها به کمک مدل یادگیری عمیق یولو ۸ با استفاده

جدول ۳: تعداد تصاویر مورد استفاده در آموزش مدل یولو با دو کلاس، قبل و بعد از افزودن داده

نوع تصویر	وظیفه	کلاس	تعداد قبل از افزودن	تعداد تصاویر آموزش	تعداد تصاویر اعتبارسنجی	تصاویر آزمون	تعداد بعد از افزودن
خاکستری	تشخیص	سالم	۷۲۰	۱۲۸۴	۸۵	۱۵۴	۱۵۲۳
		معیوب	۱۳۳	۱۸۳	۲۱	۴۸	۲۵۲
رنگی	تشخیص	سالم	۷۲۰	۱۵۷۳	۷۹	۱۳۲	۱۷۸۴
		معیوب	۱۳۳	۱۸۲	۱۴	۱۷	۲۱۳
خاکستری	طبقه‌بندی	سالم	۱۶۰۱	۲۱۴۲	۲۲۷	۳۰۶	۲۶۷۵
		معیوب	۳۲۰	۴۳۶	۴۳	۵۶	۵۳۵
رنگی	طبقه‌بندی	سالم	۱۶۰۱	۲۱۴۰	۲۲۷	۳۰۴	۲۶۷۱
		معیوب	۳۲۰	۴۳۶	۴۳	۵۷	۵۳۶

و برای طبقه‌بندی عیوب تشخیص داده‌شده به کار می‌رود. مراحل اصلی این چارچوب به این شرح است:  
 (۱) **پیش‌پردازش تصویر:** تصاویر مقرر در ابتدا پیش‌پردازش می‌شوند تا برای مدل‌های یادگیری عمیق مناسب شوند. این پیش‌پردازش شامل تغییر اندازه، نرمال‌سازی و افزودن داده است.

(۲) **تشخیص شیء با یولو ۸:** مدل مذکور برای تشخیص اشیاء موجود در تصاویر مانند مقررها و عیوب مقرر به کار می‌رود. این مدل موقعیت و نوع هر شیء را در تصویر مشخص می‌نماید.

(۳) **استخراج ویژگی و طبقه‌بندی:** با استفاده از مدل یولو ۸ طبقه‌بندی عیوب مقررهای خطوط انتقال، تفکیک عایق‌های سالم و معیوب انجام می‌شود.

در جدول (۳)، تعداد کل تصاویر اخذ شده برای آموزش مدل در دو کلاس سالم، و معیوب مشاهده می‌شود. همچنین، در این جدول اطلاعات تصاویر مورد استفاده با در نظر گرفتن دو کلاس سالم و معیوب ارائه شده است.

به منظور دستیابی دقیق‌تر به عیوب مقرر، دسته معیوب به دو زیرشاخه شکستگی و آرک‌زدگی دسته‌بندی شدند و عیوب مورد پایش در مقررها تفکیک شدند. همچنین

از مجموعه داده‌های پیش‌پردازش شده پیشنهاد و بررسی می‌شوند. در طول فرآیند آموزش، مدل یاد می‌گیرد که عیوب و نواقص احتمالی مقررها را در تصاویر تشخیص بدهد. روند آموزش و نتیجه آموزش به این صورت است:  
 (۱) **استخراج و دسته‌بندی عیوب:** پس از آموزش مدل‌ها، از آن‌ها برای پردازش تصاویر جدید و استخراج عیوب احتمالی مقررها استفاده می‌شود. سپس عیوب استخراج‌شده براساس نوع و شدت آن‌ها دسته‌بندی می‌شوند.

(۲) **تولید گزارش:** در نهایت، گزارشی از وضعیت مقررها به همراه تصاویر عیوب استخراج‌شده و دسته‌بندی آن‌ها به اپراتور خطوط انتقال برق ارائه می‌شود.

### ۲-۲-۲- ساختار مدل عمیق پیشنهادی

در این مقاله مدل یادگیری عمیق یولو ۸ در وظایف مختلف مورد استفاده قرار می‌گیرد. با توجه به تغییرات پس‌زمینه تصاویر با وجود مدل عمیق ذکر شده تشخیص و طبقه‌بندی تصاویر به خوبی صورت می‌گیرد. همچنین، با آموزش مدل یولو ۸، کادرهای برجسب‌گذاری مقرر برش داده شده و به‌عنوان داده جدیدی برای تشخیص دقیق‌تر عیوب کوچک برای مراحل بعد در این روند در نظر گرفته شده است. مدل یولو ۸ برای تشخیص اشیاء در تصاویر مقرر

جدول ۴: تعداد تصاویر مورد استفاده در آموزش مدل یولو قبل و بعد از افزودن داده در حالات مختلف با سه کلاس

نوع تصویر	وظیفه	کلاس	تعداد قبل از افزودن	تعداد تصاویر آموزش	تعداد تصاویر اعتبارسنجی	تعداد تصاویر تست	تعداد بعد از افزودن
سطوح خاکستری	تشخیص	سالم	۷۲۰	۱۳۷۰	۸۷	۱۷۱	۱۶۲۸
		شکستگی	۵۱	۱۱۱	۷	۶	۱۲۴
		آرک زدگی	۱۰۷	۱۱۳	۱۲	۲۵	۱۵۰
رنگی	تشخیص	سالم	۷۲۰	۱۳۱۳	۸۵	۱۴۹	۱۵۴۷
		شکستگی	۵۱	۹۸	۷	۶	۱۱۱
		آرک زدگی	۱۰۷	۱۲۹	۱۴	۴۷	۱۹۰
سطوح خاکستری	طبقه بندی	سالم	۱۶۰۱	۲۳۸۰	۲۲۷	۳۰۴	۲۹۱۱
		شکستگی	۸۸	۱۷۹	۱۱	۱۱	۲۰۱
		آرک زدگی	۲۲۹	۴۱۲	۳۲	۴۵	۴۸۹
رنگی	طبقه بندی	سالم	۱۶۰۱	۲۴۵۸	۲۲۷	۳۰۴	۲۹۸۹
		شکستگی	۸۸	۱۵۳	۱۱	۱۱	۱۷۵
		آرک زدگی	۲۲۹	۳۶۰	۳۲	۴۵	۴۳۷

در آن برای رسیدن به دقت بهتر انجام شد. پس از طراحی و آموزش مدل، باید مدل ارزیابی شود. این ارزیابی با استفاده از مجموعه داده‌های آزمایش انجام می‌شود تا دقت، صحت، و عملکرد کلی مدل در تشخیص عیوب مقره‌ها سنجیده شود. در صورت نیاز، مدل بهینه‌سازی و تنظیم مجدد می‌شود تا به بهترین عملکرد دست یابد. مدل یولو ۸ با سرعت زیاد و توانایی تشخیص همزمان عیوب مختلف در تصاویر بزرگ، برای پایش زمان واقعی و نگهداری پیشگیرانه مناسب است. بلوک دیاگرام روش پیشنهادی براساس مدل یولو ۸ در نگاره (۴) نشان داده شده است.

### ۲-۳-۱- مدل عمیق یولو ۸

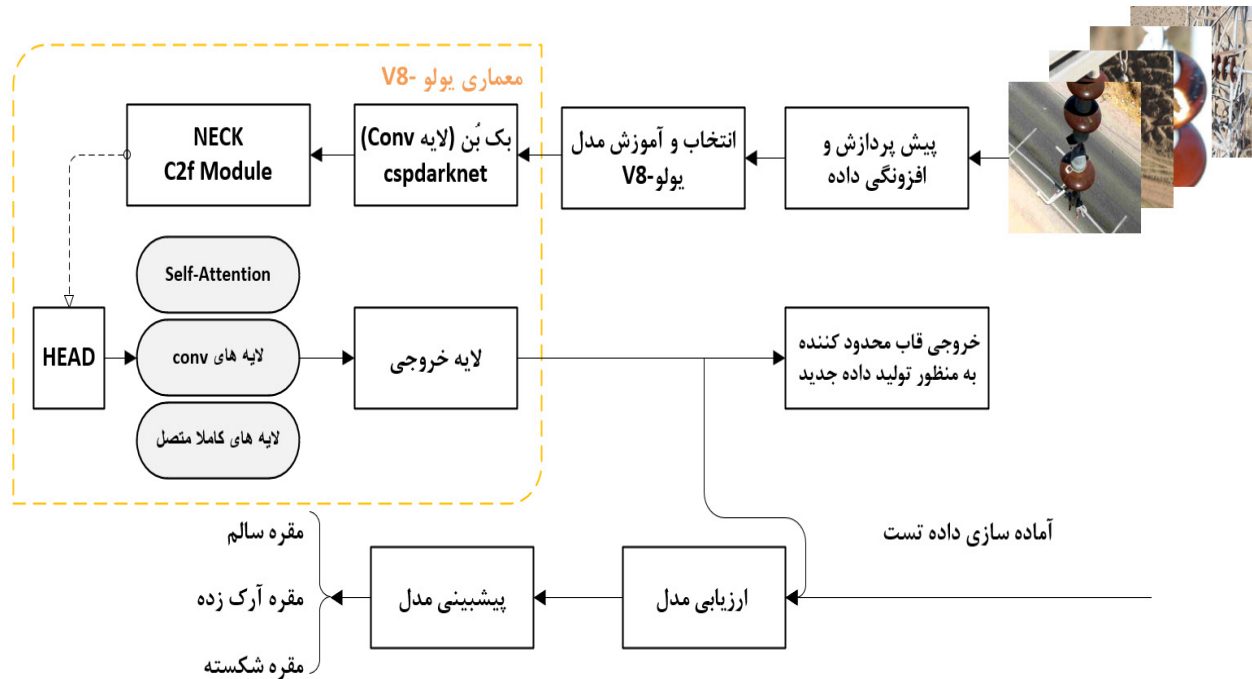
کتابخانه Ultralytics یک چارچوب منبع باز محبوب برای آموزش و استقرار مدل‌های تشخیص شیء مبتنی بر یولو ۸ است (Ultralytics, n.d.). این کتابخانه به دلیل سادگی استفاده، عملکرد بالا و مجموعه ویژگی‌های غنی، به انتخابی محبوب برای محققان و متخصصان یادگیری عمیق تبدیل

مجموعه تصاویر رنگی و سطوح خاکستری برای وظایف تشخیص و طبقه‌بندی با مدل یولو ۸ مورد استفاده قرار گرفت. جدول (۴) پایگاه داده با سه کلاس معرفی شده برای آموزش مدل را به همراه تعداد تصاویر هر کلاس گزارش می‌دهد.

### ۲-۳-۲ آموزش مدل عمیق یولو ۸

پس از جمع‌آوری و پیش‌پردازش تصاویر، باید مدل مناسب انتخاب و طراحی شود. طراحی معماری مدل شامل انتخاب تعداد و نوع لایه‌ها مانند لایه‌های پیچشی<sup>۱</sup>، تجمعی<sup>۲</sup> و به‌طور کامل متصل<sup>۳</sup>، و تنظیم هایپرپارامترها مانند نرخ یادگیری<sup>۴</sup> و اندازه دسته<sup>۵</sup> می‌شود. در آموزش مدل یولو ۸، با توجه به اندازه تصاویر پایگاه داده فرا پارامترهای مدل از جمله اندازه دو دسته به‌صورت تجربی و با ایجاد تغییرات

- 1- Convolutional layers
- 2- Cumulative layers
- 3- Fully connected
- 4- Learning rate
- 5- Batch size



نگاره ۴: بلوک دیاگرام روش پیشنهادی مبتنی بر به کارگیری مدل یولو ۸ در پایش خطوط انتقال برق با تصاویر پهپاد

بزرگتر می‌تواند منجر به آموزش سریع‌تر مدل شود، زیرا به مدل اجازه می‌دهد تا از اطلاعات بیشتری در هر به‌روزرسانی استفاده کند (Newton et al., 2018). با این حال، اندازه دسته بزرگتر می‌تواند به حافظه بیشتری نیز نیاز داشته باشد و ممکن است منجر به بیش‌برازش<sup>۲</sup> شود. به‌طور معمول، نرخ یادگیری مقدار کمی است که می‌تواند به مدل اجازه دهد تا به‌طور دقیق و با ثبات همگرا شود. نرخ یادگیری پایین می‌تواند از نوسانات بیش از حد در طول فرآیند آموزش جلوگیری نماید و به مدل کمک کند تا در حداقل‌های محلی گرفتار نشود (Yu & Zhu, 2020). در جدول (۵) فرآیندهای تعیین شده در روند آموزش گزارش داده شده‌اند. پیش‌پردازش داده‌ها نقشی اساسی در آموزش موفق رزنت ایفا می‌نماید. این روال شامل نرمال‌سازی داده‌ها، تغییر اندازه تصاویر و اعمال افزودنی داده به منظور افزایش تنوع مجموعه داده‌ها می‌شود. انتخاب بهینه‌ساز مناسب مانند آدام<sup>۳</sup> یا SGD<sup>۴</sup> می‌تواند بر سرعت و ثبات

شده است. همان‌طور که اشاره شد با خروجی پایگاه داده با فرمت یولو ۸ در این کتابخانه مدل یادگیری عمیق یولو ۸ برای تشخیص و طبقه‌بندی عیوب مقره به‌کار گرفته شده است. برچسب‌ها باید در قالب فایل‌های متنی با فرمت یولو ۸ باشند. فرمت یولو ۸ شامل اطلاعاتی مانند موقعیت و کلاس هر شیء در تصویر است. برای آموزش مدل از یک فایل پیکربندی که پارامترهای مدل را مشخص می‌نماید استفاده می‌شود. این پارامترها شامل اندازه تصویر، تعداد کلاس‌ها، تعداد بلوک‌های پیچشی و مسیرهای داده هست. لازم به ذکر است که آموزش مدل مذکور در چارچوب گوگل کولب صورت گرفته است.

## ۲-۳-۲- جزئیات شبیه‌سازی مدل عمیق در روش پیشنهادی

در روند آموزش مدل، اندازه دسته<sup>۱</sup> یکی از پارامترهای مهم در آموزش مدل‌های یادگیری عمیق، از جمله یولو ۸ است. این پارامتر تعداد نمونه‌هایی را که در هر به‌روزرسانی وزن مدل استفاده می‌شوند، تعیین می‌نماید. اندازه دسته

2- Over fitting

3- Adaptive moment estimation

4- Stochastic Gradient Descent

1- Batch size

جدول ۵: فرآپارامترهای تعیین شده در آموزش مدل یولو ۸

مدل	دوره	بهینه‌ساز	ابعاد دسته	ابعاد کرنل	نرخ یادگیری	تعداد لایه
یولو v8	۲۶۸/۱۰۰۰	SGD	۳۲	۳×۳	۱۰ <sup>-۲</sup>	۲۲۵
یولو v8-cls	۱۳۶/۱۰۰۰	SGD	۳۲	۳×۳	۱۰ <sup>-۲</sup>	۹۹

جدول (۶)، ابعاد کرنل و ابعاد ورودی تصاویر برای دو مدل یادگیری عمیق یولو ۸ را نشان می‌دهد (Ultralytics, n.d.).


جدول ۶: پیکربندی، ابعاد کرنل و لایه‌های عمیق، و تعداد کانال ویژگی برای مدل یولو ۸

لایه‌ها	ورودی لایه	ابعاد کرنل
Conv module	۳۲۰×۳۲۰×۶۴	[۳×۳]
CSP layer	۱۶۰×۱۶۰×۱۲۸	[۳×۳]
Conv module	۱۶۰×۱۶۰×۱۲۸	[۳×۳]
CSP layer	۸۰×۸۰×۲۵۶	[۳×۳]
Conv module	۸۰×۸۰×۲۵۶	[۳×۳]
CSP layer	۴۰×۴۰×۵۱۲	[۳×۳]
Conv module	۴۰×۴۰×۵۱۲	[۳×۳]
CSP layer	۲۰×۲۰×۵۱۲	[۳×۳]
Conv module	۲۰×۲۰×۵۱۲	[۳×۳]

### ۳- نتایج و ارزیابی مدل‌ها

در این بخش ارزیابی مدل آموزش داده شده برای تشخیص مقره‌ها و ارزیابی و پیش‌بینی بر روی مدل طبقه‌بندی یولو 8-CLS صورت می‌پذیرد. این ارزیابی با تنظیم بهترین وزن‌های آموزش مدل بر روی داده‌های مربوط به پیش‌بینی مدل یعنی تصاویری که مدل در حافظه خود آن‌ها را ندیده است، صورت می‌گیرد. به منظور ارزیابی عملکرد الگوریتم‌های مختلف طبقه‌بندی نقوص مقره، از معیارهای گوناگونی همچون دقت<sup>۲</sup> (Acc)، نرخ پیش‌بینی

همگرایی تأثیر بگذارد (Newton et al., 2018). همچنین مومنتوم<sup>۱</sup> نیز باید به دقت تنظیم شوند. کرنل ۳×۳ به دلیل توانایی در استخراج جزئیات کوچک، مانند ترک‌ها و علائم آرک‌زدگی، در تشخیص عیوب مقره‌ها مناسب است. این کرنل با کاهش تعداد پارامترها، سرعت آموزش و پردازش مدل را افزایش می‌دهد که برای تحلیل بلادرنگ تصاویر پهپادی اهمیت دارد. همچنین، به دلیل کارایی بالا و کاربرد گسترده در معماری‌های مدرن مانند یولو، VGG و ResNet به ایجاد شبکه‌های عمیق‌تر بدون افزایش نیاز محاسباتی کمک می‌کند و برای این پژوهش انتخاب مناسبی است. در آموزش مدل عمیق یولو ۸، انتخاب اندازه دسته مناسب موجب تعادل بین سرعت و دقت آموزش است. به طور کلی، اندازه دسته بزرگ‌تر منجر به آموزش سریع‌تر مدل می‌شود، اما ممکن است دقت را به خصوص برای مدل‌های بزرگ‌تر یا مجموعه داده‌های پیچیده‌تر کاهش دهد. از طرف دیگر، اندازه دسته کوچک‌تر می‌تواند منجر به آموزش کندتر مدل شود. اما ممکن است دقت را به خصوص برای مدل‌های کوچک‌تر یا مجموعه داده‌های ساده‌تر افزایش دهد. با توجه به شبیه‌سازی‌های تجربی صورت گرفته در این پژوهش در مورد اندازه دسته‌های مختلف بهترین مقدار برای دستیابی به دقت مورد انتظار در نظر گرفته شده است. ابعاد تصاویر ورودی در مدل یولو ۶۴۰×۶۴۰ است. عملکرد مدل‌های یادگیری عمیق می‌تواند به عوامل مختلفی از جمله معماری مدل، داده‌های آموزشی و هایپرپارامترها بستگی داشته باشد. در جدول (۵) فرآپارامترهای مدل‌های عمیق به کار گرفته شده مشاهده می‌شوند.



نگاره ۵: تصاویر خروجی آموزش و ارزیابی مدل یولو۸ در تشخیص کلاس‌های مفره

همان‌طور که قابل پیش‌بینی است، در کلاس آرک‌زدگی مفره تصاویر سطوح خاکستری تأثیر بیشتری در افزایش دقت مدل داشته است. همچنین، در کلاس شکستگی مفره نیز افزایش دقت در تشخیص مدل برجسته است. استفاده از تصاویر خاکستری برای پایش و تشخیص عیوب مفره‌ها در خطوط انتقال برق می‌تواند به دلایل متعددی منجر به نتایج بهتر و دقیق‌تری شود.

یکی از اصلی‌ترین این دلایل، کاهش پیچیدگی داده‌های ورودی است. تصاویر رنگی دارای سه کانال رنگ هستند که هر کدام حاوی اطلاعاتی متفاوت و گسترده‌ای از رنگ‌ها هستند.

مثبت (Ppr)، و فراخوانی<sup>۲</sup> (R) استفاده می‌شود (Heydarian et al., 2022). معیارهای به‌کار رفته در این مقاله برای مقایسه مدل‌های مختلف به صورت روابط (۱ تا ۳) تعریف می‌شوند.

$$\text{رابطه (۱)} \quad \text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

$$\text{رابطه (۲)} \quad \text{Ppr} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

$$\text{رابطه (۳)} \quad \text{Sen} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

که TP<sup>۳</sup> نشان‌دهنده تعداد موارد مثبت واقعی، TN<sup>۴</sup> تعداد موارد منفی واقعی، FP<sup>۵</sup> تعداد موارد مثبت کاذب و FN<sup>۶</sup> تعداد موارد منفی کاذب هستند. مقادیر بالاتر برای هر یک از این معیارها نشان‌دهنده عملکرد بهتر الگوریتم در طبقه‌بندی صحیح تصاویر ورودی و تشخیص درست است (Heydarian et al., 2022). به‌طور خاص، Acc نشان‌دهنده درصد کلی تشخیص‌های صحیح، Ppr توانایی الگوریتم در اجتناب از تشخیص نادرست مثبت، و Sen توانایی تشخیص موارد مثبت است. توازن میان Acc و Sen، تشخیص‌های مثبت را نشان می‌دهند (Heydarian et al., 2022). در نگاره (۵) خروجی مدل یولو۸ با هدف تشخیص نقص مفره‌ها ارائه شده است.

دقت تشخیص عیوب مفره‌ها توسط مدل عمیق یولو۸ با در نظر گرفتن دو کلاس و براساس تصاویر رنگی در جدول (۷) گزارش شده است. همچنین، در جدول (۸) نتایج با در اختیار گرفتن دو کلاس و تصاویر سطوح خاکستری مشاهده می‌شود. نتایج ارزیابی نشان می‌دهد که مدل یولو۸ توانسته است برای انجام وظایف تشخیص و طبقه‌بندی کلاس‌های مورد انتظار به دقت مطلوبی دست یابد. نتایج نشان می‌دهد آموزش مدل با پیش‌پردازش داده‌ها و تغییر از تصاویر رنگی به سطوح خاکستری در دو کلاس سالم و معیوب در تشخیص کلاس معیوب افزایش دقت مناسبی داشته است.

1- Positive Predictive Rate

2- Recall

3- True Positive

4- True Negative

5- False Positive

6- False Negative

جدول ۷: دقت مدل یولو و نتایج ارزیابی مدل یولو ۸ با دو کلاس تشخیص مفره سالم و مفره معیوب با استفاده از تصاویر رنگی

دقت ارزیابی (Cls-RGB)	دقت آموزش (Cls-RGB)	دقت ارزیابی (V8n- RGB)	دقت آموزش (V8n- RGB)	کلاس
--	--	٪۹۸/۱	٪۹۸/۱	سالم
--	--	٪۸۴/۹	٪۸۴/۹	معیوب
٪۹۸/۶	٪۹۸/۶	٪۹۱/۵	٪۹۱/۵	کل کلاس‌ها

جدول ۸: دقت مدل یولو ۸ در دو وظیفه تشخیص و طبقه‌بندی عیوب با دو کلاس تشخیص مفره سالم و مفره معیوب با استفاده از تصاویر سطوح خاکستری

دقت ارزیابی (Cls-RGB)	دقت آموزش (Cls-RGB)	دقت ارزیابی (V8n- RGB)	دقت آموزش (V8n- RGB)	کلاس
--	--	٪۹۷/۷	٪۹۷/۷	سالم
--	--	٪۸۷/۵	٪۸۷/۵	معیوب
٪۹۸/۹	٪۹۸/۹	٪۹۲/۶	٪۹۲/۶	کل کلاس‌ها

این امر می‌تواند باعث افزایش نويز و اطلاعات غیرضروری در تصاویر شود و یادگیری مدل را طولانی و پیچیده‌تر کند. در مقابل، تصاویر خاکستری تنها یک کانال دارند و فقط اطلاعات مربوط به شدت روشنایی را ذخیره می‌کنند، که این امر به کاهش نويز و تمرکز بیشتر مدل بر روی ویژگی‌های کلیدی مانند لبه‌ها، بافت‌ها و الگوهای موجود در تصویر کمک می‌کند. البته قابل ذکر است که در تصاویر سطوح خاکستری برخی از ویژگی‌های تصاویر رنگی از بین می‌روند و در سایر مدل‌ها برای استخراج ویژگی در تصاویر امکان کاهش دقت وجود دارد. همچنین، مفره‌ها و عیوب مرتبط با آن‌ها اغلب دارای تفاوت‌های برجسته‌ای در شدت روشنایی هستند که در تصاویر خاکستری به خوبی نمایان می‌شوند (Žeger & Grgić, 2020). از سوی دیگر، پردازش تصاویر خاکستری به منابع محاسباتی کمتری نیاز دارد و سرعت پردازش را افزایش می‌دهد. این کاهش پیچیدگی داده‌ها و تمرکز بر ویژگی‌های مهم، موجب افزایش دقت مدل‌های یادگیری عمیق در تشخیص و طبقه‌بندی عیوب می‌شود، همان‌طور که در این مطالعه نیز دقت بالاتری در استفاده از تصاویر خاکستری نسبت به تصاویر رنگی مشاهده شده است. همچنین نتایج دقت مدل با در اختیار گرفتن سه کلاس عیوب تفکیکی با نام مفره سالم، شکستگی مفره، و آرک‌زدگی مفره برای تصاویر رنگی و سطوح خاکستری در جداول (۹) و (۱۰) گزارش شده است.

جدول ۹: دقت مدل یولو ۸ در دو حالت تشخیص و طبقه‌بندی با سه کلاس با استفاده از تصاویر رنگی

دقت ارزیابی (Cls-RGB)	دقت آموزش (Cls-RGB)	دقت ارزیابی (V8n- RGB)	دقت آموزش (V8n- RGB)	کلاس
--	--	٪۹۷/۳	٪۹۷/۳	مفره سالم
--	--	٪۹۷/۸	٪۹۷/۸	شکستگی
--	--	٪۸۰/۹	٪۸۰/۹	آرک‌زده
٪۹۹/۲	٪۹۹/۲	٪۹۱/۹	٪۹۱/۹	کل کلاس‌ها

جدول ۱۰: دقت مدل یولو ۸ در دو حالت تشخیص و طبقه‌بندی با سه کلاس با استفاده از تصاویر سطوح خاکستری


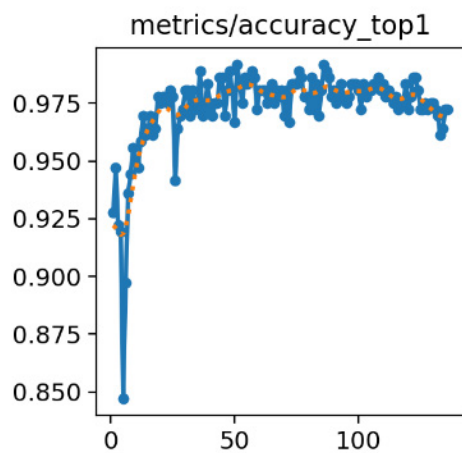
دقت ارزیابی (Cls-RGB)	دقت آموزش (Cls-RGB)	دقت ارزیابی (V8n- RGB)	دقت آموزش (V8n-RGB)	کلاس
--	--	٪۹۸	٪۹۸	مقره سالم
--	--	٪۹۹/۵	٪۹۹/۵	شکستی
--	--	٪۸۴/۳	٪۸۴/۳	آرک زده
٪۹۸/۶	٪۹۸/۶	٪۹۳/۹	٪۹۳/۹	کل کلاس‌ها

خطا باقی بمانند، مدل دچار برازش کم است. همچنین این منحنی‌ها به تنظیم هایپرپارامترها کمک می‌نمایند. به طور مثال اگر نمودار پیشرفت آموزش نوسانات زیادی داشته باشد، ممکن است نیاز به کاهش نرخ یادگیری باشد.

منحنی آموزش مدل یولو ۸ در نگاره (۶) مشاهده می‌شود که بر آموزش مناسب این مدل تأکید دارد. دقت این مدل‌های عمیق براساس پیش‌بینی و برچسب‌گذاری صحیح پس از آموزش مدل با توجه به ماتریس ابهام خروجی مدل یکی از معیارهای تعیین کارایی مدل است.

جدول (۱۱)، دقت پیش‌بینی کلاس‌ها به کمک مدل

منحنی آموزش مدل عمیق ابزاری کلیدی برای ارزیابی عملکرد و کارایی یک مدل یادگیری عمیق است. این منحنی شامل دو نمودار اصلی است: منحنی آموزش و منحنی اعتبارسنجی که تغییرات مقدار خطا یا دقت مدل در فرآیند یادگیری مدل را نشان می‌دهند. این منحنی‌ها به ارزیابی عملکرد مدل کمک می‌کنند و می‌توانند نشانه‌هایی از بیش‌برازش و کم‌برازش را نشان دهند (Yu & Zhu, 2020). اگر دقت مدل روی داده‌های آموزش افزایش یابد ولی روی داده‌های اعتبارسنجی کاهش یابد یا ثابت بماند، نشان‌دهنده بیش‌برازش است. اگر هر دو منحنی در مقادیر بالایی از



نگاره ۶: نمودار پیشرفت و ارزیابی مدل یولو ۸ در روال آموزش به منظور تشخیص کلاس‌های عیوب مقره. تصویر راست) نمودار مربوط به پیشرفت مدل برای شناسایی اهداف. تصویر چپ) نمودار مربوط به پیشرفت مدل در طبقه‌بندی کلاس‌های تعریف شده

تشخیص و تفکیک به صورت آبشاری به منظور تشخیص عیوب عایق‌های الکتریکی است مقایسه شده‌اند. این مقایسه در جدول (۱۴) گزارش شده است که به میزان دقت روش پیشنهادی براساس مقدار اختلافات درصد دقت حاصل شده در تشخیص نقص مقره‌ها در مقایسه با سایر روش‌ها تأکید دارد. در نگاره (۷) نمودار مقایسه نتایج روش پیشنهادی با (Li et al., 2020) و (Miao et al., 2019) به صورت آماری مشاهده می‌شود.

جدول ۱۴: نتایج تشخیص عیوب مقره‌ها در سناریوی پیشنهادی در مقایسه با سایر روش‌ها (منظور از نوع مقره ترکیبی تشخیص همزمان جنس‌های چینی و شیشه‌ای مقره‌ها هست)

روش	فراخوانی	صحت	دقت	نوع مقره
SSD	٪۸۷	٪۸۵/۲	٪۸۶/۷	ترکیبی
SSD	٪۹۰	٪۹۳/۷	٪۹۴/۱	چینی
یولو v3	٪۷۷/۵	٪۸۵/۵	٪۷۳/۴	چینی
FR-CNN	٪۹۱/۷	٪۹۷/۳	٪۹۰/۸	ترکیبی
یولو-۸ cls	٪۹۱	٪۱۰۰	٪۹۹/۲	ترکیبی
یولو ۸	٪۸۹/۷	٪۹۱	٪۹۳/۹	ترکیبی

دلایل عدم کارایی روش‌های مقایسه‌شده در این پژوهش به سه جنبه اصلی مربوط می‌شود: نخست، این روش‌ها در استخراج ویژگی‌های دقیق و جزئیات موضعی از تصاویر پهبادی دچار محدودیت هستند که برای تشخیص عیوب کوچک مقره‌ها حیاتی است، در حالی که مدل یولو ۸ به واسطه معماری عمیق خود این دقت را فراهم می‌کند. دوم، روش‌های مذکور در پردازش بلادرنگ و سریع تصاویر پهبادی ناکارآمد هستند، در حالی که مدل یولو ۸ بهینه‌سازی‌های لازم را برای تحلیل سریع‌تر ارائه می‌دهد. سوم، این روش‌ها در شرایط متغیر نور و زاویه‌های مختلف دچار کاهش دقت می‌شوند، در حالی که یولو ۸ پایداری بیشتری در مواجهه با این تغییرات از خود نشان می‌دهد. در نتیجه، روش پیشنهادی با بهره‌گیری از مدل یولو ۸ نانو، دقت

یولو ۸ را نشان می‌دهد. در جدول (۱۲)، ماتریس ابهام<sup>۱</sup> مدل یولو ۸ با وظیفه تشخیص مشاهده می‌شود (جدول ۱۳). در این بخش به منظور پی بردن به کارایی رویکرد پیشنهادی، نتایج حاصل با سایر روش‌های استفاده شده در این حوزه مانند روش (Miao et al., 2019) مقایسه شده است.

جدول ۱۱: دقت تشخیص مدل‌های عمیق در روش پیشنهادی به منظور تشخیص نوع نقص مقره

مدل عمیق	شکستگی	آرک زدگی	سالم	دقت
یولو ۸ نانو	٪۱۰۰	٪۷۹	٪۹۷	٪۹۲/۴
یولو-۸ cls	٪۹۱	٪۱۰۰	٪۹۹	٪۹۹/۲

جدول ۱۲: ماتریس ابهام مدل یولو ۸ با وظیفه تشخیص

برچسب/پیش‌بینی	آرک زدگی	شکستگی	سالم
آرک زدگی	٪۷۹	۰	۰
شکستگی	۰	٪۱۰۰	۰
سالم	٪۱/۴	۰	٪۹۷

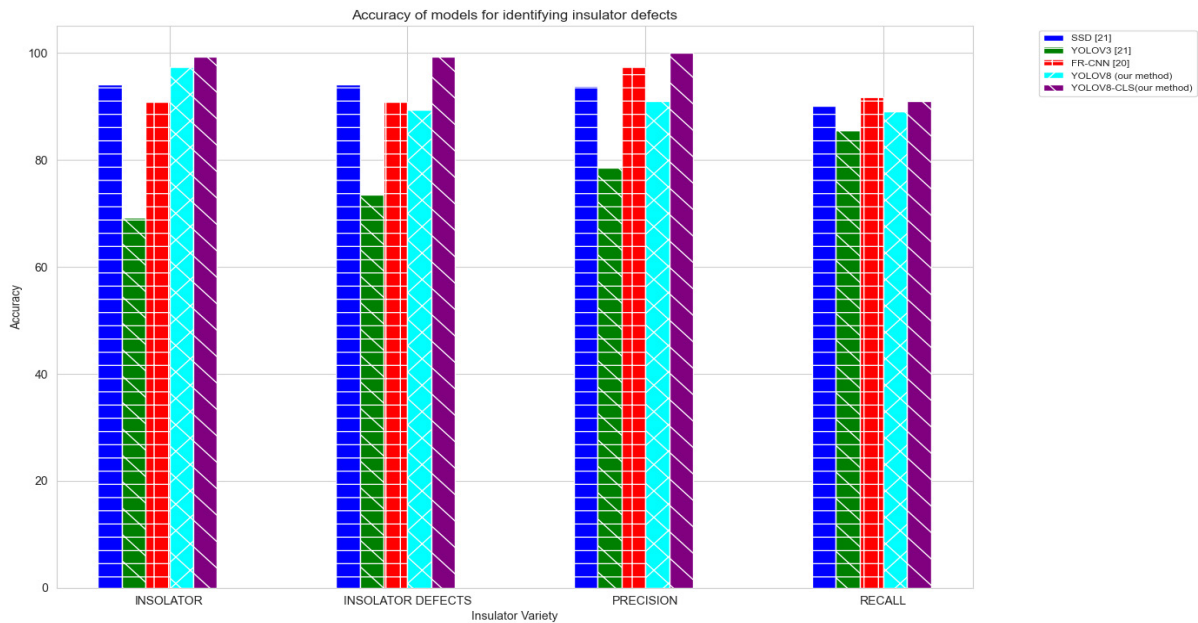
جدول ۱۳: ماتریس ابهام روش پیشنهادی مبتنی بر مدل یولو ۸ در جهت تشخیص صحیح هریک از کلاس‌ها با وظیفه طبقه‌بندی

برچسب/پیش‌بینی	آرک زدگی	شکستگی	سالم
آرک زدگی	٪۱۰۰	۰	۰
شکستگی	٪۹	٪۹۱	۰
سالم	۰	۰	٪۹۹

در این مقاله، با استفاده از SSD<sup>۲</sup>، آشکارساز تک‌شات چندکادری به‌عنوان یک معماری عمیق قدرتمند و به‌کارگیری استراتژی تنظیم دقیق دو مرحله‌ای در آن، نقص‌های مقره از جمله شکستگی و آرک زدگی تشخیص داده شده است. همچنین، نتایج در روش پیشنهادی با روال پیشنهادی (Li et al., 2020) که مبتنی بر ترکیب شبکه‌های

1- Confusion matrix

2- Single-Shot multibox Detector



#### نگاره ۷: نمودار مقایسه دقت مدل‌های مختلف و مدل یادگیری عمیق روش پیشنهادی در پایش مقره‌ها

با اختلال سیگنال ممکن است منجر به قطع ارتباط و سقوط پرنده یا از دست رفتن داده‌ها شود. در نهایت، محدودیت‌های قانونی و امنیتی در ایران نیز می‌تواند بر استفاده از فناوری پهباد تأثیر بگذارد. برای بهبود کارایی و دقت در پژوهش‌های آینده، نیاز به مدیریت و کاهش این محدودیت‌ها احساس می‌شود. در بخش پردازشی پژوهش، از مدل پیشرفته یادگیری عمیق، یعنی یولوو ۸ نانو به منظور تشخیص و طبقه‌بندی عیوب مقره‌ها استفاده شده است. نتایج به دست آمده نشان می‌دهد که مدل یولوو ۸ توانسته است با دقت ۹۳/۹٪ مقره‌ها را تشخیص دهد. همچنین، مدل با دقت ۹۹/۲٪ توانایی بالایی در طبقه‌بندی مقره‌های سالم و معیوب نشان داده است. استفاده از تصاویر پهباد و پردازش آن‌ها با استفاده از مدل‌های یادگیری عمیق، علاوه بر دقت قابل قبول، مزایای دیگری از جمله سرعت پردازش سریع، کاهش هزینه‌های عملیاتی و افزایش ایمنی را نیز به همراه دارد. تصاویر خاکستری در این پژوهش به دلیل کاهش پیچیدگی داده‌ها و تمرکز بیشتر بر روی ویژگی‌های کلیدی مانند لبه‌ها و بافت‌ها، نتایج بهتری نسبت به تصاویر

سرعت و انعطاف‌پذیری بیشتری برای پایش و تشخیص عیوب مقره‌ها در خطوط انتقال نیرو فراهم می‌آورد.

#### ۴- نتیجه‌گیری

روشی نوین برای پایش و تشخیص عیوب مقره‌های خطوط انتقال برق با استفاده از تصاویر پهباد و مدل‌های یادگیری عمیق ارائه شد. با توجه به اهمیت بالای مقره‌ها در عملکرد صحیح و پایدار شبکه‌های برق، پایش و تشخیص به موقع عیوب این تجهیزات حیاتی ضروری است. روش‌های سنتی پایش مقره‌ها غالباً زمان‌بر، پرهزینه و همراه با خطرات جانی هستند. این پژوهش در زمینه تشخیص و پایش عیوب مقره‌های خطوط انتقال برق با استفاده از پهباد و اخذ اطلاعات مورد نیاز با چالش‌هایی مواجه بوده که شامل این موارد می‌شود: محدودیت در مدت زمان پرواز به دلیل ظرفیت باتری و مصرف انرژی، کیفیت تصویربرداری، شرایط جوی نامساعد مانند باران و باد شدید که می‌تواند اجرای پروازها را محدود کند، مشکلات ارتباطی میان اپراتور و پهباد به‌ویژه در مناطقی

## References

- 1- Ahmed, F., Mohanta, J. C., & Keshari, A. (2024). Power Transmission Line Inspections: Methods, Challenges, Current Status and Usage of Unmanned Aerial Systems. *Journal of Intelligent & Robotic Systems*, 110(2), 54.
- 2- Alomar, K., Aysel, H. I., & Cai, X. (2023). Data augmentation in classification and segmentation: A survey and new strategies. *Journal of Imaging*, 9(2), 46.
- 3- Antwi-Bekoe, E., Zhan, Q., Xie, X., & Liu, G. (2020). Insulator recognition and fault detection using deep learning approach. *Journal of Physics: Conference Series*,
- 4- Bholra, R., Krishna, N. H., Ramesh, K., Senthilnath, J., & Anand, G. (2018). Detection of the power lines in UAV remote sensed images using spectral-spatial methods. *Journal of environmental management*, 206, 1233-1242.
- 5- Chang, R., Zhou, S., Zhang, Y., Zhang, N., Zhou, C., & Li, M. (2023). Research on insulator defect detection based on improved YOLOv7 and multi-UAV cooperative system. *Coatings*, 13(5), 880.
- 6- Hao, Z. (2019). Deep learning review and discussion of its future development. *MATEC Web of Conferences*,
- 7- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*,
- 8- Heydari, M., Doyle, T. E., & Samavi, R. (2022). MLCM: Multi-label confusion matrix. *IEEE Access*, 10, 19083-19095.
- 9- <https://github.com/ultralytics>.
- 10- <https://roboflow.com/>. <https://roboflow.com/>
- 11- Hu, H., Liu, Y., & Rong, H. (2022). Detection of insulators on power transmission line based on an improved faster region-convolutional neural network. *Algorithms*, 15(3), 83.
- 12- Hussain, M. (2023). YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection. *Machines*, 11(7), 677.
- 13- Jiang, P., Ergu, D., Liu, F., Cai, Y., & Ma, B. (2022). A Review of Yolo algorithm developments. *Procedia computer science*, 199, 1066-1073.
- 14- Lei, X., & Sui, Z. (2019). Intelligent fault detection

رنگی ارائه داده‌اند. این ویژگی‌ها موجب شده است که مدل‌های مورد استفاده بتوانند با دقت و کارایی بیشتری عیوب مقره‌ها را تشخیص دهند و به این ترتیب، پایداری و ایمنی شبکه‌های برق را بهبود بخشند.

## ۵- کارهای آینده

با توجه به نتایج مثبت این پژوهش، چندین مسیر برای تحقیقات آینده وجود دارد که می‌تواند به بهبود و گسترش روش پیشنهادی کمک کنند. افزایش حجم و تنوع داده‌های آموزشی با استفاده از تصاویر بیشتر از مناطق مختلف و تحت شرایط تصویربرداری متفاوت می‌تواند به بهبود دقت مدل‌ها کمک کند. بررسی استفاده از ترکیب مدل‌های مختلف یادگیری عمیق، مانند ترکیب یولو ۸ با سایر مدل‌های شبکه‌های عصبی کانولوشنی، می‌تواند منجر به افزایش دقت تشخیص شود. استفاده از پهپادها و دوربین‌های با کیفیت بالاتر و تکنولوژی‌های پیشرفته‌تر در تصویربرداری نیز می‌تواند به دستیابی به تصاویر دقیق‌تر و با وضوح بیشتر کمک کند. توسعه سامانه‌های پایش بلادرنگ با استفاده از پردازش سریع‌تر و انتقال داده‌ها به صورت بی‌درنگ، می‌تواند به افزایش کارایی و کاهش زمان واکنش به عیوب کمک کند. ترکیب تصاویر مرئی با تصاویر حرارتی و چندطیفی می‌تواند اطلاعات بیشتری درباره وضعیت مقره‌ها فراهم کرده و دقت تشخیص عیوب را افزایش دهد. در نهایت، ارزیابی عملیاتی و میدانی روش پیشنهادی در محیط‌های واقعی و در مقیاس بزرگ‌تر می‌تواند به تعیین قابلیت اطمینان و کارایی سیستم در شرایط عملی کمک کند.

## تعارض منافع

در این پژوهش، حامی مالی و تعارض منافع وجود ندارد.

- 23- Sadykova, D., Pernebayeva, D., Bagheri, M., & James, A. (2019). IN-YOLO: Real-time detection of outdoor high voltage insulators using UAV imaging. *IEEE Transactions on Power Delivery*, 35(3), 1599-1601.
- 24- Sampedro, C., Rodriguez-Vazquez, J., Rodriguez-Ramos, A., Carrio, A., & Campoy, P. (2019). Deep learning-based system for automatic recognition and diagnosis of electrical insulator strings. *IEEE Access*, 7, 101283-101308.
- 25- Silva, I., Spatti, D., Yoshizumi, V., Lopes, S., Flauzino, R., Tavares, B. D. L., Barquete, A. C., & Honorato, W. (2022). Condition Monitoring of Power Insulators Using Intelligent Techniques—A Survey. 2022 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC),
- 26- Wang, X., Gao, H., Jia, Z., & Li, Z. (2023). BL-YOLOv8: An improved road defect detection model based on YOLOv8. *Sensors*, 23(20), 8361.
- 27- Xu, C., Xin, M., Wang, Y., & Gao, J. (2023). Design and Implementation of Transmission Line Insulator Online Monitoring Platform Based on Image Analysis. *Journal of Physics: Conference Series*,
- 28- Yu, T., & Zhu, H. (2020). Hyper-parameter optimization: A review of algorithms and applications. *arXiv preprint arXiv:2003.05689*.
- 29- Žeger, I., & Grgić, S. (2020). An overview of grayscale image colorization methods. 2020 International Symposium ELMAR,
- of high voltage line based on the Faster R-CNN. *Measurement*, 138, 379-385.
- 15- Li, X., Su, H., & Liu, G. (2020). Insulator defect recognition based on global detection and local segmentation. *IEEE Access*, 8, 59934-59946.
- 16- Lin, Y.-T., & Kuo, C.-C. (2024). Real-Time Salt Contamination Monitoring System and Method for Transmission Line Insulator Based on Artificial Intelligence. *Applied Sciences*, 14(4), 1506.
- 17- Liu, Z., Wu, G., He, W., Fan, F., & Ye, X. (2022). Key target and defect detection of high-voltage power transmission lines with deep learning. *International Journal of Electrical Power & Energy Systems*, 142, 108277.
- 18- Miao, X., Liu, X., Chen, J., Zhuang, S., Fan, J., & Jiang, H. (2019). Insulator detection in aerial images for transmission line inspection using single shot multibox detector. *IEEE Access*, 7, 9945-9956.
- 19- Newton, D., Yousefian, F., & Pasupathy, R. (2018). Stochastic gradient descent: Recent trends. *Recent advances in optimization and modeling of contemporary problems*, 193-220.
- 20- Qiang, H., Tao, Z., Ye, B., Yang, R., & Xu, W. (2023). Transmission Line Fault Detection and Classification Based on Improved YOLOv8s. *Electronics*, 12(21), 4537.
- 21- Qiu, Z., Zhu, X., Liao, C., Shi, D., & Qu, W. (2022). Detection of transmission line insulator defects based on an improved lightweight YOLOv4 model. *Applied Sciences*, 12(3), 1207.
- 22- Reis, D., Kupec, J., Hong, J., & Daoudi, A. (2023). Real-time flying object detection with YOLOv8. *arXiv preprint arXiv:2305.09972*.

---

## COPYRIGHTS

©2025 by the authors. Published by National Geographical Organization. This article is an open access article distributed under the terms and conditions of the Creative Commons [Attribution-NoDerivs 4.0 International \(CC BY-ND 4.0\)](https://creativecommons.org/licenses/by-nd/4.0/)

