

Automated detection and classification of solar panel defects in UAV imagery using the YOLOv8m model

Mohammad Amin Safari¹ , Samira Mavaddati*²

1- MSc student, Faculty of engineering and technology, University of Mazandaran ,Babolsar, Iran, Email: mohammadaminsafaribusiness@gmail.com

2- (*Corresponding author) Associate professor, Faculty of engineering and technology, University of Mazandaran, Babolsar, Iran.
Email: s.mavaddati@umz.ac.ir

Article Info

Date of receive:

2025/06/23

Date of last review:

2025/11/02

Date of accept:

2025/11/02

Date of online publication:

2025/11/02

Keywords:

Defect detection,
Solar panels,
Deep learning,
YOLOv8m,
Machine vision,
Automated surveillance
systems,
Smart monitoring

Extended Abstract

Introduction

With the rapid global shift toward renewable energy sources, photovoltaic (PV) systems have emerged as a cornerstone for clean and sustainable power generation. Ensuring the optimal performance and long-term durability of these systems requires effective inspection and maintenance strategies. Solar panels are frequently exposed to harsh environmental factors such as dust, moisture, temperature variations, and mechanical stress, which can lead to various physical defects including cracks, hotspots, delamination, and surface contamination. If left undetected, these defects may significantly compromise the energy output and reduce the economic lifespan of the solar panel infrastructure.

Traditional inspection methods, such as manual visual inspection or infrared thermography, are often labor-intensive, expensive, and prone to inaccuracies due to human error and environmental interference. These limitations underscore the need for an automated, accurate, and scalable solution. This research presents a smart defect detection framework based on deep learning, leveraging the cutting-edge YOLOv8m model for accurate and real-time identification of defects in solar panels. In addition, spatial analysis techniques are integrated to investigate the geographic distribution of defects, aiding in the development of targeted and predictive maintenance policies.

Materials & Methods

The core of the proposed framework is the YOLOv8m (You Only Look Once version 8, medium variant) model, an advanced object detection architecture optimized for speed, accuracy, and efficiency.... ▶ Page 48

How to Cite:

Safari, M.A. Mavaddati, S. (2026). Automated detection and classification of solar panel defects in UAV imagery using the YOLOv8m model. Scientific -Research Quarterly Geographical Data (SEPEHR). 34(136), 47-75.

YOLOv8m is known for its compact design and superior performance, making it suitable for deployment in real-time monitoring systems.

A curated dataset was constructed for training and evaluation, consisting of both colored (RGB) and grayscale images of solar panels collected under various illumination conditions, angles, and environmental settings. The images were annotated to highlight six prevalent types of defects observed in real-world installations: cracks, hot spots, delamination, bird droppings, dirt patches, and broken glass.

To improve the model's robustness and generalization capability, several data augmentation techniques were applied, such as random flipping, rotation, brightness variation, and Gaussian noise injection. Hyperparameter tuning was conducted to optimize learning rates, batch sizes, and anchor box dimensions. The model was trained using a transfer learning approach with pre-trained weights on the COCO dataset and fine-tuned on the specific solar panel defect dataset.

Furthermore, to extract spatial insights, the metadata embedded within the image files—such as GPS coordinates and timestamps—was utilized. This data was combined with the defect detection results to perform spatial clustering and distribution mapping using GIS-based tools and statistical analysis techniques.

Results & Discussion

The proposed YOLOv8m model achieved impressive results across several performance metrics. The model recorded a mean average accuracy (mAP) of 97.43%, a precision score of 97%, and a recall rate of 97.58% in detecting and classifying the six identified defect types. These values were consistently higher than those of traditional deep learning models such as Convolutional Neural Networks (CNN), VGG16, and ResNet50, which served as baseline comparisons. Specifically, the YOLOv8m framework demonstrated a relative improvement of 1.5% to 3.5% in detection accuracy over the baseline models, highlighting its effectiveness in handling complex visual scenarios.

Qualitative analysis further supported these results, with the YOLOv8m model accurately localizing defects with tight bounding boxes and minimal false positives. The lightweight nature of the architecture enabled near real-time inference on standard GPU hardware, making it viable for deployment in field conditions.

The integration of spatial analysis added a novel dimension to the defect detection task. By correlating the defect locations with their geographic coordinates, patterns such as defect clustering in specific panel zones or environmental exposure zones were identified. These patterns suggested that external factors like shading from nearby objects, accumulation of debris, or exposure to extreme weather conditions could contribute to defect formation. Such insights can be used to develop location-specific maintenance protocols or preventive interventions, thereby improving the overall health and longevity of the solar panel infrastructure.

Conclusion

This research introduces a comprehensive and scalable framework for intelligent detection of solar panel defects, built on the robust and efficient YOLOv8m architecture. The system not only offers high accuracy and real-time performance but also incorporates spatial intelligence for deeper understanding of defect trends and propagation. Its performance superiority over conventional models and its operational feasibility position it as a powerful tool for smart solar farm management.

By facilitating early diagnosis and enabling condition-based maintenance, the proposed framework contributes to reducing operational costs, extending the service life of solar panels, and enhancing the efficiency of photovoltaic systems. Moreover, the integration of machine vision and spatial analytics bridges the gap between technical diagnostics and actionable maintenance strategies, paving the way for smarter and more sustainable energy infrastructures.



صفحات ۷۵ - ۴۷

فصلنامه علمی - پژوهشی

اطلاعات جغرافیایی (سپهر) دوره ۳۴، شماره ۱۳۶، زمستان ۱۴۰۴



مقاله پژوهشی

doi <https://doi.org/10.22131/sepehr.2025.2064007.3145>

تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از مدل یولو V8m در تصاویر پهپادی

محمدامین صفری^۱، سمیرا مودتی*^۲۱- دانشجوی کارشناسی ارشد مهندسی برق، دانشکده مهندسی و فناوری، دانشگاه مازندران، بابلسر، ایران mohammadaminsafaribusiness@gmail.com۲- دانشیار گروه مهندسی برق، دانشکده مهندسی و فناوری، دانشگاه مازندران، بابلسر، ایران s.mavaddati@umz.ac.ir

چکیده

در سال‌های اخیر، نگهداری و پایش خودکار پنل‌های خورشیدی به‌عنوان یکی از ارکان حیاتی در توسعه پایدار انرژی‌های تجدیدپذیر اهمیت فزاینده‌ای یافته است. در این پژوهش، یک چارچوب دقیق و کارآمد مبتنی بر یادگیری عمیق برای طبقه‌بندی خودکار عیوب پنل‌های خورشیدی ارائه شده است. مدل پیشنهادی با بهره‌گیری از معماری یولو V8m، پیاده‌سازی شده است. این مدل با ساختاری سبک و مدرن قادر است تصاویر ورودی را به سرعت پردازش نموده و نوع عیب موجود در هر تصویر را با دقت بالا تعیین کند. برای آموزش و ارزیابی مدل، مجموعه داده‌ای جامع شامل تصاویر رنگی و خاکستری از پنل‌های خورشیدی تحت شرایط نوری و محیطی مختلف مورد استفاده قرار گرفت. نوآوری این پژوهش در به‌کارگیری معماری پیشرفته یولو V8m برای توسعه یک سامانه عملیاتی و دقیق در شناسایی و طبقه‌بندی خودکار عیوب متنوع پنل‌های خورشیدی در تصاویر پهپادی است. نتایج تجربی نشان می‌دهند که مدل یولو V8m توانسته در طبقه‌بندی شش نوع عیب رایج پنل‌های خورشیدی تمیز، پوشیده با برف، پوشیده با گرد و غبار، آلوده به فضولات پرندگان، دارای آسیب الکتریکی، و دارای آسیب فیزیکی به میانگین دقت ۹۷/۴۳٪، میانگین دقت پیش‌بینی برابر ۹۷٪، و میانگین نرخ بازیابی برابر ۹۷/۵۸٪ دست یابد. این نتایج نسبت به مدل‌های پایه مانند VGG16، CNN و رزنت ۵۰ به‌طور میانگین بین ۱/۵ تا ۳/۵ درصد بهبود عملکرد نشان می‌دهند. افزون بر آن، با طراحی چارچوبی هوشمند بر پایه مدل یولو V8m، الگوی شناسایی و طبقه‌بندی عیوب به گونه‌ای بهینه‌سازی شد که امکان پردازش سریع و دقیق تصاویر در شرایط واقعی و در مقیاس وسیع فراهم شود. این سامانه، علاوه بر دقت بالا در تفکیک نوع عیوب، قابلیت پیاده‌سازی عملیاتی در سامانه‌های نظارتی خودکار را دارد و می‌تواند نقش مؤثری در نگهداری پیش‌بینانه و بهینه‌سازی زمان‌بندی تعمیرات ایفا نماید. استفاده از این راهکار می‌تواند به افزایش عمر مفید پنل‌ها، کاهش هزینه‌های تعمیر و نگهداری، و بهبود عملکرد کلی شبکه‌های انرژی خورشیدی کمک کند.

اطلاعات مقاله

تاریخ دریافت:

۱۴۰۴/۰۴/۰۲

تاریخ آخرین بازنگری:

۱۴۰۴/۰۸/۱۱

تاریخ پذیرش:

۱۴۰۴/۰۸/۱۱

تاریخ انتشار:

۱۴۰۴/۰۸/۱۱

واژه‌های کلیدی:

تشخیص عیب؛

پنل خورشیدی؛

یادگیری عمیق؛

یولو V8m؛

بینایی ماشین؛

سامانه‌های نظارتی

خودکار؛

پایش هوشمند

استناد به این مقاله:

صفری، م. الف؛ مودتی، س (۱۴۰۴) تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از مدل یولو V8m در تصاویر پهپادی؛ فصلنامه علمی پژوهشی اطلاعات جغرافیایی (سپهر)، ۳۴ (۱۳۶)، ۷۵ - ۴۷.

۱- مقدمه

در سال‌های اخیر، استفاده از سامانه‌های فتوولتائیک (پنل‌های خورشیدی) به‌عنوان یکی از منابع اصلی تولید انرژی تجدیدپذیر، رشد چشم‌گیری داشته است. عملکرد بهینه این سامانه‌ها به وضعیت فیزیکی و سلامت پنل‌ها وابسته است؛ به‌گونه‌ای که بروز آسیب‌هایی همچون ترک‌خوردگی، لکه‌های داغ^۱، تجمع گرد و غبار، یا شکست ساختاری می‌تواند منجر به کاهش شدید راندمان تولید انرژی شود (Liang et al., 2024; Yang et al., 2024). با توجه به گسترش استفاده از پنل‌های خورشیدی در ابعاد صنعتی و گسترده، نیاز به روش‌های خودکار و هوشمند برای پایش و تشخیص عیوب در این تجهیزات بیش از پیش احساس می‌شود. روش‌های سنتی بررسی و نگهداری اغلب وقت‌گیر، پرهزینه و وابسته به نیروی انسانی هستند، و قابلیت به‌کارگیری گسترده یا عملکرد در زمان واقعی را ندارند (Singh et al., 2024; Pandey & Dhavale, 2024). از این‌رو، در پژوهش حاضر، تمرکز اصلی بر مدل‌های یادگیری عمیق به‌عنوان ابزارهای قدرتمند در حوزه پردازش تصویر و بینایی ماشین قرار گرفته است. لازم به ذکر است که در این مقاله صرفاً به روش‌های مبتنی بر یادگیری عمیق پرداخته می‌شود و سایر روش‌های سنتی یا کلاسیک مانند روش‌های مبتنی بر آستانه‌گذاری، ویژگی‌های دستی یا الگوریتم‌های یادگیری ماشین کلاسیک مورد بررسی قرار نگرفته‌اند. در سال‌های اخیر، پژوهش‌های متعددی در زمینه تشخیص خودکار عیوب پنل‌های خورشیدی با استفاده از مدل‌های یادگیری عمیق انجام شده است. در ادامه، برخی از این مطالعات مرور می‌شوند:

در مطالعه (Zyout & Oatawneh, 2020)، روشی مبتنی بر یادگیری انتقالی و شبکه عصبی کانولوشنی عمیق^۲ (CNN) برای تشخیص خودکار عیوب سطح پنل‌های خورشیدی توسعه داده شده است. در این روش، با اصلاح لایه‌های

انتهایی مدل پیش‌آمخته AlexNet، دسته‌بندی پنل‌های معیوب و سالم با دقت مناسب انجام شده و ضمن کاهش پیچیدگی آموزش، امکان توسعه سیستم در مقیاس‌های بزرگ فراهم شده است. نویسندگان همچنین به ضرورت استفاده از داده‌های واقعی و مکان‌محور در مراحل بعدی اشاره کرده‌اند. در پژوهش (Shafiei et al., 2023)، چارچوبی مؤثر مبتنی بر یادگیری عمیق و ترکیب تصاویر الکترولومینسانس^۳ (EL)، شبکه‌های CNN و درخت تصمیم برای تشخیص عیب پیشنهاد شده است، اما تمرکز آن صرفاً بر طبقه‌بندی دودویی (معیوب/سالم) بوده و دسته‌بندی انواع عیب‌ها مورد بررسی قرار نگرفته است. در مطالعه (Song & Liu, 2023)، روشی بر پایه Dense U-Net برای شناسایی عیوبی نظیر سایه و ترک‌های ریز در مراحل مختلف تولید پنل‌های خورشیدی ارائه شده است. بهره‌گیری از اتصالات متراکم موجب بهبود انتشار ویژگی‌ها و جلوگیری از ناپدید شدن گرادیان‌ها شده، اما مسئله تفکیک انواع عیب به‌صورت مجزا همچنان مورد توجه قرار نگرفته و محدودیت‌هایی در دقت تشخیص نیز باقی مانده است. مطالعه (Balcioglu et al., 2023) یک شبکه CNN عمیق جدید برای تشخیص عیوب در سلول‌های خورشیدی با پس‌زمینه‌های پیچیده (نظیر خطوط باس‌بار و انگشتی) معرفی کرده است. با تغییرات ساختاری در عمق و عرض شبکه، معماری بهینه‌ای طراحی شده که توانایی تمایز دقیق بین ساختار و عیب را افزایش داده و با دقت ۸۰/۸۵٪ از روش‌های سنتی و دستی پیشی گرفته است. در پژوهش (Li et al., 2023)، مدلی بهبود یافته بر پایه یولو V5^۴ همراه با ماژول توجه^۵ CBAM معرفی شده است که توانایی تشخیص پنج نوع عیب متداول شامل ترک‌های پنهان، خراش، شکست شبکه، لکه سیاه و اتصال کوتاه را دارد. این مدل برخلاف بسیاری از پژوهش‌های پیشین، مسئله طبقه‌بندی چندکلاسه را مورد هدف قرار داده و بر روی داده‌های واقعی و عمومی عملکرد مطلوبی نشان داده است.

3- Electroluminescence

4- You Only Look Once, Version 5

5- Convolutional Block Attention Module

1- Hot Spots

2- Convolutional Neural Network

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (ص ۵۱)

تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از ... / ۵۱

در سلول‌های خورشیدی پلی‌کریستالین طراحی شده است. این مدل با بهینه‌سازی در لایه‌های پایین‌نمونه‌بردار، ترکیب ویژگی و سرهای تشخیص، به mAP برابر با ۸۸/۸۱٪ و سرعت پردازش ۶۹ فریم بر ثانیه رسیده که آن را برای کاربردهای بلادرنگ مناسب می‌کند. در تحقیق (Lakshmi et al., 2024)، یک شبکه CNN با پیچیدگی پایین برای محیط‌های دارای محدودیت منابع سخت‌افزاری توسعه داده شده که با استفاده از ویژگی‌های یک‌بعدی توانسته به دقت تشخیص ۹۸٪ در عیب‌یابی پنل‌ها دست یابد. در پژوهش (Basheer et al., 2024)، از مدل یولو V5 برای تشخیص خودکار عیوب در مزارع خورشیدی در مقیاس بزرگ استفاده شده است. این سیستم ابتدا نواحی شامل دو پنل را شناسایی کرده و سپس به تشخیص جزئیات عیوب می‌پردازد. مدل موفق شده است به دقت ۹۴۷٪، بازیابی ۹۶۸٪ و mAP50 برابر با ۹۸۹٪ دست یابد. همچنین در مطالعه (Abdelsattar et al., 2025)، ارزیابی گسترده‌ای از ۲۴ معماری مختلف CNN شامل رزنت، VGG، DenseNet، Xception، MobileNet، Inception در آن مدل‌های سبک نظیر MobileNetV2 با دقت ۹۹/۹۵٪ و Xception با ۹۹/۲۹٪ عملکرد بسیار موفقی در تشخیص دودویی عیوب پنل‌ها از خود نشان داده‌اند.

با توجه به گسترش استفاده از مدل‌های یادگیری عمیق در حوزه پایش و تشخیص عیوب پنل‌های خورشیدی، مطالعات متعددی در سال‌های اخیر انجام شده‌اند که هر یک با بهره‌گیری از معماری‌های مختلف و تکنیک‌های پردازش تصویر، به دنبال بهبود دقت، سرعت و پایداری سیستم‌های تشخیص خودکار بوده‌اند. در این پژوهش، یک چارچوب تشخیص خودکار عیوب پنل‌های خورشیدی بر اساس مدل عمیق یولو V8 پیشنهاد شده است. مدل پیشنهادی با استفاده از معماری پیشرفته یولو V8 و بهره‌گیری از تکنیک‌های تنظیم دقیق^۱، بر روی یک مجموعه داده واقعی شامل تصاویر RGB آموزش دیده و قادر است شش نوع عیب رایج در

در ادامه، مقاله (Huang et al., 2023) مدلی تقویت‌شده از یولو V5 ارائه داده که با افزودن سازوکار توجه مختصات^۱ (LCA)، هرم ویژگی دوپرفه و سر تشخیص جداشده، دقت مدل را به میزان چشمگیری بهبود داده است. در این روش^۲ mAP برابر با ۹۵/۵٪، افزایش دقت ۱/۵٪ و بازیابی ۲/۴٪ است. مطالعه (Lu et al., 2023) نیز نسخه بهینه‌سازی‌شده‌ای از یولو V5 را معرفی کرده است که با به‌کارگیری پنج روش افزایش داده شامل HSV، Mixup، Mosaic، تغییر مقیاس و وارون‌سازی، سازوکار توجه مختصات و ساختار جداسازی تشخیص، موفق شده در دو مجموعه داده دودویی و PVEL-AD به ترتیب mAP برابر با ۹۶/۱۰٪ و ۸۷/۴۰٪ کسب کند که نسبت به مدل پایه یولو V5 حدود ۱۰/۳۸٪ بهبود عملکرد دارد. مطالعه مروری (Hijjawi et al., 2023) روش‌های تشخیص عیوب پنل‌های فتوولتائیک را در دو دسته اصلی شامل تکنیک‌های تصویربرداری مانند تصویربرداری مادون قرمز و الکترومینسانس و آزمون‌های الکتریکی نظیر منحنی جریان-ولتاژ بررسی نموده و نقش پردازش دیجیتال و یادگیری ماشین را در بهبود این روش‌ها تحلیل کرده است. در پژوهش (Mahmud et al., 2023)، از معماری‌های VGG16 و VGG19 برای تشخیص خودکار عیوبی نظیر ترک، گردوغبار و فضولات پرندگان استفاده شده و ارزیابی تطبیقی این دو معماری نشان داده که دقت بالایی در تشخیص انواع مختلف عیب در داده‌های دیده‌نشده دارند. در مقاله (Aktouf et al., 2024)، مدل یولو V10 برای شناسایی ۱۲ نوع مختلف عیب در تصاویر سلول‌های خورشیدی معرفی شده است. این مدل با بهره‌گیری از ماژول‌های بلوک اطلاعات زمینه‌ای^۳ و CIB و توجه فضایی نقطه‌ای^۴ PSA و آموزش روی دیتاستی با بیش از ۱۰۵۰۰ تصویر، توانسته دقت برابر با ۹۸/۵۰٪ و دقت نهایی ۱۰۰٪ در برخی عیوب خاص کسب کند. مدل ASDD-Net در مطالعه (Liu et al., 2024) برای تشخیص عیوب

1- Location Coordinate Attention

2- Mean Average Precision

3- Hue – Saturation – Value

4- Context Information Block

5- Point-wise Spatial Attention

6- Fine-tuning

پنل‌های خورشیدی را به‌طور دقیق شناسایی و طبقه‌بندی کند. تحقیقات پیشین عمدتاً از نسخه‌های قدیمی‌تر مدل‌های یولو مانند یولو V4 و یولو V5 استفاده کرده‌اند که محدودیت‌هایی از نظر دقت، سرعت و قابلیت استقرار در شرایط واقعی دارند. همچنین بسیاری از این مطالعات بر طبقه‌بندی دودویی (سالم/معیوب) تمرکز داشته‌اند یا برای تشخیص عیوب از تصاویر تخصصی و پرهزینه مانند الکترو لومینسانس بهره برده‌اند. در مقابل، روش پیشنهادی ما با بهره‌گیری از معماری پیشرفته و سبک یولو V8m، قادر به طبقه‌بندی شش نوع عیب رایج بر اساس تصاویر RGB ساده و در شرایط واقعی است و ضمن حفظ سرعت بالا، امکان استقرار آسان در سامانه‌های نظارتی صنعتی را فراهم می‌کند.

در میان نسخه‌های اخیر شبکه‌های یولو، معماری یولو V8m به دلیل توازن مناسب میان دقت و سرعت پردازش، گزینه‌ای کارآمد برای داده‌های پهبادی محسوب می‌شود. در حالی که مدل‌های جدیدتری نظیر یولو V10 معرفی شده‌اند، تمرکز اصلی این پژوهش بر قابلیت‌های عملیاتی و پیاده‌سازی‌پذیری در شرایط واقعی بوده است. نوآوری این تحقیق نه صرفاً در به‌کارگیری یولو V8m، بلکه در توسعه یک چارچوب هوشمند مبتنی بر آن برای شناسایی خودکار شش نوع عیب رایج پنل‌های خورشیدی در شرایط نوری و محیطی متنوع است؛ موضوعی که کمتر در پژوهش‌های پیشین مورد توجه قرار گرفته است. نوآوری‌های اصلی این تحقیق عبارتند از:

- استفاده از یک مجموعه داده عمومی و واقعی با تنوع بالا و طبقه‌بندی شش‌گانه: برخلاف مطالعاتی که صرفاً به طبقه‌بندی دودویی (عیب‌دار/سالم) پرداخته‌اند، این پژوهش از یک دیتاست جامع شامل شش کلاس واقعی (آلودگی، زباله، برف، فضله پرندگان، آسیب مکانیکی و آسیب الکتریکی) استفاده می‌کند که به بررسی دقیق‌تر و کاربردی‌تر شرایط عملیاتی کمک می‌کند.

- به‌کارگیری یادگیری انتقالی^۱ برای افزایش دقت و کاهش هزینه محاسباتی: با استفاده از وزن‌های اولیه از پیش آموزش دیده شده بر روی مجموعه داده COCO^۲ و تطبیق آن با داده‌های عیب‌یابی پنل، مدل با سرعت بیشتری همگرا شده و عملکرد بهتری در تشخیص عیوب کمتر مشاهده شده از خود نشان داده است.

- استفاده از تکنیک‌های افزودنی داده^۳ برای بهبود تعمیم‌پذیری مدل: با بهره‌گیری از روش‌هایی مانند چرخش، مقیاس‌دهی، برش تصادفی، و تغییرات رنگی، مقاومت مدل

پنل‌های خورشیدی را به‌طور دقیق شناسایی و طبقه‌بندی کند. تحقیقات پیشین عمدتاً از نسخه‌های قدیمی‌تر مدل‌های یولو مانند یولو V4 و یولو V5 استفاده کرده‌اند که محدودیت‌هایی از نظر دقت، سرعت و قابلیت استقرار در شرایط واقعی دارند. همچنین بسیاری از این مطالعات بر طبقه‌بندی دودویی (سالم/معیوب) تمرکز داشته‌اند یا برای تشخیص عیوب از تصاویر تخصصی و پرهزینه مانند الکترو لومینسانس بهره برده‌اند. در مقابل، روش پیشنهادی ما با بهره‌گیری از معماری پیشرفته و سبک یولو V8m، قادر به طبقه‌بندی شش نوع عیب رایج بر اساس تصاویر RGB ساده و در شرایط واقعی است و ضمن حفظ سرعت بالا، امکان استقرار آسان در سامانه‌های نظارتی صنعتی را فراهم می‌کند.

در میان نسخه‌های اخیر شبکه‌های یولو، معماری یولو V8m به دلیل توازن مناسب میان دقت و سرعت پردازش، گزینه‌ای کارآمد برای داده‌های پهبادی محسوب می‌شود. در حالی که مدل‌های جدیدتری نظیر یولو V10 معرفی شده‌اند، تمرکز اصلی این پژوهش بر قابلیت‌های عملیاتی و پیاده‌سازی‌پذیری در شرایط واقعی بوده است. نوآوری این تحقیق نه صرفاً در به‌کارگیری یولو V8m، بلکه در توسعه یک چارچوب هوشمند مبتنی بر آن برای شناسایی خودکار شش نوع عیب رایج پنل‌های خورشیدی در شرایط نوری و محیطی متنوع است؛ موضوعی که کمتر در پژوهش‌های پیشین مورد توجه قرار گرفته است. نوآوری‌های اصلی این تحقیق عبارتند از:

- در این پژوهش، برخلاف بسیاری از مطالعات پیشین که عمدتاً از نسخه‌های قدیمی‌تر یولو مانند یولو V4 یا یولو V5 استفاده کرده‌اند، از مدل یولو V8m بهره گرفته شده است. این نسخه جدیدتر با معماری سبک‌تر، بهینه‌تر و سریع‌تر همراه است و از ماژول‌های نوین مانند C2f و سر تشخیص Anchor-free بهره می‌برد. این ویژگی‌ها به طور قابل توجهی مقاومت مدل را در برابر نویزهای زمینه افزایش داده، دقت تشخیص عیوب کوچک و مخفی را بهبود می‌بخشند و امکان

1- Transfer Learning

2- Common Objects in Context

3- Data Augmentation

موجود در این دیتاست به صورت RGB و از زوایا و شرایط نوری مختلف ثبت شده‌اند که تنوع مناسبی برای آموزش مدل‌ها فراهم می‌کنند و چالش‌هایی نظیر نور زیاد، سایه‌ها، پس‌زمینه‌های پیچیده و تغییرات اقلیمی را در بر می‌گیرند. هدف اصلی از استفاده از این مجموعه داده، ارزیابی توانایی مدل‌های یادگیری ماشین و به‌ویژه مدل‌های یادگیری عمیق در شناسایی و طبقه‌بندی انواع عیوب رایج در پنل‌های خورشیدی است. این مجموعه داده شامل تصاویری واقعی و رنگی از سطح پنل‌های خورشیدی در شرایط نوری و محیطی مختلف می‌شود و بر پایه داده‌های جمع‌آوری شده از منابع متنوع در فضای باز طراحی شده است. برخلاف برخی مطالعات که به تصاویر تخصصی نظیر الکترو لومینسانس وابسته هستند، در این تحقیق از تصاویر مرئی (RGB) معمول استفاده شده که شرایطی نزدیک به محیط‌های واقعی صنعتی و عملیاتی دارند (PythonAfroz, n.d). این مجموعه داده دارای شش کلاس اصلی است که هر کدام نمایانگر یک وضعیت یا نوع عیب خاص در پنل‌های خورشیدی هستند. دسته اول، تمیز^۳، مربوط به پنل‌های سالم و بدون هیچ‌گونه عیب یا آلودگی است که به عنوان مرجع (مرجع مثبت) برای تشخیص سایر وضعیت‌ها مورد استفاده قرار می‌گیرد. این تصاویر معمولاً شفاف، یکنواخت و بدون انسداد سطحی هستند. دسته دوم، پوشیده با گرد و غبار^۴، به پنل‌هایی اشاره دارد که در معرض گرد و غبار قرار گرفته‌اند. انباشت ذرات ریز گرد و غبار می‌تواند جذب نور را کاهش داده و باعث افت محسوس در راندمان تولید برق شود. کلاس پوشیده با برف^۵ شامل تصاویری از پنل‌هایی است که به صورت جزئی یا کامل توسط برف پوشیده شده‌اند؛ این وضعیت به‌ویژه در مناطق سردسیر رایج بوده و چالش مهمی برای عملکرد بهینه پنل‌ها محسوب می‌شود.

در دسته آلوده با فضولات پرندگان^۶، پنل‌هایی که سطح

نسبت به تغییرات نوری، زاویه دید و پیچیدگی‌های ظاهری به‌طور چشمگیری افزایش یافته است.

• با بهره‌گیری از ساختار مؤثر یولو V8 شامل لایه C2f و مکانیزم ادغام مؤثر لایه‌ها، مدل پیشنهادی قادر است به‌صورت هم‌زمان ویژگی‌های سطح پایین و بالا را استخراج کرده و دقت شناسایی عیوبی چون ترک‌های ریز یا فضله‌پرنندگان را افزایش دهد. این چارچوب، بدون نیاز به تجهیزات پیشرفته تصویربرداری یا منابع محاسباتی سنگین، امکان پیاده‌سازی در سامانه‌های نظارتی لبه‌ای^۱ را داشته و برای پایش در مقیاس وسیع نیز مناسب است. در مقایسه با روش‌های جدیدتر مانند مدل‌های ترکیبی یولو-Transformer، ساختار یولو V8m با حفظ سادگی و سرعت بالای پردازش، نیاز به پیچیدگی‌های محاسباتی کمتر دارد و به همین دلیل برای پیاده‌سازی در محیط‌های واقعی با محدودیت منابع، گزینه‌ای عملی‌تر و مؤثرتر به شمار می‌آید.

ساختار مقاله به شرح زیر است: در بخش دوم، مجموعه داده مورد استفاده و ویژگی‌های آن معرفی می‌شود. در بخش سوم، معماری یولو V8 و تنظیمات مدل پیشنهادی تشریح می‌شود. در بخش چهارم، نتایج آزمایش‌ها، معیارهای ارزیابی و مقایسه عملکرد مدل گزارش می‌شوند و در بخش پنجم، جمع‌بندی نهایی، محدودیت‌ها و پیشنهادهایی برای تحقیقات آینده ارائه می‌شود.

۲ - مجموعه داده و ویژگی‌های آن

مجموعه داده ارائه شده در پژوهش (PythonAfroz, n.d) یکی از مجموعه داده‌های کاربردی و واقعی در حوزه پایش وضعیت پنل‌های خورشیدی است که برای اهداف تشخیص عیوب و تحلیل سلامت پنل‌ها تهیه شده است. این مجموعه شامل تصاویری واقعی از پنل‌های خورشیدی تحت شرایط محیطی متنوع بوده و برای توسعه، آموزش و ارزیابی مدل‌های یادگیری ماشین و یادگیری عمیق به‌ویژه مدل‌های بینایی ماشین طراحی شده است. تصاویر

3- Clean

4- Dusty

5- Snow-Covered

6- Bird-drop

1- Efficient Layer Aggregation

2- Edge deployment

طراحی چارچوب پیشنهادی و ارزیابی آن با استفاده از این مجموعه داده بوده است. هرچند نتایج به خوبی نشان دهنده کارایی مدل در شرایط متنوع موجود در دیتاست هستند، اما گسترش مطالعه به داده‌های بومی و اقلیمی متنوع‌تر می‌تواند زمینه‌ای برای پژوهش‌های آتی باشد.

همچنین باید توجه داشت که اگرچه در این پژوهش یک کلاس مجزا برای آسیب‌های الکتریکی در نظر گرفته شده است، اما ماهیت داده‌های تصویری به گونه‌ای است که صرفاً می‌تواند برخی نمودهای ظاهری این نوع آسیب‌ها را پوشش دهد. آسیب‌های داخلی پیچیده‌تر نظیر تخریب EVA یا نقص‌های لایه‌های ساختاری، ممکن است در تصاویر RGB به‌طور مستقیم قابل شناسایی نباشند. بنابراین، این موضوع به‌عنوان یکی از محدودیت‌های تحقیق در نظر گرفته می‌شود و بهره‌گیری از داده‌های مکمل مانند تصویربرداری حرارتی در مطالعات آتی توصیه می‌شود.

نگاره ۱ نمونه‌هایی از تصاویر مربوط به هر یک از شش کلاس موجود در مجموعه داده مورد استفاده را نشان می‌دهد. این تصاویر نمایانگر تنوع ظاهری و شرایط نوری گوناگون برای هر نوع عیب در پنل‌های خورشیدی هستند. کلاس‌ها شامل پنل‌های تمیز، پوشیده از برف، آلوده به گرد و غبار، دارای فضله پرندگان، آسیب مکانیکی و آسیب الکتریکی می‌شوند. این تصاویر نشان‌دهنده چالش‌های موجود در تشخیص دقیق هر نوع عیب در شرایط واقعی هستند.

باید توجه داشت که در مستندات منتشرشده مربوط به این مجموعه داده، اطلاعات دقیق در خصوص موقعیت جغرافیایی، شرایط آب‌وهوایی محل نصب پنل‌ها، یا نوع و مدل پنل‌ها ارائه نشده است. بنابراین تحلیل‌های انجام‌شده در این پژوهش مبتنی بر ویژگی‌های بصری موجود در تصاویر بوده و فاقد وابستگی به اطلاعات محیطی است.

تشخیص دقیق و خودکار عیوب پنل‌های خورشیدی در صنعت انرژی‌های تجدیدپذیر از اهمیت بالایی برخوردار است، زیرا عملکرد و بازدهی سیستم‌های فتوولتائیک به شدت تحت تأثیر عوامل مختلفی مانند آلودگی سطح، تجمع

آن‌ها توسط فضولات پرندگان آلوده شده‌اند، قرار می‌گیرند. این نوع آلودگی نه تنها باعث افت راندمان می‌شود بلکه در صورت باقی ماندن طولانی مدت می‌تواند باعث ایجاد نقاط داغ و آسیب به سلول‌های فتوولتائیک شود. آسیب فیزیکی^۱ به آسیب‌های فیزیکی ناشی از ضربه، ترک، شکستگی یا تغییر شکل بدنه پنل اشاره دارد که معمولاً در اثر عوامل خارجی مانند برخورد اجسام، طوفان یا نصب نادرست رخ می‌دهد. در نهایت، دسته آسیب الکتریکی^۲ شامل مواردی است که خرابی ناشی از اختلالات الکتریکی همچون سوختگی، قوس الکتریکی یا نقص در سیم‌کشی داخلی در سطح پنل مشاهده می‌شود. با توجه به وجود این شش دسته متمایز و متنوع، مجموعه داده حاضر شرایط بسیار مناسبی برای آموزش مدل‌های تشخیص عیب بصری نظیر یولو V8 فراهم می‌نماید. این کلاس‌ها نه تنها بازتاب‌دهنده مشکلات متداول در محیط‌های عملیاتی واقعی هستند، بلکه به پژوهشگران امکان می‌دهند تا مدل‌های خود را در سناریوهای چندکلاسه و با داده‌های پیچیده بصری مورد ارزیابی قرار دهند. از دیگر مزایای این دیتاست می‌توان به کیفیت بالای تصاویر، تنوع شرایط محیطی، و فراهم بودن آن به صورت عمومی برای پژوهشگران اشاره نمود.

لازم به ذکر است که مجموعه داده مورد استفاده شامل تصاویر رنگی و خاکستری از پنل‌های خورشیدی تحت شرایط نوری و سایه‌های مختلف می‌شود. با وجود تنوع مناسب در نوع آسیب‌ها، این مجموعه داده به‌صورت مستقیم از مناطق جغرافیایی گوناگون جمع‌آوری نشده و ممکن است در پوشش شرایط اقلیمی مختلف محدودیت‌هایی داشته باشد. این موضوع به‌عنوان یکی از مسیرهای توسعه آتی پژوهش پیشنهاد می‌شود تا با گردآوری داده‌های میدانی از مناطق مختلف، تعمیم‌پذیری و دقت نهایی مدل ارتقاء یابد. این مجموعه داده عمومی بوده و داده‌های آن از مناطق جغرافیایی و اقلیمی خاصی جمع‌آوری شده‌اند. در این پژوهش داده جدیدی گردآوری نشد و تمرکز اصلی بر

1- Physical-Damage


2- Electrical-damage

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی ()

تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از ... / ۵۵




پنل خورشیدی آلوده به گرد و غبار



پنل خورشیدی پوشیده با برف



پنل خورشیدی تمیز



پنل خورشیدی با آسیب الکتریکی



پنل خورشیدی با آسیب فیزیکی



پنل آلوده به فضولات پرندگان

نگاره ۱: نمونه‌هایی از تصاویر مربوط به شش کلاس موجود در مجموعه داده پنل خورشیدی

پارامترهای آموزش مانند نرخ یادگیری، تعداد دوره‌ها و تابع هزینه است. چنین رویکردی تضمین می‌کند که مدل بتواند در مواجهه با تصاویر واقعی، عیوب را به صورت دقیق و قابل اطمینان طبقه‌بندی کرده و در محیط‌های صنعتی نیز عملکرد مطلوبی داشته باشد. از آنجایی که تشخیص این دسته به منظور آموزش دقیق و منصفانه مدل یادگیری عمیق پیشنهادی هست، لازم است داده‌های آموزشی به طور متوازن میان کلاس‌ها توزیع شوند. با توجه به اینکه مجموعه داده اولیه شامل تعداد نامساوی نمونه در هر کلاس است، ابتدا کل داده‌ها به سه بخش مجزا تقسیم شدند: ۱۵٪ داده تست (برای ارزیابی نهایی)، و ۸۵٪ باقی مانده که خود به دو بخش آموزش (۷۰٪) و اعتبارسنجی (۱۵٪) تقسیم شد. سپس برای جلوگیری از بایاس مدل نسبت به کلاس‌های پرتکرار یا کم‌تکرار، تنها بر روی داده‌های آموزش، افزونگی داده اعمال شد تا تعداد نمونه‌های آموزشی در تمام کلاس‌ها تقریباً به عدد ثابتی (حدود ۵۰۰ تصویر) برسد. این فرآیند

برف، فضله پرندگان، و آسیب‌های فیزیکی یا الکتریکی قرار دارد. در صورت عدم شناسایی و رفع به موقع این عیوب، نه تنها تولید انرژی کاهش می‌یابد، بلکه ممکن است به خرابی‌های گسترده‌تر، افت طول عمر پنل‌ها و افزایش هزینه‌های تعمیر و نگهداری نیز منجر شود. از این رو، توسعه روش‌های هوشمند مبتنی بر بینایی ماشین و یادگیری عمیق برای پایش پیوسته و دقیق وضعیت پنل‌ها، گامی حیاتی در جهت افزایش بهره‌وری، کاهش هزینه‌ها و تضمین پایداری سامانه‌های خورشیدی در مقیاس صنعتی به شمار می‌رود (Fasihi & Dakiya, 2024; Dakamayi et al., 2021). بنابراین، روال آموزش مدل در حل این مسئله باید به گونه‌ای هدفمند و به‌درستی تنظیم شود تا بتواند تفاوت‌های ظریف میان انواع عیوب را با دقت بالا یاد بگیرد و تعمیم دهد.

این تنظیم شامل انتخاب مناسب ساختار مدل، استفاده از وزن‌های از پیش آموزش‌دیده (یادگیری انتقالی)، اعمال تکنیک‌های متنوع افزونگی داده برای مقابله با عدم توازن کلاس‌ها و تنوع شرایط نوری، و همچنین تعیین دقیق

جدول ۱: تعداد تصاویر مربوط به هر کلاس در مراحل مختلف تقسیم داده (تست، آموزش، اعتبارسنجی) و پس از اعمال

افزونگی داده جهت ایجاد مجموعه‌ای متوازن برای آموزش مدل‌های یولو V8

نام کلاس	کل تصاویر	تست (%۱۵)	باقی مانده (%۸۵)	اعتبارسنجی (%۱۵ از %۸۵)	آموزش (%۷۰)	افزونگی (Training × n)	آموزش نهایی	مجموع کل نهایی
تمیز	۱۹۴	۲۹	۱۶۵	۲۵	۱۴۰	$(۵۶۰=۴ \times ۱۴۰) \times ۴$	۵۶۰	۶۱۴
پوشیده با برف	۱۲۴	۱۹	۱۰۵	۱۶	۸۹	$(۵۳۴=۶ \times ۸۹) \times ۶$	۵۳۴	۵۶۹
گرد و خاک	۱۹۱	۲۹	۱۶۲	۲۴	۱۳۸	$(۵۵۲=۴ \times ۱۳۸) \times ۴$	۵۵۲	۶۰۵
فضولات پرندگان	۱۹۲	۲۹	۱۶۳	۲۵	۱۳۸	$(۵۵۲=۴ \times ۱۳۸) \times ۴$	۵۵۲	۶۰۶
آسیب فیزیکی	۷۰	۱۱	۵۹	۹	۵۰	$(۵۰۰=۱۰ \times ۵۰) \times ۱۰$	۵۰۰	۵۲۰
آسیب الکتریکی	۱۰۴	۱۶	۸۸	۱۳	۷۵	$(۵۲۵=۷ \times ۷۵) \times ۷$	۵۲۵	۵۵۴
مجموع	۸۷۵	۱۳۳	۷۴۲	۱۱۲	۶۳۰	-	۳۲۲۳	۳۴۶۸

باعث شد مدل با مجموعه‌ای غنی‌تر و متوازن‌تر از نمونه‌ها

مواجهه شود و بتواند ویژگی‌های بصری مربوط به هر نوع عیب را با دقت بالاتری بیاموزد. جدول ۱ تعداد تصاویر در هر مرحله از این فرآیند را برای هر یک از شش کلاس موجود در مجموعه داده نشان می‌دهد. به‌منظور بهبود عملکرد مدل در مواجهه با تنوع‌های موجود در داده‌های واقعی، از روش‌های مختلف افزون‌سازی داده بهره گرفته شد. در نگاره ۲، نمونه‌ای از تصاویر مربوط به هر کلاس اصلی عیب در سطر اول و نسخه‌های افزون‌شده آن‌ها در ستون‌های بعدی نمایش داده شده است. این عملیات شامل چرخش تصادفی، افزودن نویز گوسی، اعمال فیلتر گوسی، تغییر شدت روشنایی، و قرینه‌سازی افقی بوده که هدف از آن افزایش تنوع داده‌ها و کاهش بیش‌برازش مدل در مرحله آموزش است.

۳- روش پیشنهادی

در این بخش، چارچوب پیشنهادی برای طبقه‌بندی هوشمند عیوب پنل‌های خورشیدی و تحلیل پراکندگی فضایی آن‌ها ارائه می‌شود. ابتدا معماری مدل پایه و تنظیمات آموزش مدل YOLOv8m شرح داده می‌شود. سپس مراحل آماده‌سازی داده‌ها، فرآیند آموزش و ارزیابی مدل، و در ادامه نحوه ترکیب خروجی مدل با داده‌های مکانی به منظور

۳-۱- معماری مدل یولو V8 و تنظیمات مدل پیشنهادی

مدل یولو V8 یکی از پیشرفته‌ترین معماری‌های موجود در زمینه تشخیص و دسته‌بندی اشیاء در تصاویر است که با هدف افزایش دقت و کارایی در شرایط واقعی توسعه یافته است (Karaca Aydemir et al., 2025; Ali & Zhang, 2024; Mavaddati & Razavi, 2025; Sirisha et al., 2023; Ranjbarzadeh et al., 2025). این معماری با بهره‌گیری از ساختارهای سبک و ماژولار، امکان پردازش تصاویر در زمان واقعی را با دقت بالا فراهم می‌نماید. نسخه یولو V8m که در این پژوهش مورد استفاده قرار گرفته، توازن مناسبی میان سرعت اجرا و توان تشخیص برقرار کرده و برای کاربردهای محیطی و میدانی، به‌ویژه در سناریوهای پایش جغرافیایی، گزینه‌ای مطلوب به شمار می‌رود. در معماری یولو V8، از شبکه‌ی عصبی کانولوشنی پیشرفته به همراه لایه‌های گلوگاه، C2f و ماژول‌های تشخیص چندمقیاسی استفاده شده است. همچنین، استفاده از لایه‌های افزایش نمونه^۲ و کاهش نمونه^۱ به مدل امکان می‌دهد تا ویژگی‌های ظریف و کلان تصویر را به‌صورت هم‌زمان استخراج و تحلیل کند. در این پروژه، مدل با استفاده از تصاویر رنگی RGB ورودی در اندازه‌ی


1- Bottleneck

2- Upsampling

3- Downsampling

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (GIS)

تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از ... / ۵۷



نگاره ۲: نمونه‌ای از تصاویر مربوط به هر کلاس عیب پنل خورشیدی در ستون اول، و نسخه‌های افزونه‌شده آن‌ها در ستون‌های بعدی شامل چرخش، نویز گوسی، فیلتر گوسی، تغییر شدت روشنایی و قرینه‌سازی افقی. این روش‌های افزونه‌سازی به بهبود تعمیم‌پذیری مدل در شرایط متنوع نوری و زاویه‌ای کمک می‌کنند

از روش‌هایی مانند تنظیم‌سازی و توقف زود هنگام بهره گرفته شد. از آنجا که هدف این پژوهش، تشخیص عیوب در تصاویر پنل‌های خورشیدی و بهره‌برداری از نتایج در پایش زیرساخت‌های انرژی است، مدل به گونه‌ای طراحی و تنظیم شده که خروجی آن شامل تشخیص دقیق نوع هر عیب باشد. این تشخیص می‌تواند در سامانه‌های اطلاعات جغرافیایی^۳ (GIS) به منظور تحلیل فضایی و اولویت‌بندی اقدامات نگهداری به کار گرفته شود. در راستای آموزش

۶۴۰×۶۴۰ پیکسل آموزش داده شده و تنظیمات بهینه‌ای برای تعداد دوره، نرخ یادگیری (۰/۰۰۱)، اندازه دسته‌ای ۱۶ و الگوریتم بهینه‌سازی آدم^۲ در نظر گرفته شده است. به منظور افزایش کارایی مدل در شرایط نوری و محیطی متنوع، از تکنیک‌های افزایش داده شامل چرخش تصادفی، تغییر روشنایی و اعمال نویز استفاده شده است (Demirci et al., 2024; Go et al., 2024) همچنین برای کاهش بیش‌برازش،

3- Geographic Information System

1- Epoch

2- Adaptive Moment Estimation (Adam)

جدول ۲: ساختار اصلی مدل یولو V8m مورد استفاده در این پژوهش، شامل بخش‌های ستون فقرات^۱، گردن^۲، و خروجی

نهایی^۳ برای تشخیص عیوب پنل‌های خورشیدی در تصاویر RGB

مؤلفه شبکه	نوع/توضیح	تعداد فیلتر	اندازه کرنل	گام (Stride)	خروجی
ورودی	تصویر رنگی (RGB)	-	۶۴۰×۶۴۰	-	(۳, ۶۴۰, ۶۴۰)
بخش ستون فقرات	لایه‌های C2f و کانولوشن شبکه هرمی ویژگی‌ها	متغیر	۳×۳	۱-۲	استخراج ویژگی سطح پایین
گردن شبکه	(FPN ^۴) و شبکه تجمیع مسیر (PAN ^۵)	-	-	-	ادغام ویژگی چندمقیاسی
سر شبکه	سر تشخیص	-	-	-	کلاس + confidence + مکان
خروجی	جعبه‌های مرزبندی	-	-	-	برچسب و رتبه

جدول ۳: تنظیمات هایپرپارامترهای کلیدی در آموزش مدل یولو V8m به منظور دستیابی به تعادل میان دقت بالا و سرعت

مناسب برای کاربردهای میدانی در پایش عیوب پنل‌های خورشیدی

متغیر	مقدار	توضیح
تعداد دوره	۱۵۰	تعداد کل تکرارها بر روی مجموعه داده آموزش
اندازه دسته ^۶	۱۶	اندازه هر دسته داده ورودی به مدل در یک مرحله آموزش
نرخ یادگیری	۰/۰۰۱	نرخ یادگیری برای به‌روزرسانی وزن‌ها
بهینه‌ساز	آدام ^۷	الگوریتم بهینه‌سازی با توانایی تطبیق نرخ یادگیری
ابعاد ورودی	۶۴۰×۶۴۰	اندازه تصاویر ورودی به مدل
افزونگی	روشنایی، چرخش، نویز	تکنیک‌های افزایش داده برای بهبود تعمیم‌پذیری مدل
توقف زودهنگام	فعال	توقف زودهنگام در صورت عدم بهبود دقت
تنظیم‌سازی	$L_2 (\lambda=) 0/01$	جلوگیری از بیش‌برازش و افزایش پایداری مدل

الگوریتم بهینه‌سازی آدام نیز به دلیل قابلیت تنظیم تطبیقی نرخ یادگیری، عملکرد مناسبی در برابر نوسانات داده محیطی از خود نشان داده است. مدل یولو V8m به‌عنوان نسخه‌ای پیشرفته و سبک از خانواده یولو، با هدف دستیابی به سرعت بالا و دقت مناسب برای کاربردهای میدانی، در پژوهش حاضر مورد استفاده قرار گرفته است. ساختار این مدل شامل سه بخش اصلی ستون فقرات، گردن شبکه و سر شبکه است که هر یک نقش مجزایی در فرآیند تحلیل تصویر ایفا می‌کنند. بخش ستون فقرات وظیفه استخراج ویژگی‌های اولیه از تصویر را با استفاده از لایه‌های ترکیبی C2f و پیچشی بر عهده دارد که این ساختار به دلیل قابلیت استخراج عمیق‌تر اطلاعات محلی، برای شناسایی ظریف عیوب روی سطح پنل‌های خورشیدی بسیار مؤثر است.

مؤثر مدل یولو V8m، تنظیمات دقیق معماری شبکه و هایپرپارامترهای کلیدی مورد استفاده در جدول‌های ۲ و ۳ ارائه شده‌اند. این تنظیمات با هدف بهینه‌سازی مدل در سناریوهای محیطی و مکانی واقعی، به گونه‌ای انتخاب شده‌اند که مدل بتواند در شرایط متنوع نوری و مکانی به عملکرد پایداری برسد. استفاده از اندازه ورودی ۶۴۰×۶۴۰ باعث کاهش زمان پردازش و افزایش قابلیت اجرا در محیط‌های دارای منابع محاسباتی محدود شده است.

- 1- Backbone
- 2- Neck
- 3- Head
- 4- Feature Pyramid Network
- 5- Path Aggregation Network
- 6- Batch size
- 7- Adam

موقعیت‌های مختلف در تصویر است. در این روش، تصاویر اخذ شده از پنل‌های خورشیدی که شامل انواع مختلفی از عیوب نظیر ترک، لکه حرارتی، کثیفی، انسداد، و سایه هستند، ابتدا پیش‌پردازش و نرمال‌سازی می‌شوند. سپس با استفاده از روش‌های افزونه‌سازی داده همچون چرخش، افزودن نویز، تغییر شدت روشنایی، و قرینه‌سازی، مجموعه داده به صورت مصنوعی گسترش می‌یابد تا از بیش‌برازش مدل جلوگیری شود و عملکرد آن در شرایط واقعی تقویت می‌دهد که شامل سه بخش کلیدی ستون فقرات، گردن و سر شبکه است. در بخش ستون فقرات، لایه‌های C2f و کانولوشن با کرنل‌های 3×3 و گام‌های ۱ یا ۲ به کار رفته‌اند که نقش مهمی در استخراج ویژگی‌های سطح پایین و بالای تصویر دارند. استفاده از کرنل‌های کوچک و بهینه‌سازی معماری موجب حفظ دقت بالا در شناسایی عیوب ریز پنل‌های خورشیدی شده است. علاوه بر این، ساختار هرمی ویژگی‌ها و شبکه تجمیع مسیر در بخش گردن، با ادغام چندمقیاسی، امکان استخراج ویژگی‌های جامع‌تر را فراهم می‌نماید که به بهبود عملکرد مدل کمک می‌کند. دلایل انتخاب مدل یولو V8m به عنوان پایه‌ی روش پیشنهادی به شرح زیر است:

- توانایی تشخیص سریع و دقیق اشیاء کوچک در تصاویر رزولوشن بالا؛
 - پشتیبانی از معماری ماژولار و قابل بهینه‌سازی برای کاربردهای تعبیه‌شده؛
 - استفاده از افزونه‌های پیشرفته یادگیری انتقالی و تکنیک‌های تنظیم وزن برای کاهش نیاز به داده‌های فراوان برچسب‌خورده؛
 - عملکرد بالا در شرایط نور، زاویه، و پس‌زمینه‌ی متغیر که در محیط‌های عملیاتی پنل‌های خورشیدی رایج است.
- برای آموزش مدل، هایپرپارامترهایی همانند نرخ یادگیری، تعداد دوره‌ها، اندازه دسته، و نوع الگوریتم بهینه‌سازی با دقت تنظیم شده‌اند (مطابق جدول ۳) تا به

بخش گردن شبکه اطلاعات استخراج شده از سطوح مختلف را ادغام می‌کند تا مدل بتواند الگوهایی در مقیاس‌های گوناگون را درک کند. در نهایت، بخش سر شبکه با تولید برچسب کلاس و میزان اطمینان، خروجی مدل را برای تشخیص نوع عیوب تولید می‌کند.

به منظور آموزش این مدل، تنظیمات دقیق و بهینه‌ای اتخاذ شده‌اند تا تعادل میان دقت بالا و کارایی زمانی برقرار شود. تعداد ۱۰۰ دوره آموزشی با اندازه دسته ۱۶ انتخاب شده تا فرآیند آموزش نه بیش‌ازحد زمان‌بر باشد و نه مدل دچار یادگیری ناقص شود. نرخ یادگیری 0.001 با استفاده از الگوریتم آدام برای بهینه‌سازی وزن‌ها، به همگرایی سریع و پایدار مدل کمک می‌کند. تصاویر ورودی با ابعاد 640×640 به مدل داده شده‌اند که این ابعاد ضمن حفظ اطلاعات کافی، موجب کاهش بار محاسباتی نیز می‌شود. همچنین، برای افزایش توان تعمیم‌دهی مدل در شرایط مختلف محیطی، از روش‌های افزونگی داده شامل تغییر روشنایی، چرخش تصویر و افزودن نویز استفاده شده است. به منظور جلوگیری از بیش‌برازش، از روال تنظیم‌سازی نوع L_2 با ضریب 0.01 بهره گرفته شده و مکانیزم توقف زودهنگام نیز فعال شده تا در صورت عدم بهبود دقت طی چند دوره متوالی، فرآیند آموزش متوقف شود. این تنظیمات در کنار ساختار کارآمد مدل، زمینه‌ساز دستیابی به عملکردی قابل اتکا در تشخیص هوشمند عیوب پنل‌های خورشیدی شده‌اند.

۳-۲- روش پیشنهادی به منظور تشخیص هوشمند عیوب پنل‌های خورشیدی با استفاده از مدل یولو V8m

با توجه به نیاز روزافزون به پایش هوشمند و بلادرنگ سامانه‌های فتوولتائیک، در این پژوهش یک روش کارا برای تشخیص خودکار عیوب پنل‌های خورشیدی در تصاویر RGB با استفاده از مدل یولو V8m پیشنهاد شده است. مدل یولو V8 که یکی از جدیدترین نسخه‌های مدل‌های سری یولو به شمار می‌آید، دارای معماری بهینه‌شده‌ای به منظور افزایش دقت و سرعت در تشخیص اشیاء با اندازه‌ها و

تساویر، حجم مدل و تعداد پارامترها می‌تواند بر عملکرد نهایی شبکه‌های یادگیری عمیق تأثیرگذار باشد، مقایسه‌ی فنی بین این مدل‌ها اهمیت دارد. جدول ۴ ویژگی‌های فنی این مدل‌ها را به صورت مقایسه‌ای ارائه می‌دهد. این ویژگی‌ها شامل نوع وظیفه، طبقه‌بندی یا آشکارسازی، فرمت ورودی تصویر، تعداد پارامترها، حجم تقریبی مدل، و سطح پیچیدگی هستند. هدف از این مقایسه، بررسی تأثیر نوع معماری، پیچیدگی محاسباتی و فرمت داده ورودی بر عملکرد نهایی سیستم است. شایان ذکر است که تمامی این مدل‌ها روی داده یکسان و متوازن آموزش دیده‌اند (مطابق با جدول ۱)، و به منظور انتخاب مدل بهینه، نتایج ارزیابی هر مدل نیز در بخش‌های بعدی مقاله مورد تحلیل قرار خواهد گرفت. این مقایسه همچنین امکان تصمیم‌گیری آگاهانه در مورد انتخاب مدل مناسب براساس منابع پردازشی و دقت مورد انتظار را فراهم می‌کند.

در جدول ۵، مقایسه‌ای دقیق بین ویژگی‌های سه نسخه مختلف مدل‌های یولو شامل یولو V8-CLS، یولو V8 و یولو V8m ارائه شده است که همگی برای طبقه‌بندی تصاویر عیوب پنل‌های خورشیدی به کار گرفته شده‌اند. این جدول تفاوت‌های ساختاری و پیکربندی معماری هر مدل را نشان می‌دهد که مستقیماً بر عملکرد و کاربرد آن‌ها تأثیرگذار است. مدل یولو V8-CLS به عنوان نسخه‌ای سبک‌تر و ساده‌تر طراحی شده که شامل تعداد کمتری بلوک C2f در بخش

تعداد میان دقت تشخیص و سرعت پردازش دست یابیم. در نهایت، مدل آموزش‌دیده قادر است انواع مختلف عیب را در تصاویر ورودی به صورت جعبه‌های مرزی همراه با برچسب کلاس و مقدار اعتماد تشخیص دهد.

کاربردهای عملی این روش در حوزه نگهداری و پایش سامانه‌های خورشیدی شامل موارد زیر است:

- پایش خودکار و شبانه‌روزی پنل‌ها در نیروگاه‌های خورشیدی وسیع؛
- کاهش هزینه‌های بازرسی و نیروی انسانی؛
- جلوگیری از کاهش بهره‌وری ناشی از عیوب غیرقابل مشاهده با چشم غیرمسلح؛
- استفاده در سامانه‌های پروازی بدون سرنشین (پهپاد) برای بررسی سریع مجموعه‌های بزرگ.

۳-۳- جزئیات شبیه‌سازی مدل‌های عمیق در روش

پیشنهادی

در این پژوهش به منظور شناسایی و طبقه‌بندی هوشمند عیوب پنل‌های خورشیدی، از نسخه‌های مختلف مدل یولو V8 بهره‌گیری شده است. این مدل‌ها شامل نسخه‌های پایه (یولو V8)، نسخه میان‌رده (یولو V8m)، و نسخه مبتنی بر طبقه‌بندی (یولو V8-CLS) هستند که هر یک با دو نوع ورودی تصویری، یعنی تصاویر رنگی و تصاویر خاکستری، مورد ارزیابی قرار گرفته‌اند. از آنجا که نحوه پردازش

جدول ۴: مقایسه ویژگی‌های فنی مدل‌های یولو V8 در طبقه‌بندی عیوب پنل‌های خورشیدی در دو حالت رنگی و خاکستری،

شامل پارامترهای ساختاری، حجم حافظه و پیچیدگی مدل

یولو V8	نوع وظیفه	فرمت تصویر	تعداد پارامترها	حجم مدل (MB)	پیچیدگی تقریبی
یولو V8-CLS	طبقه‌بندی	رنگی (RGB)	۷/۷ M	۱۱/۲	پایین
یولو V8-CLS	طبقه‌بندی	خاکستری	۷/۰ M	۱۱/۲	پایین
یولو V8	طبقه‌بندی	رنگی (RGB)	۱۱/۲ M	۲۲/۲	متوسط
یولو V8	طبقه‌بندی	خاکستری	۱۱/۲ M	۲۲/۲	متوسط
یولو V8m	طبقه‌بندی	رنگی (RGB)	۸/۷ M	۱۶/۹	متوسط رو به پایین
یولو V8m	طبقه‌بندی	خاکستری	۸/۷ M	۱۶/۹	متوسط رو به پایین

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (ص ۶۱)

تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از ... / ۶۱

جدول ۵: مقایسه پیکربندی معماری سه نسخه مختلف مدل یولو V8 شامل یولو V8-CLS، یولو V8، و یولو V8m که همگی برای وظیفه طبقه‌بندی تصاویر عیوب پنل‌های خورشیدی مورد استفاده قرار گرفته‌اند.

مرحله	نوع لایه	یولو V8-CLS	یولو V8	یولو V8m
۱	ورودی تصویر	$3 \times 640 \times 640$	$3 \times 640 \times 640$	$3 \times 640 \times 640$
۲	Focus/Stem	بلوک پیچشی Stem	بلوک پیچشی Stem	بلوک پیچشی Stem
۳	بلوک ۱ Backbone	$C2f \times 1$ (small)	$C2f \times 3$	$C2f \times 3$
۴	بلوک ۲ Backbone	$C2f \times 2$	$C2f \times 6$	$C2f \times 6$
۵	بلوک ۳ Backbone	$C2f \times 2$	$C2f \times 6$	$C2f \times 6$
۶	بلوک ۴ Backbone	$C2f \times 1$	$C2f \times 3$	$C2f \times 3$
۷	لایه گردن شبکه ۱	SPPF	SPPF	SPPF
۸	لایه گردن شبکه ۲	استفاده نمی‌شود	استفاده نمی‌شود	استفاده نمی‌شود
۹	سر شبکه	طبقه‌بند خطی (Dense+Softmax)	طبقه‌بند خطی (Dense+Softmax)	طبقه‌بند خطی (Dense+Softmax)
۱۰	خروجی	بردار خروجی ۶ کلاس softmax	بردار خروجی ۶ کلاس softmax	بردار خروجی ۶ کلاس softmax

دقت بالا را به همراه دارد که آن را برای کاربردهای صنعتی و زمان واقعی بسیار مناسب می‌کند.

به طور کلی، تفاوت‌های کلیدی میان این سه مدل در تعداد و ترتیب بلوک‌های $C2f$ در بخش ستون فقرات مدل، نوع و تعداد لایه‌های گردن مدل و پیچیدگی سر مدل است که در نهایت منجر به تفاوت در دقت، سرعت و حجم محاسباتی هر مدل می‌شود. این تنوع به پژوهشگران امکان می‌دهد متناسب با نیازهای خاص پروژه، مدلی متعادل از نظر عملکرد و منابع انتخاب نمایند.

این معماری‌ها از مدل یولو V8 شامل یولو V8-CLS، یولو V8، و یولو V8m در پژوهش حاضر به صورت مدل‌های طبقه‌بندی‌کننده پیکربندی شده‌اند. در این حالت، ماژول‌های تشخیص اشیاء مانند PAN و پیش‌بینی‌های جعبه مرزی غیرفعال شده و لایه‌های خروجی به منظور پیش‌بینی کلاس نهایی تنظیم شده‌اند. تفاوت معماری این مدل‌ها در تعداد بلوک‌های $C2f$ و عمق کلی مدل تأثیر مستقیمی بر حجم و پیچیدگی آن‌ها داشته و در انتخاب مدل مناسب برای کاربردهای طبقه‌بندی تصاویر با منابع محاسباتی محدود مؤثر است.

ستون فقرات است؛ به طور خاص، در این مدل تنها یک بار بلوک $C2f$ در مرحله اول ستون فقرات و تعداد کمتری در سایر مراحل به کار رفته است. این ساختار سبک باعث کاهش حجم محاسباتی و حافظه مصرفی می‌شود، ولی در عین حال ممکن است دقت تشخیص نسبت به نسخه‌های بزرگ‌تر کاهش یابد.

در مقابل، مدل یولو V8 دارای ساختاری عمیق‌تر با تعداد بیشتری بلوک $C2f$ است که در مراحل ۱ تا ۴ ستون فقرات به صورت گسترده‌تری استفاده شده و قابلیت استخراج ویژگی‌های پیچیده‌تر و دقیق‌تری را فراهم می‌کند. این مدل تعادل مناسبی بین دقت و سرعت پردازش ایجاد می‌کند و برای کاربردهای عمومی‌تر مناسب است.

مدل یولو V8m که نسخه میانی و پیشرفته‌تر این خانواده است، به طور خاص برای تشخیص دقیق‌تر عیوب پنل‌های خورشیدی بهینه‌سازی شده است. این مدل با بهره‌گیری از تعداد بلوک‌های $C2f$ مشابه یولو V8 ولی با تنظیمات دقیق‌تر و بهبودهای معماری، عملکرد بهتری در شناسایی عیوب ریز و جزئیات پیچیده ارائه می‌دهد. علاوه بر این، یولو V8m به دلیل ساختار بهینه‌تر و معماری مدرن‌تر، ترکیبی از سرعت و

جدول ۶: مقایسه نسخه‌های مختلف یولو از نظر معماری، پارامترها، سرعت و دقت

پشتیبانی از طبقه‌بندی	دقت (mAP@0.5)	سرعت اجرا (FPS)	تعداد پارامترها	ساختار معماری	انتشار	نسخه یولو
ندارد ✗	٪۴۳/۵	۶۲	۶۳ میلیون	CSPDarknet53 + SPP + PAN	۲۰۲۰	یولو V4
ندارد ✗	٪۳۶/۷	۱۴۰	۷/۲ میلیون	Focus + CSP + PANet	۲۰۲۰	یولو V5s
ندارد ✗	٪۴۴/۵	۱۰۰	۲۱/۲ میلیون	Focus + CSP + PANet	۲۰۲۰	یولو V5m
دارد ✓	٪۴۶/۴	۹۵	۲۵/۹ میلیون	C2f + decoupled head	۲۰۲۳	یولو V8m
دارد ✓	٪۵۳/۰	۸۵	۳۰~ میلیون	C2f + TA head + NMS ² بدون	۲۰۲۴	یولو V10

صورت دسته‌بندی‌شده (مثلاً پنل سالم، پنل دارای آسیب الکتریکی یا فیزیکی و...) وارد مرحله پیش‌بینی و ارزیابی می‌شود. این ساختار منسجم کمک می‌کند تا داده‌های نامتوازن به شکلی مؤثر آموزش داده شده و عملکرد مدل در طبقه‌بندی دقیق‌تر شود. به‌منظور شفاف‌سازی مراحل اجرای چارچوب پیشنهادی، سودوکد الگوریتم طبقه‌بندی خودکار عیوب پنل‌های خورشیدی در این بخش ارائه شده است. این الگوریتم با تکیه بر معماری مدرن یولو V8m در حالت طبقه‌بندی و استفاده از روش‌هایی مانند پیش‌پردازش داده، افزونگی داده، یادگیری انتقالی و تنظیمات دقیق شبکه، قادر است شش نوع وضعیت رایج پنل‌های خورشیدی شامل: سالم، پوشیده از برف، آلوده به گرد و غبار، فضله پرندگان، آسیب فیزیکی و آسیب الکتریکی را با دقت بالا شناسایی و طبقه‌بندی کند. الگوریتم ۱ شامل مراحل دریافت داده، آماده‌سازی و افزایش تنوع آن‌ها، آموزش مدل طبقه‌بندی بر پایه یولو V8m، و ارزیابی عملکرد مدل با استفاده از معیارهای آماری دقیق است.

در این چارچوب، ساختار شبکه به گونه‌ای طراحی شده است که تنها از بخش ستون فقرات برای استخراج ویژگی‌ها و بخش نهایی سر دسته‌بندی برای پیش‌بینی کلاس تصویر استفاده می‌شود. بر خلاف نسخه‌های تشخیص شیء، در اینجا نیازی به پیش‌بینی موقعیت مکانی یا استفاده از جعبه پیش‌فرض^۲ نیست، که این امر موجب سادگی، سرعت بالا و کاهش پیچیدگی محاسباتی در فرآیند آموزش و استنتاج می‌شود.

همچنین برای ارزیابی دقیق‌تر مدل یولو V8m و مقایسه آن با نسخه‌های پیشین و جدید یولو، جدول ۶ ارائه شده است. این جدول نسخه‌های مختلف یولو شامل یولو V4، یولو V5، یولو V8 و یولو V10 را از نظر ویژگی‌های معماری، تعداد پارامترها، سرعت پردازش، دقت (mAP@0.5) و قابلیت پشتیبانی از طبقه‌بندی تصاویر مقایسه می‌کند. همان‌طور که در جدول مشاهده می‌شود، مدل یولو V8m با بهره‌گیری از ساختار C2f و سر تفکیک‌شده^۳ عملکرد بهینه‌ای را از نظر دقت و سرعت ارائه می‌دهد. در حالی که نسخه‌های قدیمی‌تر مانند یولو V4 و یولو V5 عمدتاً برای تشخیص طراحی شده‌اند و از قابلیت طبقه‌بندی مستقیم پشتیبانی نمی‌کنند، نسخه‌های جدیدتر مانند یولو V8 و یولو V10، به‌ویژه برای کاربردهایی نظیر طبقه‌بندی عیوب پنل خورشیدی مناسب‌تر هستند.

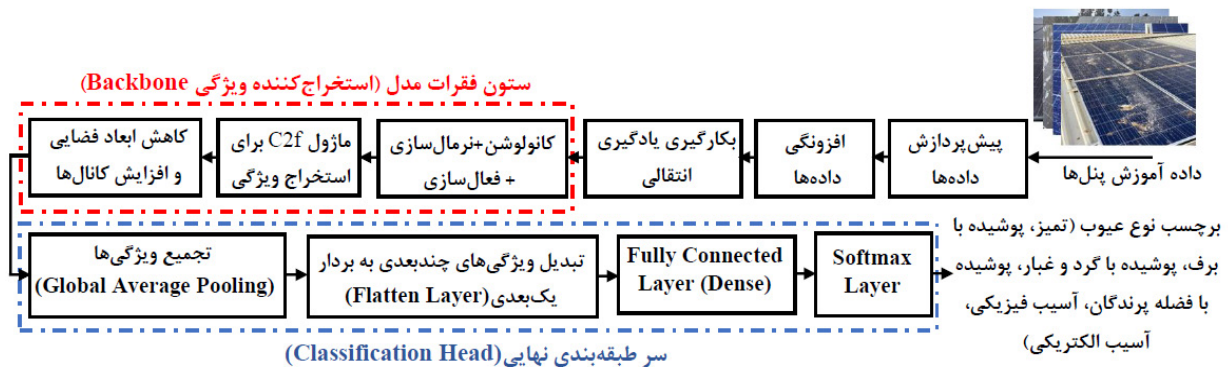
بلوک دیاگرام روش پیشنهادی در نگاره ۳ نشان داده شده است. این دیاگرام، جریان کلی مراحل پردازش، آموزش، و ارزیابی مدل یولو V8m برای تشخیص هوشمند عیوب پنل‌های خورشیدی را به‌صورت ساختاریافته نمایش می‌دهد. مراحل اصلی این فرایند شامل پیش‌پردازش تصاویر ورودی و افزونگی داده برای متوازن‌سازی کلاس‌ها، بهینه‌سازی مدل، استخراج ویژگی‌ها با بهره‌گیری از ساختارهای مدولار مانند C2f در بخش گردن و ستون فقرات مبتنی بر CSPDarknet، و در نهایت طبقه‌بندی نهایی با استفاده از سر شبکه است. همچنین، خروجی مدل به

1- Frames Per Second

2- Non-Maximum Suppression

3- Decoupled head

4- Classification Head



نگاره ۳: بلوک دیاگرام روش پیشنهادی مبتنی بر استفاده از یولو V8m به منظور پایش عیوب پنل‌های خورشیدی

الگوریتم ۱: سودوکد چارچوب پیشنهادی برای تشخیص هوشمند عیوب پنل‌های خورشیدی مبتنی بر یولو V8m
<p>ورودی: تصاویر رنگی از پنل‌های خورشیدی در شرایط نوری و محیطی مختلف</p> <p>خروجی: مدل یولو V8m آموزش دیده برای طبقه‌بندی شش کلاس عیب پنل خورشیدی، - مقادیر کمی ارزیابی مدل، و برچسب کلاس برای هر تصویر شامل یکی از شش وضعیت: ۱. تمیز، ۲. پوشیده با برف، ۳. پوشیده با گرد و غبار، ۴. آلوده با فضولات پرندگان، ۵. آسیب فیزیکی، و ۶. آسیب الکتریکی</p> <p>۱. بارگذاری مجموعه داده و برچسب گذاری تصاویر بر اساس شش دسته نامبرده</p> <p>۲. پیش پردازش تصاویر: - تغییر اندازه به 640×640، - نرمال سازی پیکسل‌ها، - تبدیل به قالب ورودی مدل</p> <p>۳. اعمال تکنیک‌های افزونگی داده: - چرخش، تغییر مقیاس، برش تصادفی، - اعمال Mosaic و Mixup، - تغییر رنگ در فضای HSV</p> <p>۴. تقسیم مجموعه داده: ۷۰٪ آموزش، ۱۵٪ اعتبارسنجی، ۱۵٪ آزمون</p> <p>۵. بارگذاری وزن‌های اولیه از مدل یولو V8m آموزش دیده روی COCO (یادگیری انتقالی)</p> <p>۶. تعریف معماری مدل یولو V8m:</p> <p>الف) بخش ستون فقرات مدل (استخراج ویژگی):</p> <ul style="list-style-type: none"> - لایه تمرکزی و فشرده سازی کانال‌ها، - چندین بلوک C2f با لایه‌های زیر: پیش‌بینی، نرمال سازی دسته‌ای، تابع فعال سازی - استفاده از ساختار C2f برای اتصال جزئی و فیوژن ویژگی‌ها، کاهش تدریجی ابعاد فضایی، افزایش کانال‌ها ب) بخش گردن مدل (ادغام چند مقیاسی ویژگی): - شبکه هرمی ویژگی‌ها، - شبکه تجمیع مسیر - تلفیق بهینه لایه‌ها، - ترکیب موثر ویژگی‌ها از سه مقیاس مختلف، - انتقال و ترکیب اطلاعات ویژگی از لایه‌های عمیق به سطحی <p>۷. تنظیمات آموزش: - انتخاب بهینه‌ساز (آدام)، تابع هزینه ترکیبی (BCE Loss برای کلاس)، انتخاب دوره و نرخ یادگیری</p> <p>۸. شروع فرآیند آموزش:</p> <ul style="list-style-type: none"> - آموزش روی داده‌های آموزشی - اعتبارسنجی دوره‌ای روی مجموعه اعتبارسنجی - ذخیره بهترین وزن‌ها (Best Checkpoint) <p>۹. ارزیابی نهایی مدل روی داده‌های آزمون:</p> <ul style="list-style-type: none"> - استخراج ماتریس درهم‌ریختگی هر ۶ کلاس، - محاسبه دقت، Precision، یادآوری، F1 برای هر کلاس <p>خروجی: مدل یولو V8m آموزش دیده با قابلیت تشخیص شش نوع عیب</p>

جدول ۷: تنظیمات هایپرپارامترهای اصلی مورد استفاده برای آموزش سه مدل مبتنی بر یولو V8 به منظور طبقه‌بندی عیوب پنل‌ها

فرآپارامتر	یولو V8-CLS	یولو V8	یولو V8m
نوع وظیفه	طبقه‌بندی	طبقه‌بندی	طبقه‌بندی
اندازه تصویر ورودی	۶۴۰×۶۴۰	۶۴۰×۶۴۰	۶۴۰×۶۴۰
تعداد دوره	۱۰۰	۱۲۰	۱۵۰
اندازه دسته	۳۲	۳۲	۱۶
نرخ یادگیری اولیه	۰/۰۰۱۵	۰/۰۰۱	۰/۰۰۰۸
ضریب کاهش وزن	۰/۰۰۰۵	۰/۰۰۰۶	۰/۰۰۰۸
بهینه‌ساز	گرادیان نزول تصادفی ^۱	گرادیان نزولی تصادفی	گرادیان نزولی تصادفی
زمان بند نرخ یادگیری	کاهش نرخ یادگیری به صورت کسینوسی	کاهش نرخ یادگیری به صورت کسینوسی	کاهش نرخ یادگیری به صورت کسینوسی
Warmup Epochs	۳	۵	۸
به‌کارگیری Mixed Precision	خیر	بله	بله
توقف زود هنگام	فعال	فعال	فعال

به‌طور خاص، در مدل یولو V8m که نسخه‌ای بزرگ‌تر و پیچیده‌تر از یولو V8 محسوب می‌شود، تعداد دوره‌ها افزایش یافته تا مدل فرصت بیشتری برای یادگیری دقیق‌تر ویژگی‌ها داشته باشد. همچنین برای جلوگیری از بروز خطاهای حافظه در مدل یولو V8m، اندازه دسته کاهش یافته است. نرخ یادگیری در این مدل نیز با اندکی کاهش تنظیم شده تا فرآیند همگرایی با ثبات بیشتر و احتمال کمتری برای نوسانات شدید انجام شود. استفاده از آموزش با دقت ترکیبی^۳ در مدل‌های یولو V8 و یولو V8m نیز باعث کاهش مصرف حافظه و افزایش سرعت آموزش شده است، در حالی که در مدل یولو V8-CLS این ویژگی غیرفعال باقی مانده است. در نهایت، فعال‌سازی توقف زود هنگام^۴ در هر سه مدل، از بیش‌برازش بر داده‌های آموزشی جلوگیری کرده و به انتخاب بهینه‌ترین نقطه توقف در فرآیند یادگیری کمک کرده است. این تنظیمات به مدل‌ها امکان می‌دهند تا بدون پیچیدگی بیش از حد و با بازده بالا، وظیفه طبقه‌بندی

به منظور آموزش دقیق و منصفانه مدل‌های مبتنی بر یولو V8 با هدف طبقه‌بندی هوشمند عیوب پنل‌های خورشیدی، مجموعه‌ای از هایپرپارامترهای مهم شامل نرخ یادگیری، تعداد دوره، اندازه دسته و سایر تنظیمات مرتبط با بهینه‌سازی مدل تعیین شده‌اند. جدول ۷ تنظیمات فرآپارامترهای اصلی به‌کاررفته برای هر یک از سه مدل یولو V8-CLS، یولو V8 و یولو V8m را نمایش می‌دهد. برای اطمینان از آموزش مؤثر و منصفانه سه مدل مبتنی بر یولو V8، تنظیمات هایپرپارامترها با دقت انتخاب شده‌اند تا شرایط یکسانی برای مقایسه عملکرد فراهم شود. در تمامی مدل‌ها، اندازه ورودی تصویر برابر با ۶۴۰×۶۴۰ انتخاب شده تا شبکه‌های عصبی ویژگی‌های تصویری را از داده‌های یکسان و با دقت بالا استخراج کنند. با این حال، تفاوت‌هایی در سایر پارامترها مشاهده می‌شود که به دلیل تفاوت در عمق معماری مدل‌ها و میزان حافظه مورد نیاز برای پردازش است.

3- Mixed Precision Training

4- Early Stopping

1- Stochastic Gradient Descent

2- Anchor Box

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (ص ۶۵)

تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از ... / ۶۵

در پژوهش حاضر، این معیارها برای ارزیابی و مقایسه عملکرد سه نسخه از مدل یولو V8 شامل یولو V8-CLS، یولو V8m و یولو V8 ساده در فرآیند طبقه‌بندی عیوب پنل‌های خورشیدی مورد استفاده قرار گرفته‌اند. مدل‌ها با استفاده از تصاویر دریافتی از پنل‌های خورشیدی، سعی در شناسایی صحیح کلاس هر تصویر (سالم، ترک‌خورده، آسیب‌دیده و ...) داشته‌اند. در این راستا، دقت کلی نشان می‌دهد چه درصدی از کل نمونه‌های آزمایش به درستی طبقه‌بندی شده‌اند. دقت پیش‌بینی مثبت بیان می‌کند که چه نسبت از پیش‌بینی‌های مثبت مدل واقعاً صحیح بوده‌اند. در حالی که فراخوانی میزان توانایی مدل در شناسایی صحیح تمامی موارد مثبت را اندازه‌گیری می‌کند. استفاده همزمان از این معیارها، امکان تحلیل دقیق‌تری از نقاط قوت و ضعف هر مدل در مواجهه با تصاویر با کیفیت و شرایط نوری مختلف را فراهم می‌کند. از آنجا که در کاربردهایی مانند پایش و عیب‌یابی پنل‌های خورشیدی با استفاده از تصاویر هوایی، شناسایی سریع و دقیق عیوب برای جلوگیری از افت عملکرد سیستم ضروری است، بهره‌گیری از این معیارها در ارزیابی عملکرد مدل‌ها اهمیت زیادی دارد. در ادامه، نتایج ارزیابی مدل‌های یولو V8 در قالب جدول‌های مقایسه‌ای و نمودارهای عملکرد ارائه می‌شود تا بتوان به صورت شفاف‌تری عملکرد هر مدل را از نظر دقت، سرعت و کارایی در طبقه‌بندی عیوب بررسی کرد. جدول ۸ عملکرد مدل‌های مختلف یولو در دو حالت استفاده از تصاویر رنگی و خاکستری را در طبقه‌بندی عیوب پنل‌ها مقایسه می‌کند. در این جدول، شش کلاس مختلف عیب شامل: تمیز، گرد و خاک، پوشیده با برف، فضولات پرندگان، آسیب فیزیکی، و آسیب الکتریکی بررسی شده‌اند.

بر اساس جدول ۸، مدل یولو V8m در طبقه‌بندی تصاویر رنگی با میانگین دقت ۹۷/۴۳٪ بهترین عملکرد را در میان سه مدل یولو ارائه می‌دهد. این عملکرد بالا به دلیل معماری قدرتمند یولو V8m و توانایی آن در یادگیری ویژگی‌های پیچیده بصری در تصاویر رنگی است. کاهش جزئی دقت

تصاویر پنل‌های خورشیدی را انجام دهند.

همانطور که بیان شد مقادیر تنظیمات هایپرپارامترهای اصلی هر یک از مدل‌های یولو V8، یولو V8m و مدل یولو V8-CLS براساس ویژگی‌های معماری و اندازه مدل‌ها به‌طور جداگانه تعیین شده‌اند. به‌عنوان مثال، مقدار ضریب کاهش وزن برای مدل یولو V8m برابر ۰/۰۰۰۸ انتخاب شده است که نسبت به مدل یولو V8m با مقدار ۰/۰۰۰۶ و مدل یولو V8-CLS با مقدار ۰/۰۰۰۵ کمی بالاتر است. این افزایش تدریجی به منظور کنترل دقیق‌تر بیش‌برازش در مدل‌های کوچکتر و سبکتر صورت گرفته است، چرا که مدل‌های کوچکتر ممکن است به دلیل ظرفیت کمتر، حساسیت بیشتری نسبت به داده‌های آموزشی داشته باشند. همچنین تفاوت در تعداد دوره‌های آموزش و اندازه دسته نشان‌دهنده تلاش برای یافتن تعادلی بین سرعت آموزش، دقت نهایی مدل و مصرف حافظه است. به طور کلی، این مقادیر از طریق آزمایش‌های مقدماتی و تنظیمات تجربی بهینه‌سازی شده‌اند تا بهترین عملکرد هر مدل در تشخیص عیوب پنل‌های خورشیدی حاصل شود.

۴- نتایج و ارزیابی عملکرد مدل‌های پیشنهادی

به‌منظور بررسی میزان موفقیت مدل‌های مختلف یادگیری عمیق در طبقه‌بندی هوشمند عیوب پنل‌های خورشیدی، از معیارهای رایج ارزیابی عملکرد در مسائل طبقه‌بندی استفاده شده است. این معیارها شامل دقت کلی (Acc)، دقت پیش‌بینی مثبت (Ppr)^۲ و نرخ بازیابی^۳ هستند، که عملکرد مدل‌ها را در شناسایی صحیح کلاس‌های مختلف نشان می‌دهند. این معیارها به‌صورت گسترده در حوزه تشخیص و طبقه‌بندی کاربرد دارند و عملکرد مدل را از جنبه‌های مختلف مانند نرخ خطا و توانایی در شناسایی درست نمونه‌های مثبت ارزیابی می‌کنند (Rainio et al., 2024;

Terven et al., 2025)

1- Accuracy

2- Precision

3- Recall

جدول ۸: مقایسه دقت طبقه‌بندی مدل‌های مختلف و نسخه کلاس‌بندی یولو V8-CLS برای تصاویر رنگی و خاکستری

مدل عمیق	دسته عیوب	دقت (%)		میانگین دقت (%)	
		رنگی	خاکستری	رنگی	خاکستری
یولو V8-CLS	تمیز	۹۶/۲۵	۹۴/۷۰	۹۶/۱۱	۹۴/۸۶
	گرد و خاک	۹۶/۳۲	۹۴/۹۲		
	پوشیده با برف	۹۶/۱۱	۹۴/۸۴		
	فضولات پرندگان	۹۵/۹۲	۹۴/۶۸		
	آسیب فیزیکی	۹۶/۰۳	۹۴/۷۱		
	آسیب الکتریکی	۹۶/۰۳	۹۴/۹۱		
یولو V8	تمیز	۹۴/۱۰	۹۲/۹۵	۹۴/۲۵	۹۳/۱۴
	گرد و خاک	۹۴/۳۵	۹۳/۰۷		
	پوشیده با برف	۹۴/۱۸	۹۳/۲۵		
	فضولات پرندگان	۹۴/۲۷	۹۳/۰۸		
	آسیب فیزیکی	۹۴/۳۳	۹۳/۴۲		
	آسیب الکتریکی	۹۴/۲۷	۹۳/۰۸		
یولو V8m	تمیز	۹۷/۵۱	۹۵/۱۰	۹۷/۴۳	۹۵/۰۲
	گرد و خاک	۹۷/۳۲	۹۵/۲۴		
	پوشیده با برف	۹۷/۴۶	۹۵/۱۰		
	فضولات پرندگان	۹۷/۳۸	۹۴/۹۲		
	آسیب فیزیکی	۹۷/۴۷	۹۴/۸۲		
	آسیب الکتریکی	۹۷/۴۵	۹۵/۰۶		

و شبکه عصبی بازگشتی با دقت ۹۰/۳۱٪ عملکرد بهتری دارد. این اختلاف عملکرد نشان‌دهنده توانایی معماری یولو V8m در یادگیری دقیق الگوهای عیوب مختلف در تصاویر است. همچنین مقادیر بالا در دقت مثبت و بازیابی در تمام کلاس‌ها بیانگر توازن مناسب بین نرخ پیش‌بینی درست و پوشش کامل نمونه‌ها است. در مقایسه با مدل شبکه عصبی بازگشتی، که عملکرد پایین‌تری دارد (میانگین ۹۰/۳۱٪)، مشاهده می‌شود که مدل‌های مبتنی بر شبکه‌های کانولوشنی و به‌ویژه مدل یولو در تحلیل تصاویر بصری پیچیده عملکرد قابل توجه‌تری دارند. مدل رزنت ۵۰ نیز عملکرد مناسبی دارد اما همچنان در برابر یولو V8m با حدود ۱/۵ درصد اختلاف عقب‌تر است.

در تصاویر خاکستری نیز منطقی است، چرا که تصاویر رنگی اطلاعات بیشتری در مورد بافت و ساختار ارائه می‌دهند. در مقابل، یولو V8 و ساده دقتی حدود ۹۴/۲۵٪ دارد و مدل یولو V8-CLS نیز عملکردی در حدود ۹۶/۱۱٪ ثبت کرده است.

به منظور ارزیابی دقیق‌تر، عملکرد مدل پیشنهادی یولو V8m با چندین مدل رایج شامل VGG16، CNN، رزنت ۵۰، شبکه عصبی بازگشتی^۱ و سایر نسخه‌های یولو در جدول ۹ مقایسه شده است. این جدول علاوه بر دقت طبقه‌بندی، مقادیر دقت مثبت و بازیابی برای هر کلاس را نیز ارائه می‌دهد. طبق جدول ۹، مدل یولو V8m با میانگین دقت ۹۷/۴۳٪ از سایر مدل‌ها از جمله رزنت ۵۰ با میانگین ۹۵/۹۷٪، VGG16، ۹۴/۸۷٪، CNN، با دقت ۹۴/۰۹٪

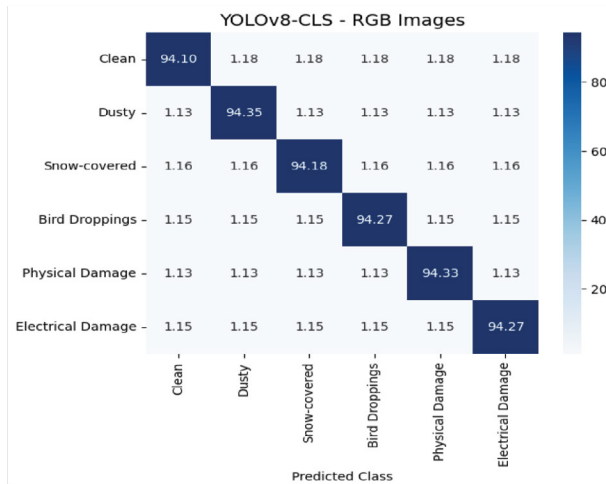
فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (سیر)

تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از ... / ۶۷


جدول ۹: مقایسه عملکرد مدل پیشنهادی یولو V8m با سایر مدل‌های عمیق در شش کلاس مختلف عیب برای تصاویر رنگی.

معیارهای دقت، دقت پیش‌بینی و بازیابی در این جدول برای هر کلاس و میانگین کل گزارش شده‌اند


مدل عمیق	دسته عیوب	دقت (%)	Ppr (%)	Recall (%)	F1-score (%)	میانگین دقت (%)
شبکه عصبی پیچشی	تمیز	۹۴/۲۸	۹۳/۶۰	۹۴/۷۲	۹۴/۵۰	۹۴/۰۹
	گرد و خاک	۹۳/۸۹	۹۴/۲۱	۹۴/۲۱	۹۴/۰۵	
	پوشیده با برف	۹۴/۱۳	۹۳/۴۸	۹۳/۹۵	۹۳/۸۰	
	فضولات پرندگان	۹۴/۰۷	۹۴/۳۸	۹۴/۲۸	۹۴/۲۲	
	آسیب فیزیکی	۹۳/۹۰	۹۳/۱۹	۹۵/۱۲	۹۳/۵۴	
	آسیب الکتریکی	۹۴/۲۸	۹۳/۷۱	۹۴/۴۲	۹۴/۰۰	
VGG16	تمیز	۹۴/۹۷	۹۴/۶۱	۹۵/۱۸	۹۴/۷۹	۹۴/۸۷
	گرد و خاک	۹۴/۸۸	۹۴/۵۳	۹۵/۰۱	۹۴/۷۰	
	پوشیده با برف	۹۴/۸۰	۹۳/۹۴	۹۳/۹۳	۹۴/۳۷	
	فضولات پرندگان	۹۴/۹۶	۹۴/۵۹	۹۵/۱۱	۹۴/۵۲	
	آسیب فیزیکی	۹۴/۷۲	۹۴/۳۱	۹۴/۹۸	۹۴/۷۱	
	آسیب الکتریکی	۹۴/۹۰	۹۴/۵۳	۹۵/۰۲	۹۴/۷۱	
رزنت ۵۰	تمیز	۹۵/۹۶	۹۵/۲۲	۹۶/۱۱	۹۵/۵۹	۹۵/۹۷
	گرد و خاک	۹۶/۰۸	۹۵/۴۵	۹۶/۲۷	۹۵/۷۶	
	پوشیده با برف	۹۵/۸۲	۹۵/۱۱	۹۶/۰۱	۹۵/۴۱	
	فضولات پرندگان	۹۵/۹۳	۹۵/۲۰	۹۶/۰۹	۹۵/۵۱	
	آسیب فیزیکی	۹۶/۰۳	۹۵/۲۶	۹۶/۲۳	۹۵/۶۴	
	آسیب الکتریکی	۹۶/۰۱	۹۵/۲۸	۹۶/۲۲	۹۵/۶۴	
شبکه عصبی بازگشتی	تمیز	۸۹/۹۲	۸۷/۹۰	۹۰/۲۱	۹۱/۵۶	۹۰/۳۱
	گرد و خاک	۸۹/۸۱	۸۸/۷۴	۹۰/۱۰	۹۰/۹۵	
	پوشیده با برف	۸۹/۷۷	۸۷/۸۳	۹۰/۰۱	۹۰/۳۹	
	فضولات پرندگان	۸۹/۶۶	۸۸/۷۱	۸۹/۹۳	۹۱/۷۴	
	آسیب فیزیکی	۸۹/۸۷	۸۹/۸۸	۹۰/۱۷	۸۹/۹۹	
	آسیب الکتریکی	۸۹/۷۹	۸۸/۹۲	۹۰/۱۳	۸۴/۷۰	
یولو V8- CLS	تمیز	۹۶/۲۵	۹۵/۸۱	۹۶/۴۲	۹۵/۸۳	۹۶/۱۱
	گرد و خاک	۹۶/۳۲	۹۵/۷۹	۹۶/۴۹	۹۵/۹۰	
	پوشیده با برف	۹۶/۱۱	۹۵/۷۲	۹۶/۲۷	۹۵/۶۹	
	فضولات پرندگان	۹۵/۹۲	۹۵/۵۸	۹۶/۰۳	۹۵/۹۷	
	آسیب فیزیکی	۹۶/۰۳	۹۵/۶۱	۹۶/۱۴	۹۵/۵۸	
	آسیب الکتریکی	۹۶/۰۳	۹۵/۶۳	۹۶/۱۷	۹۵/۶۰	
یولو V8	تمیز	۹۴/۱۰	۹۳/۵۴	۹۴/۳۷	۹۴/۲۴	۹۴/۲۵
	گرد و خاک	۹۴/۳۵	۹۳/۶۹	۹۴/۵۵	۹۴/۴۵	
	پوشیده با برف	۹۴/۱۸	۹۳/۶۱	۹۴/۴۳	۹۴/۳۰	
	فضولات پرندگان	۹۴/۲۷	۹۳/۷۱	۹۴/۴۸	۹۴/۳۷	
	آسیب فیزیکی	۹۴/۳۳	۹۳/۷۶	۹۴/۶۰	۹۴/۴۶	
	آسیب الکتریکی	۹۴/۲۷	۹۳/۶۹	۹۴/۵۱	۹۴/۳۹	
یولو V8m	تمیز	۹۷/۵۱	۹۷/۰۸	۹۷/۶۸	۹۷/۵۹	۹۷/۴۳
	گرد و خاک	۹۷/۳۲	۹۶/۸۸	۹۷/۴۵	۹۷/۳۸	
	پوشیده با برف	۹۷/۴۶	۹۷/۰۲	۹۷/۶۱	۹۷/۵۴	
	فضولات پرندگان	۹۷/۳۸	۹۶/۹۵	۹۷/۵۲	۹۷/۴۵	
	آسیب فیزیکی	۹۷/۴۷	۹۷/۰۵	۹۷/۶۱	۹۷/۵۴	
	آسیب الکتریکی	۹۷/۴۵	۹۷/۰۱	۹۷/۵۸	۹۷/۴۸	



(ب)



(الف)



(ج)

نگاره ۴: مقایسه ماتریس‌های درهم‌ریختگی برای طبقه‌بندی عیوب پنل با استفاده از سه مدل مبتنی بر یولو در تصاویر رنگی،

الف) یولو V8، ب) یولو V8-CLS، ج) یولو V8m

تشخیص درست) به وضوح غالب هستند و عناصر غیرقطری (خطاهای طبقه‌بندی) حداقلی هستند. در مقابل، یولو V8 ساده، اشتباهاتی جزئی بین کلاس‌های گرد و خاک و پوشیده با برف دارد که می‌تواند ناشی از شباهت ظاهری آن‌ها در برخی شرایط نوری باشد. نتایج حاصل از دو جدول ۸ و ۹ نشان‌دهنده برتری قابل توجه مدل یولو V8m در مقایسه با سایر مدل‌های یولو و همچنین مدل‌های کلاسیک یادگیری عمیق مانند CNN، VGG16،

نگاره ۴ ماتریس‌های درهم‌ریختگی^۱ مربوط به سه نسخه مختلف از یولو شامل یولو V8، یولو V8-CLS و یولو V8m را نشان می‌دهد. این ماتریس‌ها مشخص می‌کنند که مدل‌ها تا چه حد در تشخیص صحیح هر کلاس موفق عمل کرده‌اند و کدام کلاس‌ها بیشتر با هم اشتباه گرفته شده‌اند. در ماتریس یولو V8m، بیشترین دقت در تشخیص صحیح کلاس‌ها دیده می‌شود، به گونه‌ای که عناصر قطری

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (۳۳)

تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از ... / ۶۹

به همین دلیل در تمامی معیارها دقت پایین‌تری از خود نشان داده‌اند. در مجموع، می‌توان نتیجه گرفت که ترکیب معماری عمیق، طراحی مازولار پیشرفته و توانایی پردازش همزمان اطلاعات مکانی و معنایی در مدل یولو V8m باعث شده است این مدل در تشخیص و طبقه‌بندی دقیق عیوب پنل‌های خورشیدی، از سایر مدل‌ها عملکرد بهتری ارائه دهد. همچنین این نتایج بر اهمیت انتخاب صحیح معماری متناسب با نوع داده و ماهیت مسئله تأکید دارند، به‌ویژه در کاربردهای صنعتی که دقت و قابلیت اطمینان بالا ضروری است. نگاره ۵ روند پیشرفت آموزش سه مدل یولو را در طبقه‌بندی عیوب پنل‌های خورشیدی نشان می‌دهد. در قسمت الف، مدل یولو V8-CLS با ۱۰۰ دوره آموزش همگرایی سریع‌تری را تجربه کرده اما دقت نهایی آن نسبت به سایر مدل‌ها کمتر است؛ این موضوع به دلیل ساختار ساده‌تر و تعداد کمتر دوره‌های آموزشی است که ممکن است باعث شده مدل نتواند به طور کامل الگوهای پیچیده داده‌ها را یاد بگیرد. قسمت ب نمودار مربوط به مدل یولو V8 است که با ۱۲۰ دوره آموزش، همگرایی پایدارتر و بهبود تدریجی دقت را نشان می‌دهد. این نشان‌دهنده تعادل مناسب بین عمق مدل و تعداد دوره‌های آموزش است که باعث شده مدل در یادگیری ویژگی‌های مرتبط بهتر عمل کند. نهایتاً، قسمت ج مربوط به مدل یولو V8m است که با ۱۵۰ دوره آموزش، روندی بسیار پایدار و دقیق را طی کرده و کمترین مقدار تلفات را در طول آموزش داشته است. این امر نشان‌دهنده بهره‌گیری موفق این مدل از معماری پیشرفته‌تر و تنظیمات بهینه هایدپارامترها است که منجر به همگرایی بهتر، جلوگیری از بیش‌برازش و دستیابی به بالاترین دقت تشخیص شده است. به طور کلی، افزایش تعداد دوره‌های آموزش و پیچیدگی مدل به همراه تنظیم دقیق پارامترهای آموزش، از عوامل اصلی بهبود عملکرد و همگرایی مدل‌ها بوده‌اند.

به‌منظور بررسی عمیق‌تر عملکرد مدل‌ها، یک تحلیل خطا بر اساس نتایج جدول ۹ انجام شد. همان‌طور که

رزنت ۵۰ و شبکه عصبی بازگشتی هست. برتری مدل یولو V8m را می‌توان در میانگین دقت طبقه‌بندی، دقت پیش‌بینی و نرخ بازیابی در تمامی کلاس‌های شش‌گانه مشاهده کرد؛ به‌طوری‌که این مدل موفق شده است به میانگین دقتی برابر با $97/43\%$ دست یابد که بالاتر از سایر مدل‌ها است.

این عملکرد به‌ویژه در کلاس‌هایی مانند "فضولات پرندگان" و "پوشیده با برف" که تمایز بصری آن‌ها دشوارتر است نیز حفظ شده و دقت مدل همچنان بالا باقی مانده است. علت اصلی این عملکرد چشمگیر را می‌توان در معماری به‌روز و بهینه‌شده مدل یولو V8m جستجو کرد. این مدل از نسخه‌های میانی خانواده یولو V8 است و برخلاف نسخه‌های سبک‌تر مانند یولو V8-CLS، از لایه‌های عمیق‌تر و تعداد پارامترهای بیشتر بهره می‌برد. این ساختار پیچیده‌تر به مدل امکان می‌دهد تا ویژگی‌های دقیق‌تری از تصاویر استخراج کرده و الگوهای جزئی‌تر را در داده‌های ورودی شناسایی کند. به‌علاوه، یولو V8m از معماری یکپارچه‌ای برخوردار است که همزمان وظیفه تشخیص و طبقه‌بندی را انجام می‌دهد، در حالی‌که نسخه CLS صرفاً برای طبقه‌بندی طراحی شده و فاقد اطلاعات مکانی اشیاء است. همین تفاوت باعث شده که یولو V8-CLS با وجود سادگی و سرعت بیشتر، عملکردی پایین‌تر در شناسایی دقیق کلاس‌ها داشته باشد. مقایسه یولو V8m با مدل‌هایی مانند رزنت ۵۰ و VGG16 نیز نکات قابل توجهی را روشن می‌سازد. مدل رزنت ۵۰ با میانگین دقت $95/97\%$ عملکردی نسبتاً نزدیک به یولو V8m دارد، اما فاقد ساختار یکپارچه پردازش مکانی و ویژگی‌های چندمقیاسی است که در یولو V8m وجود دارد. همچنین، مدل VGG16 علی‌رغم معماری نسبتاً عمیق، فاقد مسیرهای بازگشتی^۱ است که باعث بهبود جریان گرادیان در شبکه می‌شوند. از سوی دیگر، مدل CNN پایه و شبکه عصبی بازگشتی ساختارهایی سبک و عمومی‌تر دارند که برای استخراج ویژگی‌های بصری پیچیده در داده‌های با تنوع بالا همچون تصاویر عیوب پنل، مناسب نیستند و

مشاهده می‌شود، مدل پیشنهادی یولو V8m در اکثر کلاس‌ها عملکرد بالاتری نسبت به سایر روش‌ها داشته است؛ به‌ویژه در کلاس‌های «آسیب فیزیکی» و «آسیب الکتریکی» که F1-score به ترتیب ۹۷/۵۴٪ و ۹۷/۴۸٪ به دست آمد.

با این حال، در کلاس‌هایی مانند «گرد و خاک» (F1=۹۷/۳۸) و «فضولات پرندگان» (F1=۹۷/۴۵) نرخ خطای بیشتری نسبت به سایر دسته‌ها مشاهده شد. دلیل اصلی این موضوع شباهت ظاهری الگوهای بافت و رنگ در این دو کلاس است؛ به‌طوری‌که در برخی تصاویر، لکه‌های ناشی از گرد و غبار از نظر بصری بسیار مشابه با اثرات فضولات پرندگان هستند. این امر موجب افزایش اشتباهات طبقه‌بندی در این دو کلاس شده است.

توجه به ابعاد مکانی عیوب است. استفاده از تصاویر پهپادی این مزیت را دارد که علاوه بر شناسایی نوع عیب، امکان تعیین موقعیت دقیق هر پنل معیوب در سطح مزرعه خورشیدی فراهم می‌شود. به این ترتیب می‌توان الگوهای توزیع مکانی عیوب را تحلیل نمود؛ به عنوان نمونه، احتمال تجمع گردوغبار یا فضولات پرندگان در نواحی خاصی از مزرعه بیشتر است یا آسیب‌های فیزیکی در لبه‌ها و مرزهای پنل‌ها شیوع بالاتری دارند. چنین تحلیل‌هایی نقش مهمی در برنامه‌ریزی تعمیرات پیشگیرانه و بهینه‌سازی عملیات نگهداری دارد.

اگرچه در این تحقیق از تصاویر فاقد مختصات مکانی استفاده شده است، اما چارچوب پیشنهادی قابلیت ادغام با داده‌های مکانی واقعی نظیر مختصات GPS^۱ ثبت شده توسط پهپاد را دارد. در کاربردهای عملی، می‌توان با ثبت موقعیت دقیق عکس‌ها و اتصال آن‌ها به نتایج مدل تشخیص عیب، تحلیل مکانی توزیع خرابی‌ها را در قالب نقشه‌های GIS پیاده‌سازی نمود. این تلفیق می‌تواند در تصمیم‌سازی‌های نگهداری پیش‌گیرانه و مدیریت بهینه پنل‌های خورشیدی بسیار مؤثر واقع شود. بررسی عملی این قابلیت به عنوان بخشی از کارهای آینده مد نظر قرار گرفته است.

یکی از محدودیت‌های این پژوهش، عدم پوشش گسترده شرایط آب‌وهوایی بسیار شدید مانند گردوغبار غلیظ، باران شدید یا یخ‌زدگی کامل در مجموعه داده مورد استفاده است. اگرچه مدل توانایی تشخیص در برخی شرایط نیمه‌سخت مانند گردوغبار سطحی و پوشش برفی را دارد، اما لازم است در مطالعات آینده، داده‌هایی از محیط‌های واقعی در شرایط جوی حاد نیز به کار گرفته شود تا پایداری و تصمیم‌پذیری مدل به‌طور کامل مورد ارزیابی قرار گیرد.

همچنین از آنجا که اندازه ورودی تصاویر در این پژوهش برابر ۶۴۰×۶۴۰ انتخاب شده است، امکان از دست رفتن جزئیات بسیار ظریف مانند میکروترک‌ها وجود دارد. اگرچه این ابعاد باعث تسریع پردازش و بهبود کارایی زمان واقعی

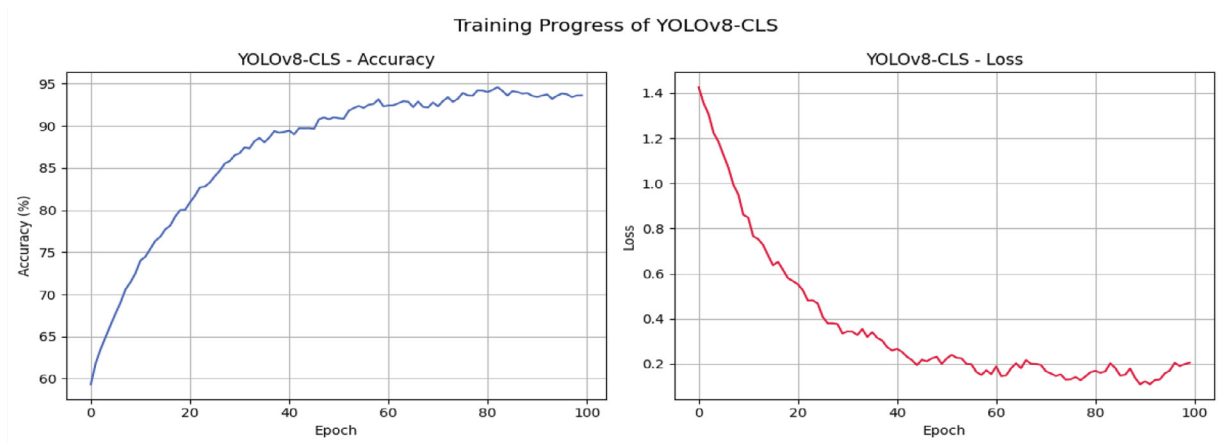
در مقابل، دسته‌هایی مانند «تمیز» و «پوشیده با برف» به دلیل تمایز بصری بیشتر (کنتراست بالا و مرزبندی واضح‌تر)، نرخ خطای کمتری داشته‌اند. این تحلیل نشان می‌دهد که علی‌رغم عملکرد برتر یولو V8m، همچنان تفکیک کلاس‌هایی با شباهت ظاهری بالا نیازمند بهره‌گیری از تکنیک‌های تکمیلی مانند استفاده از ویژگی‌های طیفی بیشتر، افزایش حجم داده‌های آموزشی برای کلاس‌های مشابه، یا به‌کارگیری مدل‌های ترکیبی مبتنی بر Transformerها هستند.

تحلیل نتایج نشان می‌دهد که مدل یولو V8m در طبقه‌بندی عیوب پنل‌های خورشیدی نسبت به سایر مدل‌های پایه مانند یولو V8 و یولو V8m-CLS دارای دقت بالاتری است. این برتری ناشی از معماری پیشرفته مدل است که شامل لایه C2f و Anchor-free Head می‌شود. لایه C2f با ترکیب ویژگی‌های چندسطحی امکان استخراج جزئیات ظریف عیوب نظیر ترک‌ها، نقاط داغ و آلودگی سطحی را فراهم می‌کند و Anchor-free Head موجب ساده‌تر شدن فرآیند پیش‌بینی موقعیت عیوب و کاهش خطاهای ناشی از جعبه‌های مرجع می‌شود. این ساختار باعث افزایش دقت و سرعت پیش‌بینی شده و پتانسیل بالای یولو V8m برای کاربرد در سامانه‌های پایش بلادرنگ را اثبات می‌کند.

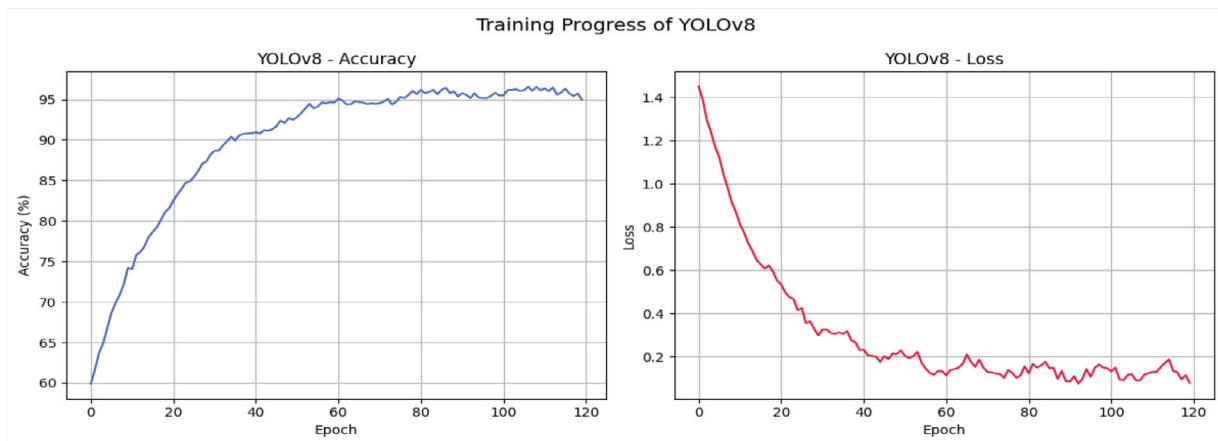
یکی از جنبه‌های مهم در پایش پنل‌های خورشیدی،

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (سپهر)


تشخیص و طبقه‌بندی خودکار عیوب پنل‌های خورشیدی با استفاده از ... / ۷۱



(الف)



(ب)



(ج)

نگاره ۵: روند پیشرفت آموزش سه مدل یولو در طبقه‌بندی عیوب پنل خورشیدی در شش کلاس مختلف. الف) مدل یولو V8-CLS با ۱۰۰ دوره آموزش و همگرایی سریع ولی دقت پایین‌تر، ب) مدل یولو V8 با ۱۲۰ دوره و همگرایی باثبات‌تر، و ج) مدل یولو V8m با ۱۵۰ دوره آموزش، روندی پایدار و دقیق‌تر با کمترین مقدار تلفات

علاوه بر ارزیابی شاخص‌های دقت، دقت پیش‌بینی و بازیابی، زمان استخراج مدل‌ها نیز برای بررسی قابلیت اجرای عملیاتی در محیط‌های واقعی مورد اندازه‌گیری قرار گرفت.

اما در کاربردهای حساس‌تر، استفاده از تصاویر با وضوح بالاتر یا تکنیک‌های پردازش تطبیقی می‌تواند به شناسایی دقیق‌تر آسیب‌های میکروسکوپی کمک کند.

بهینه شبکه‌های خورشیدی دارد، جایی که شناسایی به موقع و هدفمند نقص‌ها باعث افزایش دوام تجهیزات و کاهش خرابی‌های گسترده می‌شود. در مجموع، این پژوهش گامی مؤثر در جهت توسعه فناوری‌های هوشمند تشخیص عیوب پنل‌های خورشیدی است که می‌تواند تأثیر مستقیم و مثبت بر افزایش بهره‌وری و کاهش هزینه‌های نگهداری در صنعت انرژی‌های تجدیدپذیر داشته باشد.

از سوی دیگر، توسعه آینده این پژوهش می‌تواند بر ترکیب مدل یولو V8m با سامانه‌های اطلاعات مکانی (GIS) و نقشه‌برداری پهپادی متمرکز شود. این ترکیب نه تنها دقت تشخیص و طبقه‌بندی عیوب را افزایش می‌دهد، بلکه الگوهای توزیع مکانی آن‌ها را نیز آشکار می‌کند. چنین رویکردی امکان ارائه راهکارهای هوشمند برای نگهداری پیش‌بینانه و بهینه‌سازی عملکرد مزارع خورشیدی در مقیاس وسیع را فراهم می‌کند.

با توجه به این موفقیت‌ها، پیشنهاد می‌شود در تحقیقات آینده، بهره‌گیری از داده‌های چند طیفی و تصویربرداری حرارتی برای افزایش دقت تشخیص عیوبی که در طیف مرئی قابل رؤیت نیستند، مورد بررسی قرار گیرد. استفاده از روش‌های یادگیری چند وظیفه‌ای^۱ به منظور تشخیص همزمان نوع عیب، شدت آسیب و تخمین عمر باقی‌مانده پنل‌ها، می‌تواند ابعاد جدیدی از هوشمندسازی را به این حوزه وارد کند. علاوه بر این گسترش داده‌های آموزشی با منابع متنوع و به‌کارگیری یادگیری انتقالی، باعث افزایش تعمیم‌پذیری مدل در شرایط واقعی و محیط‌های مختلف خواهد شد. همچنین به‌عنوان یکی از مسیرهای توسعه آتی، گردآوری مجموعه‌داده‌هایی با تنوع جغرافیایی و اقلیمی بیشتر می‌تواند به افزایش تعمیم‌پذیری مدل و بهبود دقت تشخیص در شرایط واقعی کمک نماید.

لازم به ذکر است که تصاویر مورد استفاده در این پژوهش صرفاً شامل داده‌های بصری RGB و خاکستری هستند و از آنجا که برخی آسیب‌های پنل‌های خورشیدی

زمان استنتاج نشان‌دهنده مدت زمان لازم برای پردازش یک تصویر ورودی و تولید خروجی است و شامل تمام مراحل پیش‌پردازش، عبور از شبکه و تولید برجسب طبقه‌بندی می‌شود. نتایج تجربی نشان داد که مدل پیشنهادی یولو V8m با معماری سبک و بهینه‌شده، هر تصویر را به طور میانگین در حدود ۶ ثانیه پردازش می‌کند، در حالی که مدل‌های پایه مانند VGG16 و رزنت ۵۰ به ترتیب حدود ۶ و ۱۳ ثانیه زمان نیاز داشتند. این تفاوت قابل توجه نشان‌دهنده سرعت بالای یولو V8m و پتانسیل آن برای پردازش بلادرنگ و استفاده در سامانه‌های پیش‌پهپادی با حجم بالای تصاویر است. به این ترتیب، مدل پیشنهادی، ترکیبی از دقت بالا و زمان استنتاج کم را فراهم می‌آورد که آن را برای پیاده‌سازی عملیاتی در مقیاس وسیع مناسب می‌نماید.

۵- نتیجه‌گیری و کارهای آینده

تشخیص دقیق و سریع عیوب پنل‌های خورشیدی، یکی از چالش‌های کلیدی در بهینه‌سازی بهره‌وری و افزایش طول عمر سیستم‌های انرژی تجدیدپذیر به شمار می‌رود. توسعه روش‌های هوشمند و خودکار برای پایش این عیوب، نقش مهمی در کاهش هزینه‌های نگهداری، بهبود کارایی و تضمین پایداری انرژی تولیدی دارد. نتایج این مطالعه نشان می‌دهد که مدل یولو V8m با بهره‌گیری از معماری بهینه و تنظیمات دقیق، توانسته است بهبود قابل توجهی در تشخیص و طبقه‌بندی عیوب پنل‌های خورشیدی نسبت به مدل‌های مرجع کلاسیک ارائه دهد. این موفقیت‌ها عمدتاً ناشی از طراحی سبک و کارآمد یولو V8m و فرآیند آموزش مناسب با تنظیمات بهینه‌های پارامترها است که ضمن حفظ سرعت پردازش، دقت تشخیص را افزایش داده است. تحلیل مکانی عیوب نشان داد که بهره‌گیری از داده‌های مکانی در کنار مدل‌های یادگیری عمیق می‌تواند نه تنها به تشخیص دقیق‌تر، بلکه به بهبود برنامه‌ریزی نگهداری و کاهش هزینه‌های عملیاتی منجر شود. این موضوع اهمیت بسیار بالایی برای مدیریت

تعارض منافع

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

References

- 1- Abdelsattar, M., Abdelmoety, A., Ismeil, M. A., & Emad-Eldeen, A. (2025). Automated defect detection in solar cell images using deep learning algorithms. *IEEE Access*, 13, 4136–4157. <https://doi.org/10.1109/ACCESS.2024.3525183>
- 2- Aktouf, L., Shivanna, Y., & Dhimish, M. (2024). High-precision defect detection in solar cells using YOLOv10 deep learning model. *Solar*, 4(4), 639–659. <https://doi.org/10.3390/solar4040030>
- 3- Ali, M. L., & Zhang, Z. (2024). The YOLO framework: A comprehensive review of evolution, applications, and benchmarks in object detection. *Computers*, 13(12), 336. <https://doi.org/10.3390/computers13120336>
- 4- Balcioglu, Y. S., Sezen, B., & Cubukcu Cerasi, C. (2023). Solar cell busbars surface defect detection based on deep convolutional neural network. *IEEE Latin America Transactions*, 21(2), 242–250. <https://doi.org/10.1109/TLA.2023.10015216>
- 5- Basheer, M. Y. I., Ali, A. M., Hamid, N. H. A., & Yusoff, M. Z. M. (2024). Solar panel defect detection and panel localization using Yolov5. *International Conference on Innovation & Entrepreneurship in Computing, Engineering & Science Education (InvENT)*, 139–149. https://doi.org/10.2991/978-94-6463-589-8_15
- 6- Dakamayi, Y., Sadeghzadeh, S. M., & Dakamayi, M. (2021). Intelligent fault detection and diagnosis in solar systems using machine learning methods. *2nd International Conference on Modern Research in Electrical Engineering, Computer, Mechanics and Mechatronics in Iran and the Islamic World*, Karaj, Iran. <https://civilica.com/doc/1245859>
- 7- Demirci, M. Y., Beşli, N., & Gümüştü, A. (2024). An improved hybrid solar cell defect detection approach using generative adversarial networks and weighted classification. *Expert Systems with Applications*, 252(A),

مانند ترک‌های داخلی، نقص در سلول‌ها یا اتصالات، در تصاویر ظاهری قابل تشخیص نیستند، شناسایی این نوع عیوب در چارچوب پژوهش حاضر ممکن نبوده و به‌عنوان یکی از محدودیت‌های پژوهش در نظر گرفته می‌شود. پیشنهاد می‌شود در مطالعات آینده، از داده‌های حرارتی یا ترموگرافی به‌صورت ترکیبی استفاده شود تا پوشش دقیق‌تری از وضعیت داخلی پنل‌ها فراهم شود.

در مطالعات آینده، بررسی تأثیر افزایش وضوح تصاویر ورودی یا بهره‌گیری از تکنیک‌های بزرگ‌نمایی ناحیه‌ای می‌تواند در بهبود تشخیص عیوب بسیار ریز نظیر میکروترک‌ها مفید واقع شود.

همچنین در گام‌های آتی، می‌توان چارچوب پیشنهادی را در سناریوهای صنعتی واقعی توسعه داد؛ برای نمونه، پیاده‌سازی سیستم پایش خودکار بر بستر پهپادهای مجهز به GPS و دوربین مادون‌قرمز به‌منظور پایش مزرعه‌های خورشیدی در مقیاس وسیع، یا ادغام مدل تشخیص عیب با پلتفرم‌های اینترنت اشیا (IoT¹) مانند Azure IoT Hub یا AWS IoT Core برای ارسال بلادرنگ هشدارهای خرابی و نگهداری هوشمند. همچنین، تحلیل‌های مکانی براساس داده‌های موقعیت‌یابی تصاویر می‌تواند به تولید نقشه‌های حرارتی خرابی‌ها و بهینه‌سازی چیدمان پنل‌ها منجر شود.

علاوه بر این، یکی دیگر از مسیرهای توسعه آینده، به‌کارگیری مدل‌های سبک‌تر نظیر یولو-MobileNet یا یولو-Tiny است. این مدل‌ها به‌دلیل کاهش نیاز محاسباتی و سرعت بالاتر در استنتاج، گزینه‌ای مناسب برای پیاده‌سازی عملی سیستم‌های پایش هوشمند بر روی پهپادها یا دستگاه‌های لبه‌ای به‌شمار می‌روند. استفاده از این رویکرد می‌تواند قابلیت به‌کارگیری گسترده‌تر و کم‌هزینه‌تر سامانه‌های پیشنهادی را در محیط‌های صنعتی و واقعی فراهم آورد.

- Communication and Information (ICETCI), 820–827. <https://doi.org/10.1109/ICETCI61221.2024.10594221>
- 16- Liu, Y., Wu, Y., Yuan, Y., & Zhao, L. (2024). Deep learning-based method for defect detection in electroluminescent images of polycrystalline silicon solar cells. *Optics Express*, 32, 17295–17317.
- 17- Lu, S., Wu, K., & Chen, J. (2023). Solar cell surface defect detection based on optimized YOLOv5. *IEEE Access*, 11, 71026–71036. <https://doi.org/10.1109/ACCESS.2023.3294344>
- 18- Mahmud, A., Shishir, M. S. R., Hasan, R., & Rahman, M. (2023). A comprehensive study for solar panel fault detection using VGG16 and VGG19 convolutional neural networks. 2023 26th International Conference on Computer and Information Technology (ICCIT), 1–6. <https://doi.org/10.1109/ICCIT60459.2023.10441429>
- 19- Mavaddati, S., & Razavi, M. (2025). An optimized YOLO-ViT hybrid model for enhanced precision in rice classification and quality assessment. *International Journal of Engineering*, 38(10), 2435–2450. <https://doi.org/10.5829/ije.2025.38.10a.19>
- 20- Pandey, H., & Dhavale, S. (2024). A survey on artificial intelligence based photovoltaic cell defect detection techniques. 2024 IEEE Pune Section International Conference (PuneCon), 1–6. <https://doi.org/10.1109/PuneCon63413.2024.10895155>
- 21- PythonAfroz. (n.d.). Solar panel images dataset. Kaggle. <https://www.kaggle.com/datasets/pythonafroz/solar-panel-images/data>
- 22- Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14, 6086. <https://doi.org/10.1038/s41598-024-56706-x>
- 23- Ranjbarzadeh, R., Crane, M., & Bendeche, M. (2025). The impact of backbone selection in YOLOv8 models on brain tumor localization. *Iranian Journal of Computer Science*. <https://doi.org/10.1007/s42044-025-00198-z>
- 24- Shafiei, A., Kameli, V., & Grailu, H. (2023). Improved defect detection in photovoltaic panels through deep learning and decision tree-based classifiers. *SSRN*. <https://ssrn.com/abstract=4519346>
124230. <https://doi.org/10.1016/j.eswa.2024.124230>
- 8- Fasihi, A., & Dakiya, A. (2024). Investigation of faults and defects in photovoltaic systems and solar panels in electricity generation. 10th International Conference on Electrical, Computer and Mechanical Engineering, Tehran, Iran. <https://civilica.com/doc/2120545>
- 9- Go, S.-E., Kim, J.-H., Chuluunsaikhan, T., Choi, W.-S., Choi, S.-H., & Nasridinov, A. (2024). Unified generative data augmentation for efficient solar panel soiling localization. *Electronics*, 13(24), 4859. <https://doi.org/10.3390/electronics13244859>
- 10- Hijjawi, U., Lakshminarayana, S., Xu, T., Malfense Fierro, G. P., & Rahman, M. (2023). A review of automated solar photovoltaic defect detection systems: Approaches, challenges, and future orientations. *Solar Energy*, 266, 112186. <https://doi.org/10.1016/j.solener.2023.112186>
- 11- Huang, J., Zeng, K., Zhang, Z., & Zhong, W. (2023). Solar panel defect detection design based on YOLO v5 algorithm. *Heliyon*, 9(8), e18826. <https://doi.org/10.1016/j.heliyon.2023.e18826>
- 12- Karaca Aydemir, B. K., Telatar, Z., Güney, S., & et al. (2025). Detecting and classifying breast masses via YOLO-based deep learning. *Neural Computing and Applications*, 37, 11555–11582. <https://doi.org/10.1007/s00521-025-11153-1>
- 13- Lakshmi, P. S., Sivagamasundari, S., & Rayudu, M. S. (2024). Solar panel fault detection using low complex convolution neural network deep learning model. *International Journal of Engineering Trends and Technology*, 72(8), 18–26. <https://doi.org/10.14445/22315381/IJETT-V72I8P103>
- 14- Li, J., Li, H., Wu, Y., Zhou, H., Manfredi, L., Li, P., & Zhang, H. (2023). Deep learning based defect detection algorithm for solar panels. 2023 WRC Symposium on Advanced Robotics and Automation (WRC SARA), 438–443. <https://doi.org/10.1109/WRCsARA60131.2023.10261859>
- 15- Liang, Z., Xu, M., Su, Y., Chen, H., & Jin, G. (2024). A survey of solar panel surface defect detection methods based on improved VGG-16 model. 2024 IEEE 4th International Conference on Electronic Technology,

25- Singh, R., Kashyap, R., & Kumar, A. (2024). Prominent solution for solar panel defect detection using AI-based computer vision technology with IoT sensors in the solar panel manufacturing industry. *International Journal of Information Technology*. <https://doi.org/10.1007/s41870-024-02212-2>

26- Sirisha, U., Praveen, S. P., Srinivasu, P. N., et al. (2023). Statistical analysis of design aspects of various YOLO-based deep learning models for object detection. *International Journal of Computational Intelligence Systems*, 16, 126. <https://doi.org/10.1007/s44196-023-00302-w>

27- Song, X., & Liu, Y. (2023). Defect detection of solar panel based on DenseNet network. *Advances in Transdisciplinary Engineering*, 35, 661–669. <https://doi.org/10.3233/ATDE230093>

28- Terven, J., Cordova-Esparza, D. M., Romero-González, J. A., et al. (2025). A comprehensive survey of loss functions and metrics in deep learning. *Artificial Intelligence Review*, 58, 195. <https://doi.org/10.1007/s10462-025-11198-7>

29- Yang, C., Sun, F., Zou, Y., Lv, Z., Xue, L., Jiang, C., Liu, S., Zhao, B., & Cui, H. (2024). A survey of photovoltaic panel overlay and fault detection methods. *Energies*, 17(4), 837. <https://doi.org/10.3390/en17040837>

30- Zyout, I., & Oatawneh, A. (2020). Detection of PV solar panel surface defects using transfer learning of the deep convolutional neural networks. 2020 *Advances in Science and Engineering Technology International Conference (ASET)*, 1–4. <https://doi.org/10.1109/ASET48392.2020.9118382>

COPYRIGHTS

©2026 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/)

