

DOI: 10.19650/j.cnki.cjsi.J2513805

基于 MFES-YOLOV8n 的光伏电池缺陷检测方法*

陈俊生, 陈沂蒙, 刘明杰, 朴昌浩
(重庆邮电大学自动化学院 重庆 400065)

摘要:针对现有目标检测方法在光伏电池电致发光图像中存在的小目标漏检率高、复杂背景干扰鲁棒性不足及跨尺度缺陷检测能力有限等问题,提出基于 MFES-YOLOV8n 的缺陷检测模型,旨在提升工业场景下的检测精度与效率。首先,在主干网络中嵌入 C2f-ST 特征提取模块,通过 Swin Transformer 的窗口自注意力机制,增强微小缺陷的局部-全局特征关联,结合残差连接保留浅层细节特征,提升细粒度特征提取能力;其次,设计 ES-SPPCSPC 特征表达模块,融合群卷积与增强型 SimAM 注意力机制,通过能量基、通道和空间三重注意力协同优化,动态抑制背景噪声,增强缺陷特征特异性;最后,构建 MSFF-Neck 多尺度特征融合模块,采用尺度序列特征融合和三重特征编码策略,实现深层语义与浅层细节的互补交互,缓解多尺度特征衰减问题。实验在 PVEL-AD 数据集上验证了模型的有效性,结果表明,该模型以 6.1 M 参数量达到 0.897 的 mAP@0.5,较基准模型 YOLOv8n 提升 3.0%。本研究通过“细粒度特征提取—跨尺度语义增强—多层级特征融合”的递进式优化,突破了传统模型在多类别跨尺度缺陷检测中的性能瓶颈,为工业场景提供了高精度、轻量化且适配边缘计算的缺陷检测方案,在维持低计算复杂度的同时,满足工业场景对实时性与可靠性的要求,为推动光伏产业质量控制与智能化运维提供了技术支持。

关键词: MFES-YOLOv8; 光伏电池缺陷检测; 特征提取; 特征表达; 特征融合

中图分类号: TH17 TM914.4 **文献标识码:** A **国家标准学科分类代码:** 520.20

A defect detection method for photovoltaic cells based on MFES-YOLOV8n

Chen Junsheng, Chen Yimeng, Liu Mingjie, Piao Changhao

(College of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: To address the issues of high missed detection rates for small targets, insufficient robustness against complex background interference, and limited cross-scale defect detection capabilities in existing target detection methods for photovoltaic cell electroluminescence images, a defect detection model based on MFES-YOLOV8n is proposed to enhance detection accuracy and efficiency in industrial scenarios. First, a C2f-ST feature extraction module is embedded into the backbone network, utilizing the window-based self-attention mechanism of Swin Transformer to enhance local-global feature associations for micro-defects, combined with residual connections to preserve shallow-layer detail features. Therefore, the fine-grained feature extraction capabilities are improved. Secondly, an ES-SPPCSPC feature representation module is designed, integrating group convolution with an enhanced SimAM attention mechanism, achieving dynamic suppression of background noise and enhancement of defect-specific features through synergistic optimization of energy-based, channel, and spatial attention. Finally, an MSFF-Neck multi-scale feature fusion module is established, employing scale-sequential feature fusion and triple feature encoding strategies to enable complementary interactions between deep semantic and shallow detail features, mitigating multi-scale feature degradation. Experiments on the PVEL-AD dataset validate the model's effectiveness. Results show that it achieves an mAP@0.5 of 0.897 with 6.1 M parameters, improving by 3.0% over the baseline YOLOv8n. Through a progressive optimization strategy of “fine-grained feature extraction, cross-scale semantic enhancement, and multi-level feature fusion”, this study overcomes performance bottlenecks in multi-category and cross-scale defect detection of traditional models, providing a high-precision, lightweight, and edge-computing-compatible defect detection solution for industrial scenarios. While maintaining low computational complexity, it meets the demands for real-time performance and reliability in industrial

收稿日期: 2025-03-06 Received Date: 2025-03-06

* 基金项目: 国家重点研发计划(2022YFE0101000)项目资助

applications, offering technical support for advancing quality control and intelligent maintenance in the photovoltaic industry.

Keywords: MFES-YOLOv8; photovoltaic cell defect detection; feature extraction; feature representation; feature fusion

0 引言

太阳能光伏发电技术是解决能源危机和实现“双碳”目标的重要途径之一^[1]。光伏电池作为光伏发电系统的核心部件,其质量直接影响系统可靠性和发电效率。然而,电池板在生产过程中由于工艺和材料等因素的影响,其表面易出现裂纹、污渍及断栅等多种缺陷^[2]。这些缺陷不仅降低电池板的光电转换效率,还可能引发长期使用中的安全隐患^[3-4]。因此,开发高效、可靠的缺陷检测技术对提升光伏产品质量和生产效率具有重要意义。光伏组件缺陷检测技术主要分为电气检测^[5-7]与图像分析两类。在光伏组件检测领域,传统电气检测法虽可通过电流电压特性识别系统异常,但受限于精密检测设备的高昂成本与复杂布线要求,难以实现缺陷位置的精准空间定位,实际工程中仍需配合人工目视复检,制约了大规模电站的运维效率。随着光学成像技术的发展,无损检测方法逐步形成两大技术路线:1)基于载流子复合发光原理的电致发光(electroluminescence, EL)成像法,利用硅片受激发光特性可清晰呈现裂纹、断栅等微米级结构缺陷;2)红外热成像法,通过捕捉组件温度场分布差异识别热斑、脱层等宏观故障。当前红外检测技术在小规模场景中虽可通过便携设备实施,但在兆瓦级电站应用中仍面临人工巡检效率低、检测覆盖率不足等瓶颈问题。相较之下,EL成像凭借亚毫米级的分辨能力,可清晰呈现电池片内部微观结构,为自动化缺陷识别算法提供高信噪比的图像数据基础。

近年来,基于深度学习的目标检测算法在光伏电池缺陷检测领域取得了显著进展。基于深度学习的缺陷检测方法可分为有监督与无监督两类技术路线。无监督方法通过挖掘数据内在异常模式实现缺陷判别,无需依赖人工标注信息。而有监督方法则依赖精确标注的缺陷位置及类别标签进行模型训练,使网络能够同时实现缺陷定位、分类及尺寸估计^[8]。在标注数据充足的条件下,有监督方法通常表现出更优的检测精度。当前基于有监督学习的缺陷目标检测算法主要遵循一阶段与两阶段的技术框架。一阶段方法以YOLO^[9](you only look once)、单次多框检测器^[10](single shot multibox detector, SSD)等算法为典型代表,通过端到端架构实现缺陷的快速定位与分类;而两阶段方法则以区域卷积神经网络(region-based convolutional neural networks, R-CNN)^[11]及其改进型快速R-CNN(fast R-CNN, Faster R-CNN)^[12]为核心范式,通过区域建议网络与精细检测的级联流程提升检测精度。

在一阶段方法方面,吕游等^[13]在EfficientNet网络中引入卷积注意力模块(convolutional block attention module, CBAM)模块,通过抑制冗余特征并增强空间特征提取能力,显著提高了模型性能。王育欣等^[14]将双通道特征金字塔嵌入YOLOv5中,增强了在复杂背景下的小目标检测能力。陈亚芳等^[15]针对YOLOv5算法进行了系统性改进,通过引入通道注意力机制(coordinate attention, CA)注意力机制和双向特征金字塔网络,显著提升了裂纹、断栅等5类缺陷的检测精度。项新建等^[16]提出一种基于SSDLite的多层特征融合轻量化目标检测方法,采用MobileNetV2作为SSDLite模型的骨干网络,并从中提取3个不同层次的特征层进行特征融合,针对不同缺陷的尺寸特点,对模型中的先验框的大小也进行了重新设计,在MobileNetV2的瓶颈结构中引入CBAM注意力机制,以提高模型的检测精度。廖力达等^[17]提出OD-YOLO模型以解决多晶硅光伏电池EL图像中的复杂背景干扰问题,通过TwiceConv-OD模块过滤背景噪声,结合anchor-plus1策略优化正样本分配,并采用K-means++算法自适应锚框尺寸。王道累等^[18]提出一种基于SSD改进的热斑缺陷检测方法,将SSD骨干神经网络更换为ResNet101,并提出一种新型注意力网络,该网络能学习同一通道特征图区域间的关系。文献[19]提出了ASDD-Net深度学习算法,利用空间转深度(space to depth, SPD)模块有效提取边缘和细粒度信息;提出的增强型跨阶段局部网络融合(enhanced cross-stage feature fusion, EC2f)模块和混合注意力CSP网络(hybrid attention CSP network, HAC3)模块被置于网络不同位置,以增强特征提取能力和改善特征融合效果,从而提升模型对不同尺寸和形状缺陷的感知能力。此外,在第2个检测头前放置MobileViT_CA模块,以平衡全局与局部信息的感知,进一步增强了检测头的性能。

二阶段方法方面,季瑞瑞等^[20]针对光伏组件红外图像中热斑目标小、难检测的问题,将Swin Transformer作为Faster R-CNN模型中的特征提取模块,捕获图像的全局信息,建立特征之间的依赖关系,提高模型的建模能力;进一步利用加权双向特征金字塔网络(bidirectional feature pyramid network, BiFPN)进行特征融合,改善了热斑故障由于目标小和特征不明显容易被模型忽略掉的问题;同时为了抑制光伏红外图像中背景和噪声的干扰,加入轻量级注意力模块CBAM,使模型更加关注重要通道和关键区域,提高对热斑故障检测精度。文献[21]针对复杂背景干扰下如何准确识别海上浮动太阳能发电站光伏板上的灰尘堆积的问题,提出了一个探索性框架,实现

与现有图像识别模型的兼容性扩展,利用基于色调-亮度-饱和度(hue-lightness-saturation, HLS)色彩空间的灰尘特征增强模块,结合 Mask R-CNN 验证了框架的可行性与有效性。

尽管现有方法在一定程度上取得了进展,但仍面临一些挑战:1)小目标缺陷检测性能不足:光伏电池 EL 图像中的微裂纹、断栅等小目标缺陷(边界框与图像面积之比的中位数在 0.08%~0.58%的目标分为小目标^[22])因分辨率低、特征表征能力弱,现有方法易受邻近电池片纹理干扰,导致微小缺陷漏检率较高;2)复杂背景干扰下的检测鲁棒性不足:低电流注入导致的组件明暗片分布不均(如边缘亮度衰减、局部反光伪影)与缺陷区域存在视觉相似性,使得传统方法在复杂背景噪声下误检率显著上升;3)多类别多尺度缺陷检测能力受限:现有模型对裂纹(细长条状)、碎片(不规则块状)等跨尺度缺陷的敏感度差异较大,尤其在小目标缺陷与复杂背景共存的场景下,多尺度特征融合不充分导致检测结果欠佳。

针对上述问题,本研究基于 YOLOv8 框架提出 MFES-YOLOv8n(multi-scale feature fusion and enhanced SimAM-YOLOv8n)检测网络,通过系统性结构优化实现性能突破。相较于传统方法在小目标检测、复杂背景鲁棒性和多尺度缺陷检测中的局限性,本方法通过以下针对性改进实现性能提升:1)特征提取优化:针对光伏电池 EL 图像中小目标缺陷(如裂纹、断栅)特征表征弱、易受邻近纹理干扰的问题,设计 C2f-ST(CSPDarknet53 to 2-stage FPN-swin transformer)特征提取模块,将 Swin Transformer^[20]的窗口自注意力机制嵌入主干网络末端,窗口划分策略通过动态局部-全局特征关联,增强细长边缘和局部断裂特征的捕捉能力;残差连接保障浅层细节特征的传递效率,从而降低小目标漏检率。相较于传统卷积网络依赖固定感受野的局限,C2f-ST 通过自适应特征建模提升了细粒度特征提取能力;2)特征表达增强:针对复杂背景干扰(如亮度衰减、反光伪影)导致的误检问题,构建 ES-SPPCSPC(ES-spatial pyramid pooling-cross stage partial channel)模块,融合群卷积(group convolution, GConv)与 Enhanced SimAM 注意力机制,群卷积通过降低计算冗余提升效率,Enhanced SimAM 通过能量基、通道和空间三重注意力协同优化,动态抑制背景噪声并增强缺陷特征特异性。具体而言,能量基注意力通过特征方差分析抑制伪影干扰,通道注意力强化缺陷光谱差异,空间注意力聚焦几何结构特征,从而提升复杂场景下的检测鲁棒性;3)特征融合重构:针对多尺度缺陷(如黑芯、裂纹)检测能力不足的问题,提出 MSFF-Neck(multiscale feature fusion neck)模块,通过尺度序列特征融合(scale-sequential feature fusion, SSFF)和三重特征编

码(triple feature encoding, TFE)实现深层语义与浅层细节的互补交互。SSFF 通过 3D 特征重组整合 P4、P6、P8 层特征,降低大尺度缺陷的边界定位误差;TFE 通过大尺寸特征图放大增强小尺度缺陷的细节感知能力,从而缓解多尺度特征衰减问题,提升跨尺度检测精度。

上述方法通过“细粒度特征提取—跨尺度语义增强—多层次特征融合”的递进式框架,针对性地解决了光伏电池缺陷检测中的核心挑战。相较于传统方法依赖单一模块优化或简单堆叠,本方法的模块设计基于 EL 图像特性,具有明确的理论依据和协同优化机制,显著提升了检测精度与鲁棒性,为工业级 EL 图像缺陷识别提供了高效且可扩展的解决方案。

1 MFES-YOLOV8n 的缺陷检测网络

YOLOv8 作为深度学习领域经典的一阶段目标检测方法^[23],其轻量化架构与高精度的平衡性,通过无锚点设计和 C2f 模块优化,在保持低参数数量的同时实现工业级检测精度,适配嵌入式设备实时推理需求。虽然 YOLO 网络已经发展出诸多版本,但是 YOLOv9、YOLO11、YOLOv12 与 YOLOv8 的检测头完全相同,特征金字塔网络(feature pyramid network, FPN)和路径聚合网络(path aggregation network, PANet)也仅有模块上的差异,因此选择 YOLOv8 作为基础模型进行改进。YOLOv8 提供多个版本,包括 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l 和 YOLOv8x,不同版本在精度和速度之间存在一定的权衡,能够满足不同应用场景的需求。

针对工业场景中光伏电池缺陷检测的准确性、鲁棒性和实时性的需求,在 YOLOv8n 基础上设计了 MFES-YOLOV8n 缺陷检测网络,其架构如图 1 所示。

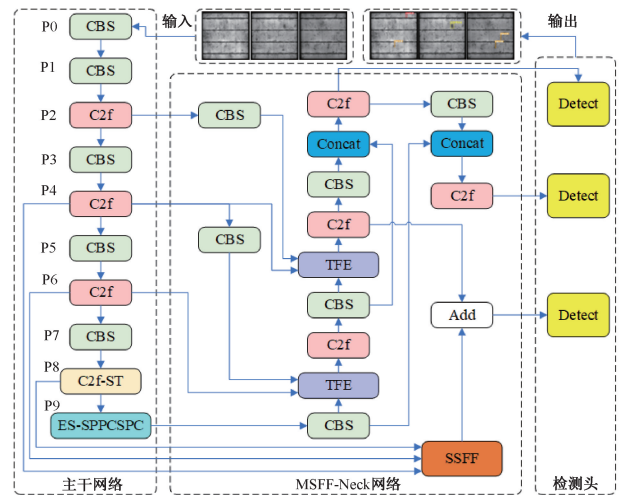


图1 MFES-YOLOV8n 网络结构

Fig. 1 MFES-YOLOV8n network structure

MFES-YOLOV8n 网络通过 3 阶段协同架构实现高效缺陷检测:1) 主干网络优化阶段, C2f-ST 模块以 Swin Transformer 的窗口自注意力机制为核心, 通过局部窗口划分与全局残差连接, 强化微小缺陷(如裂纹、断栅)的空间特征关联性, 同时保留浅层纹理信息;2) 跨尺度特征重组阶段, ES-SPPCSPC 模块利用群卷积与深度可分离卷积降低计算冗余, 并通过 Enhanced SimAM 注意力机制动态分配能量基、通道与空间分支的权重, 实现复杂背景下多尺度缺陷特征的解耦与强化;3) 多层次特征精调阶段, MSFF-Neck 模块通过 SSFF 与 TFE 的协同设计, 将 P4 层的高分辨率细节特征与 P6、P8 层的全局语义信息融合, 结合 3D 池化与特征图放大策略, 优化跨尺度缺陷的定位精度。三模块以“细粒度特征提取—跨尺度语义增强—多层次特征融合”的递进式流程协同工作, 在维持 YOLO 系列高效推理特性的基础上, 显著提升了模型对复杂工业场景中多类别、多尺度缺陷的检测鲁棒性。

1.1 C2f-ST 特征提取模块

为提升网络的特征提取能力, 在 YOLOv8 主干网络中的最后一个 C2f 模块采用 ST (Swin Transformer), 构建了 C2f-ST 结构, 如图 2 所示。

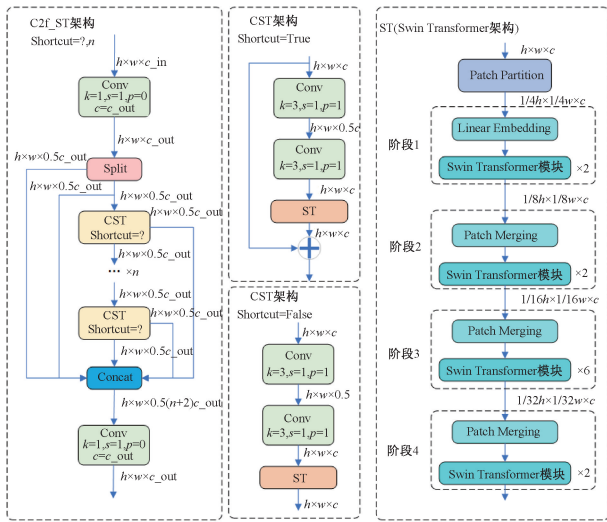


图 2 C2f-ST 网络结构

Fig. 2 C2f-ST network infrastructure

Swin Transformer 作为一种先进的视觉 Transformer 架构, 凭借其在多尺度特征提取和长距离依赖建模方面的显著优势, 能够高效捕捉图像中的全局与局部信息。将 Swin Transformer 嵌入 YOLOv8 的 C2f 模块, 增强了网络在复杂背景下对小目标缺陷的特征提取能力。通过多层次的特征融合和多尺度特征表示, C2f-ST 能够提升模型在光伏电池缺陷检测中的精度和鲁棒性, 尤其在面对复杂的背景干扰时, 仍能准确捕捉细微的缺陷特征信息。

Swin Transformer 是一种具有层次性设计的视觉 Transformer 架构, 其核心特征在于通过“窗口”机制对图像进行分割, 从而有效减少计算复杂度并提升计算效率。在传统的 Transformer 架构中, 计算每个 token 之间的关系导致计算量随着图像尺寸的增大而急剧增加, 尤其在高分辨率图像处理时, 这种计算开销尤为显著。而 Swin Transformer 通过采用局部自注意力机制和逐层特征处理, 有效降低了计算成本, 同时保留了图像的全局信息。

具体而言, Swin Transformer 首先将输入图像通过补丁分割模块切割为不重叠的 4 pixels×4 pixels 补丁, 接着通过线性投影层实现像素空间到高维特征空间的映射转换, 生成适合 Transformer 处理的特征表示。随后, Swin Transformer 通过多层 Swin Transformer Blocks 中的自注意力机制和多层感知机 (multi-layer perceptron, MLP) 进一步提取图像特征, 这些块是 Swin Transformer 的核心计算单元。图 3 展示了这一核心计算模块的具体结构。




图 3 两个连续的 Swin Transformer 模块

Fig. 3 Two successive Swin Transformer blocks

随着网络深度的增加, Swin Transformer 在每个阶段逐步合并补丁, 降低分辨率并增加特征维度, 从而构建层次化的特征表示。在此过程中, 每个阶段 (从 Stage 1~4) 包括 Swin Transformer 模块和 Patch Merging 操作, 逐步进行下采样并提取多尺度的特征图, 最终生成适用于多尺度任务的特征表示。

每个 Swin Transformer 块包含窗口多头自注意力 (window-based multi-head self-attention, W-MSA) 或移位窗口多头自注意力 (shifted window multi-head self-attention, SW-MSA): 在局部窗口内计算自注意力, 如式 (1) 所示。

$$\begin{cases} \underline{z}^l = W - MSA(LN(\underline{z}^{l-1})) + \underline{z}^{l-1} \\ \underline{z}^l = MLP(LN(\underline{z}^l)) + \underline{z}^l \\ \underline{z}^{l+1} = SW - MSA(LN(\underline{z}^l)) + \underline{z}^l \\ \underline{z}^{l+1} = MLP(LN(\underline{z}^{l+1})) + \underline{z}^{l+1} \end{cases} \quad (1)$$

其中, \underline{z}^l 和 \underline{z}^l 分别为第 l 块的 (S) W-MSA 模块和 MLP 模块的输出特征。W-MSA 和 SW-MSA 分别表示使用常规和滑动窗口划分配置的基于窗口的多头自注意力机制。

Swin Transformer 块是通过将 Transformer 模块中的标准多头自注意力 MSA 块替换为基于滑动窗口的模块来构建的, 其他层保持不变。如图 3 所示, Swin Transformer 模块采用层级化注意力架构, 其核心结构包含 2 个核心组件: 1) (可变形) 窗口多头自注意力计算层 (S)W-MSA, 采用动态窗口划分策略实现跨区域特征交互; 2) 非线性特征映射单元, 由两个 MLP 构成并集成高斯误差线性单元 (gaussian error linear unit, GELU) 激活函数。该模块采用前置归一化设计, 即在每个注意力机制和全连接操作前执行层标准化 (layer normalization, LN), 同时通过跨模块残差连接实现梯度稳定传播。

1.2 ES-SPPCSPC 多尺度特征表达模块

针对光伏电池存在复杂背景干扰的情况, 在 SPPCSPC^[24] 模块基础上设计 ES-SPPCSPC 模块, 该模块通过多层次特征重组与注意力引导机制, 有效抑制复杂背景噪声对缺陷特征的干扰, 提升模型在明暗片分布不均、反光伪影等复杂背景下缺陷检测的鲁棒性。

1) ES-SPPCSPC 模块

SPPCSPC 是 YOLO 系列中融合空间金字塔池化与跨阶段部分连接的核心模块, 通过多尺度池化核 (5×5, 9×9, 13×13) 捕获上下文信息。该研究在 SPPCSPC 模块架构基础上进行优化得到 ES-SPPCSPC 模块, 其架构如图 4 所示, 将原有的卷积块系列 (convolutional block series, CBS) 替换为计算效率更高的 GConv。在保持 1×1 和 3×3 卷积核设计的基础上, 利用群卷积的特性, 实现了更高效的特征提取。此外, 为增强特征表达能力, 在第一个 1×1GConv 后引入了深度可分离卷积 (depthwise separable convolution, DWConv) 和通道洗牌 (channel_shuffle, CS) 操作。




图 4 ES-SPPCSPC 模块

Fig. 4 ES-SPPCSPC module

这种设计使得网络能够在较低计算成本下提取丰富的空间特征信息, 同时通过通道重排保证了不同特征组之间充分的信息交互。此外, 引入残差连接 (Add 操作), 能够缓解深层网络中的梯度消失问题。在多尺度特征提取方面, 保留了并行的最大池化操作 (池化核大小分别为 5、9 和 13), 并对特征融合策略进行了优化, 为此设计了 Enhanced SimAM 注意力模块。

2) Enhanced SimAM 注意力模块

如图 5 所示, Enhanced SimAM 模块是一个多分支融合的注意力机制, 通过结合能量基注意力、通道注意力和空间注意力 3 种互补机制, 动态增强特征图中关键区域的响应。




图 5 Enhanced SimAM 网络结构

Fig. 5 Enhanced SimAM network infrastructure

其核心思想包括:

(1) 能量基注意力分支: 继承自原始 SimAM^[25], 能量基注意力通过计算输入特征图的均值和方差来评估特征的重要性。能量较低的神经元被认为更为重要, 并给予其更大的权重。首先计算特征图的均值和方差, 如式 (2) ~ (3) 所示。

$$\mu = \frac{1}{H \times W} \sum_{c,h,w} X_{c,h,w} \quad (2)$$

$$\sigma^2 = \frac{1}{H \times W} \sum_{c,h,w} (X_{c,h,w} - \mu)^2 \quad (3)$$

计算每个神经元的能量, 如式 (4) 所示。

$$E = \frac{\sigma^2}{\sigma^2 + \varepsilon} \quad (4)$$

式中: $X_{c,h,w}$ 为输入特征图; H 和 W 为特征图的高度和宽度; μ 表示特征图的均值; σ^2 表示特征图的方差; ε 为避免除 0 的小常数。

(2) 通道注意力分支: 采用轻量级设计, 包含全局平均池化和两层 1×1 卷积的多层感知机, 使用降维率 r 进行特征压缩, 使网络能够选择性地强化与不同类型缺陷相关的通道特征, 如式 (5) 所示。

$$CA(X) = \text{Sig}(\text{Conv2D}(\text{RL}(\text{Conv2D}(A_p(X)))))) \quad (5)$$

式中: Sig 表示 Sigmoid 函数; RL 表示 ReLU 激活函数; A_p 表示 AvgPool。

(3) 空间注意力分支: 同时利用平均池化和最大池化的特征信息, 有效抑制背景干扰, 增强对缺陷位置的感知能力, 如式 (6) 所示。

$$SA(X) = \text{Sig}(\text{Conv}(7 \times 7)(\text{Concat}(A_p(X), M_p(X)))) \quad (6)$$

式中: M_p 表示最大池化。

3 个分支的输出通过可学习参数 α, β, γ 自适应融合, 如式 (7) 所示。

$$Y = X \odot (\alpha \cdot \text{Sig}(E) + \beta \cdot CA(X) + \gamma \cdot SA(X)) \quad (7)$$

式中: \odot 表示逐元素相乘操作; α, β, γ 是可学习的参数, 表示每个分支输出的融合权重, 它们通过训练得到, 能够自适应地调整不同分支对最终特征表达的贡献程度。

通过上述改进, 该模块构建三重注意力协同机制: 能量分支通过特征能量分布分析动态抑制高方差背景干扰, 通道注意力建立跨光谱特征选择通道, 空间注意力强化缺陷几何结构感知。三者通过参数化融合形成复合注意力场, 在复杂背景下构建缺陷特征增强的差异化表达空间, 提升多尺度特征表达能力。

1.3 MSFF-Neck 多尺度特征融合模块

YOLOv8 模型的基础架构通过 5 组步长参数为 2 的 3×3 卷积核实现特征空间的逐级压缩, 构建了 P1~P5 五级金字塔式特征表征体系。在特征提取过程中, 网络层级与语义深度呈正相关关系, 浅层特征 (P1~P2) 主要承载纹理、边缘等细节信息, 而深层特征 (P3~P5) 则逐步提取目标语义特征。然而分析其颈部网络设计发现, 现有跨尺度融合机制虽能有效整合 P3~P5 层级特征, 但对底层特征中蕴含的几何形态学信息存在关注不足的问题。针对这一局限性, 该研究受 ASF 结构启发, 设计了 MSFF-Neck 模块, 如图 6 所示。

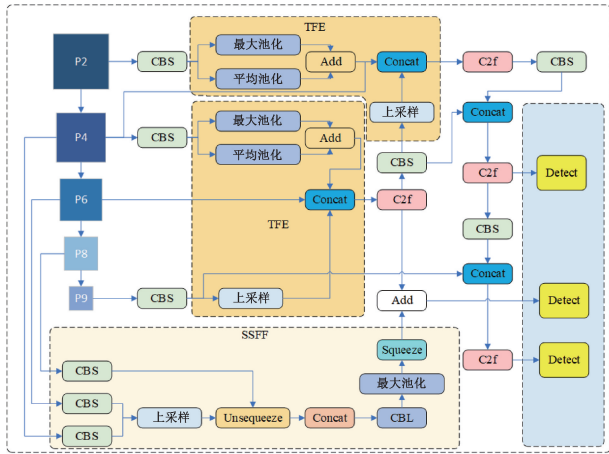


图 6 MSFF-Neck 模块

Fig. 6 MSFF-Neck module

SSFF 模块聚焦于增强 P4 特征层对小目标细节特征的捕获能力, 同时通过融合 P6 和 P8 层的全局上下文信息优化 P4 层的表征效能。该模块通过跨层级特征交互机制, 有效整合深层高维语义特征与浅层低维细节特征, 强化多尺度不变特征的融合利用率, 从而改善特征金字塔网络在小目标缺陷检测中的精度不足问题。其数学表达式如式 (8)~(9) 所示。

$$\mathbf{F}_{3d} = \text{Concat}(\text{unseq}(\mathbf{F}_s, \text{up}(\mathbf{F}_m)), \text{up}(\mathbf{F}_l)) \quad (8)$$

$$\mathbf{F}_{2d} = \text{sq}(M_{p_{3d}}(\text{CBL}(\mathbf{F}_{3d}))) \quad (9)$$

式中: $\mathbf{F}_s, \mathbf{F}_m, \mathbf{F}_l$ 分别表示小尺度、中尺度、大尺度的特征

图; \mathbf{F}_{3d} 表示经过转化后的 3 维特征图; up 表示上采样; sq 表示维度压缩; unseq 表示维度扩张; CBL 表示卷积、批归一化、LeakyRelu 激活函数; $M_{p_{3d}}$ 表示三维最大池化。

TFE 模块将检测目标按大、中、小特征进行拆分, 添加大尺寸特征图并进行特征放大, 从而提高对细节特征的关注。这种多尺度特征的分层处理与融合机制, 使得网络能够更好地保留和利用小目标的细节信息, 优化不同尺度特征图的融合。具体的实现过程如式 (10) 所示。

$$\mathbf{F}_{TFE} = \text{Concat}(\text{Add}(M_p(\mathbf{F}_l), A_p(\mathbf{F}_l)) + \mathbf{F}_m + \text{up}(\mathbf{F}_s)) \quad (10)$$

式中: \mathbf{F}_{TFE} 表示 TFE 模块输出的特征图; $\mathbf{F}_l, \mathbf{F}_m, \mathbf{F}_s$ 分别表示大、中、小尺寸的特征图; \mathbf{F}_{TFE} 由 $\mathbf{F}_l, \mathbf{F}_m$ 和 \mathbf{F}_s 连接而成, \mathbf{F}_{TFE} 的分辨率与 \mathbf{F}_m 相同, 通道数是 \mathbf{F}_m 的 3 倍。

通过 SSFF 模块和 TFE 模块两个协同工作的核心组件建立多维度特征交互通道, 实现跨层特征的连续性传递与细粒度特征的增强表达, 有效缓解深层网络中的特征衰减现象, 增强模型的多尺度融合能力, 从而显著增强模型在不同类型、不同形态缺陷的识别能力。

2 实验与结果分析

2.1 数据集

采用 PVEL-AD 基准数据集^[26]开展实验验证, 该数据集是用于光伏电池异常检测的大规模开放世界数据集, 由河北工业大学与北京航空航天大学科研团队联合开发。数据集包含 36 543 张具有各种内部缺陷和异构背景的 EL 图像, 其中 4 500 张已标注, 每个文件的大小约为 40 KB, 图像分辨率为 $1\ 024 \text{ pixels} \times 1\ 024 \text{ pixels}$ 。数据集涵盖了 12 种不同类型的缺陷, 如图 7 所示, 包括: 线状裂纹、星状裂纹、断栅、黑芯、垂直错位、水平错位、粗线、划痕、碎片、断角、短路和材料缺陷。由于断角缺陷的样本较少, 选择除断角外的其他 11 种缺陷数据作为数据集, 并将其按照 7:1.5:1.5 的比例划分为训练集、验证集和测试集。

考虑到 PVEL-AD 数据集中某些缺陷类别样本数量较少, 且存在小目标缺陷和复杂背景等挑战, 采用翻转、剪裁和对比度调整数据增强方法对样本进行扩充, 以提高模型的泛化能力和鲁棒性。

翻转: 通过水平或垂直翻转图像, 模型可以学习到缺陷在不同方向上的表现形式, 增强其对缺陷方向变化的适应能力。

剪裁: 随机剪裁图像的一部分, 模拟缺陷在图像中部分可见的情况, 增强模型对局部特征的敏感性, 提高其对小目标缺陷的检测能力。

对比度调整: 通过调整图像对比度, 模拟 EL 成像过程中因电流注入不均、环境光干扰或设备校准偏差导




图 7 PVEL-AD 数据集的 12 种缺陷

Fig. 7 12 deficiencies in the PVEL-AD dataset

致的明暗变化性,提升模型在复杂背景下的鲁棒性。

通过上述数据增强策略,能够增加训练样本的多样性,帮助模型更好地学习不同形态和尺度的缺陷特征,提升其在实际应用中的检测性能。

2.2 评价指标

该研究采用常用的目标检测评估指标来定量评估模型性能,包括平均精度均值(mean average precision, mAP)、参数量和浮点计算量,如式(11)~(14)所示。

$$P = \frac{TP}{TP + FP} \quad (11)$$

$$R = \frac{TP}{TP + FN} \quad (12)$$

$$AP = \int_0^1 PdR \quad (13)$$

$$mAP = \sum_{i=1}^m AP/m \quad (14)$$

式中: P 为准确率; R 为召回率; m 表示检测目标的类别数; TP 表示检测结果中正确目标的数量; FP 表示检测结果错误目标的数量; FN 表示目标中漏检的数量。

2.3 实验配置及参数设置

实验平台搭建于 Windows 11 操作系统环境,硬件配置搭载 13 代 Intel Core i5 处理器(主频 3.5 GHz)与 NVIDIA GeForce RTX 4060Ti 图形加速卡(16 GB 显存),软件环境基于 PyTorch 2.0.0 框架与 CUDA 11.8 并行计算架构构建。模型训练采用 200 个 epoch 的迭代策略,批量尺寸设置为 16 样本/批次,参数优化过程中使用自适应动量估计(adaptive moment estimation, Adam)优化器(初始学习率 0.01,动量因子 0.937),并引入 L2 正则化约束(权重衰减系数 0.0005)防止过拟合。训练过程通过指数滑动平均系数 0.95 实现梯度更新平滑,确保模型收敛稳定性。训练过程中,学习率会逐步衰减,以帮助模型更好地收敛。

2.4 与其他方法的比较分析

为了验证本方法的优越性,将本方法与当前主流目标检测方法进行了对比分析。实验在相同的数据集和评估指标下进行,以确保比较的公平性。

表 1 为不同方法下光伏电池缺陷检测结果对比情况。

表 1 不同方法的光伏电池缺陷检测结果对比
Table 1 Comparison of defect detection results in photovoltaic cells using different methods

方法	mAP@0.5	mAP@0.5~0.95	参数量 /M	浮点计算量/GFLOPs
YOLOv5n	0.887	0.608	2.5	7.1
YOLOv6	0.867	0.583	4.2	11.8
YOLOv7-Tiny	0.744	0.521	6.0	13.1
YOLOv8n	0.867	0.614	3.0	8.1
YOLOv9t	0.870	0.595	2.0	7.6
YOLOv10n	0.852	0.604	2.7	8.2
OD-YOLO ^[17]	0.894		6.7	
FasterNet ^[27]	0.845	0.555	1.8	5.1
DETR ^[28]	0.756	0.527	28.9	30.3
Faster RCNN ^[29]	0.686	0.470	41.2	90.9
Faster RCNN_CAN ^[30]	0.779	0.519	42.1	
Cascade RCNN ^[31]	0.797	0.449	69.4	162.0
RetinaNet ^[32]	0.746	0.441	21.4	118.0
MFES-YOLOV8n	0.897	0.610	6.1	10.4

由表 1 可知,在检测精度方面,MFES-YOLOV8n 取得了 0.897 的 mAP@0.5,相比基线模型 YOLOv8n 提升了 3 个百分点,表现优于当前主流的 YOLO 系列模型。与参数量相近的 YOLOv5n(2.5 M)相比,MFES-YOLOV8n

虽然参数量增加至 6.1 M,但在 $mAP@0.5$ 上提升了 1 个百分点,且 $mAP@0.5 \sim 0.95$ 指标提升 0.2 个百分点(0.610 对比 0.608)。相比参数量更大的 YOLOv7-Tiny (6.0 M),MFES-YOLOV8n 在检测精度上具有显著优势, $mAP@0.5$ 和 $mAP@0.5 \sim 0.95$ 分别高出 15.3% 和 8.9%。与 YOLOv9t 和 YOLOv10n 相比,MFES-YOLOV8n 在检测精度上同样表现出色,分别高出 2.7 和 4.5 个百分点,在 $mAP@0.5 \sim 0.95$ 指标上,MFES-YOLOV8n 也优于 YOLOv9t 和 YOLOv10n。值得注意的是,即便与精度最接近的 OD-YOLO 相比,MFES-YOLOV8n 仍以更少的参数(6.1 M 对比 6.7 M)实现了更高的 $mAP@0.5$ (0.897 对比 0.894)。

与非 YOLO 系列方法相比,本方法的优势更加突出。DETR ($mAP@0.5$ 为 0.756)基于 Transformer 建模全局特征,但其参数量(28.9 M)和计算复杂度(30.3 GFLOPs)远高于 MFES-YOLOV8n,且精度较低。Faster RCNN ($mAP@0.5$ 为 0.686)和 RetinaNet ($mAP@0.5$ 为 0.746)作为经典的两阶段和单阶段方法,精度较低,且参数量(41.2 和 21.4 M)和计算开销(90.9 和

118.0 GFLOPs)显著高于 MFES-YOLOV8n。Faster RCNN_CAN ($mAP@0.5$ 为 0.779)和 Cascade RCNN ($mAP@0.5$ 为 0.797)通过注意力机制和多阶段级联提升了精度,但其参数量(42.1 和 69.4 M)和计算复杂度(Cascade RCNN 为 162.0 GFLOPs)远超 MFES-YOLOV8n,不适合边缘计算场景。相比之下,本方法以 6.1 M 参数量和 10.4 GFLOPs 实现了更高的 $mAP@0.5$,体现了精度和轻量化的良好平衡。

此外,与轻量化模型 FasterNet (1.8 M)相比,MFES-YOLOV8n 以 3.4 倍参数量换取了 5.2 个 $mAP@0.5$ 百分点的性能飞跃,且在 $mAP@0.5 \sim 0.95$ 指标上更领先 10% (0.610 对比 0.555)。

这些结果表明,MFES-YOLOV8n 通过针对性优化,在与其他类型目标检测方法对比中展现了综合优势,适合工业场景中的高精度、轻量化缺陷检测需求。

2.5 消融实验

为了验证所提出改进方法的有效性,设计了消融实验来评估各个模块的贡献。实验基于 PVEL-AD 数据集,并在相同的训练和测试条件下进行对比。实验结果如表 2 所示。

表 2 消融实验

Table 2 Ablation experiment

C2f-ST	ES-SPPCSPC	MSFF-Neck	$mAP@0.5$	$mAP@0.5 \sim 0.95$	参数量/M	浮点计算量/GFLOPs
			0.867	0.614	3.0	8.1
✓			0.869	0.595	3.1	8.6
	✓		0.868	0.578	5.9	9.9
		✓	0.871	0.597	3.1	8.6
✓	✓		0.889	0.607	3.1	8.6
	✓	✓	0.882	0.608	6.0	10.4
✓		✓	0.889	0.610	6.0	10.0
✓	✓	✓	0.897	0.610	6.1	10.4

每个模块的独立改进以及不同模块组合的使用,均对基准模型 YOLOv8n ($mAP@0.5$ 为 0.867)产生了不同程度的提升。首先,单独引入 C2f-ST 模块后,模型在缺陷特征提取能力上有所提升, $mAP@0.5$ 从 0.866 提升至 0.869。ES-SPPCSPC 模块和 MSFF-Neck 模块的单独使用分别使 $mAP@0.5$ 分别提升了 0.1% 和 0.5%。虽然每个单独模块的提升有限,但当模块进行组合时,性能的提升更加显著。两两结合的情况下,模型的 $mAP@0.5$ 提升均达到了 1.5% 或以上,3 种模块同时结合时,模型的 $mAP@0.5$ 达到了最高值 0.897,相比基准 YOLOv8n 提升了 3.0%。这一消融实验结果充分证明了各个模块在提升模型性能方面的有效性,并验证了“细粒度特征提取—跨尺度语义增强—多层次特征融合”递进式优化架构的优势。

综上所述,通过逐步引入 C2f-ST 模块、ES-SPPCSPC 模块和 MSFF-Neck 模块,优化后的模型在光伏电池缺陷检测任务中取得了显著的性能提升,特别是在 $mAP@0.5$ 指标上达到了 0.897,验证了改进方法的有效性和实用性。同时,尽管增加了部分计算复杂度,但是模型的计算开销仍维持在合理范围内。

2.6 实验结果可视化分析

为了更全面地评估方法的性能,绘制改进算法与基准 YOLOv8n 模型、最新的 YOLOv9t 和 YOLOv10n 模型在不同缺陷类别上的精确率-召回率 (precision-recall, PR) 曲线(如图 8 所示)。PR 曲线展示了不同召回率下模型精度的变化。对比 PR 曲线能直观展示 3 种模型在多类别缺陷检测中的性能差异。

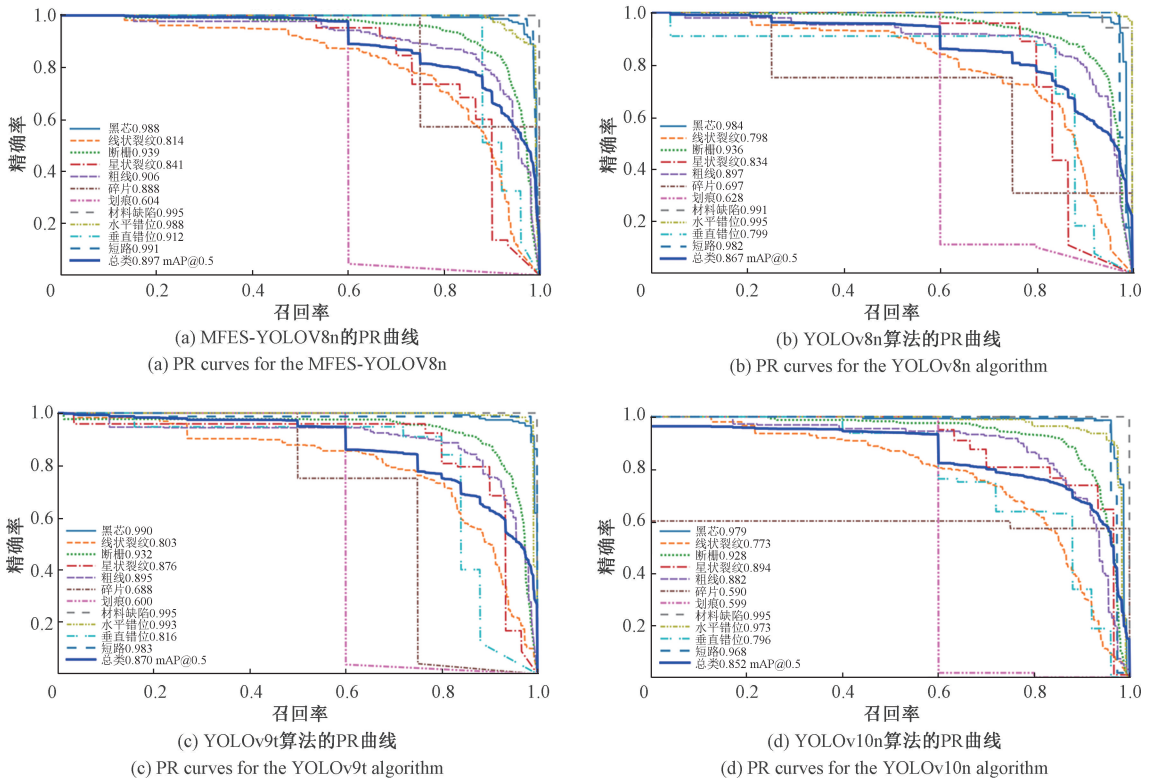


图 8 与其他算法的 PR 曲线对比

Fig. 8 PR curve comparison with other algorithms

1) 小目标缺陷检测性能

在裂纹和断栅等小目标缺陷检测中, MFES-YOLOV8n 的 mAP@0.5 值分别提升至 0.814 和 0.932。其中裂纹检测精度较基准模型提高了 1.6%, 断栅检测精度提升了 0.3%。实验结果表明, C2f-ST 模块通过 Swin Transformer 的窗口自注意力机制, 构建了空间注意力引导的残差拓扑结构。其多层次的窗口划分策略有效捕捉了裂纹的细长边缘特征和断栅的局部断裂特征, 同时残差连接保障了浅层细节特征的传递效率, 对微小缺陷展现出更强的特征提取能力。

2) 复杂背景干扰下的检测鲁棒性

在粗线和垂直错位等受背景干扰的缺陷检测中, MFES-YOLOV8n 的 mAP@0.5 值分别达到 0.953 和 0.988。其中粗线检测精度较基准模型提升 0.9%, 垂直错位检测接近完美识别。这验证了 ES-SPPCSPC 模块中 Enhanced SimAM 注意力机制的三支协同作用; 能量基注意力通过方差特征抑制了组件边缘的亮度衰减伪影; 通道注意力强化了粗线与正常栅线的光谱差异; 空间注意力则聚焦于垂直错位的几何偏移特征。

3) 多尺度缺陷检测能力

针对黑芯和短路等大尺度缺陷, 以及裂纹等小尺度缺陷, 在 mAP@0.5~0.95 指标上达到 0.610, 较基准模

型提升 3.2%。MSFF-Neck 模块通过尺度序列特征融合和三重特征编码器, 实现了跨层特征的连续性传递。其中 SSFF 模块的 3D 特征重组策略将 P4 层特征图与 P6、P8 层的全局语义信息融合, 降低黑芯检测的边界定位误差; TFE 模块通过大尺寸特征图放大策略, 增强了短路缺陷的全局感知能力, 同时保持了对裂纹缺陷的细粒度捕捉。

综上所述, 通过 C2f-ST、ES-SPPCSPC 和 MSFF-Neck 模块的协同优化, 提升了光伏缺陷检测的精度和鲁棒性。

算法使用训练过程中精度最高的网络权重, 对测试集中的缺陷图像进行了可视化, 结果如图 9 所示。

改进后的算法成功检测出了图像中的微小裂纹和断栅缺陷, 而原始 YOLOv8n 和 YOLOv10n 出现了漏检现象, 未能识别部分细微缺陷。改进算法在复杂背景下 (如反光和阴影干扰区域) 仍能准确识别裂纹缺陷, 而 YOLOv8n 和 YOLOv10n 在类似区域容易受到背景干扰, 导致漏检。

在多尺度检测效果方面, 改进算法能够同时准确检测出大小不同的缺陷 (黑芯和断栅), 而原始算法和 YOLOv10n 对不同尺度缺陷的检测能力存在明显差异。这些结果验证了 MFES-YOLOV8n 提出的改进策略在提升检测性能方面的有效性。

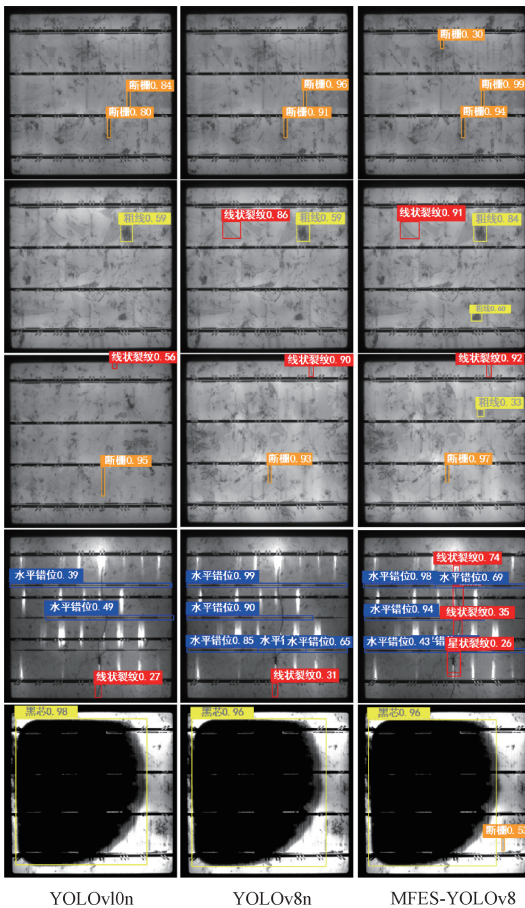


图9 改进效果对比

Fig.9 Comparison of improvement effects

3 结 论

针对光伏电池缺陷检测中的挑战,提出一种集特征提取、特征融合和特征表达改进的全新检测算法。通过一系列对比实验,验证了该方法的有效性。主要结论如下:融合了 Swin Transformer 和残差连接的 C2f-ST 模块,有效增强了细粒度特征的检测能力,提升了模型对小目标缺陷的特征提取能力;ES-SPPCSPC 模块,结合群卷积和 Enhanced SimAM 注意力机制,能够实现更高效的多尺度特征表达,提升了模型在复杂场景下的鲁棒性;MSFF-Neck 结构,利用 SSFF 和 TFE,有效增强了模型多尺度特征融合能力,显著提高了多尺度缺陷的检测精度。3 种结构的“细粒度特征提取—跨尺度语义增强—多层级特征融合”的递进式优化架构,使得模型突破了光伏缺陷检测中的精度瓶颈。

该方法可以更准确地检测出微裂纹、断栅等隐蔽缺陷,提升复杂背景下的鲁棒性可以减少误检,避免将良品误判为次品造成的浪费,通过在精度、鲁棒性上取得的针

对性提升,同时将计算成本控制在边缘设备可接受范围内,精准契合了工业视觉检测对高精度、高可靠性、可部署性的需求,特别适用于对缺陷类型复杂、对微小缺陷敏感的光伏电池生产线在线检测、或电站运维中的 EL 图像分析等场景。

尽管改进方案在检测精度方面取得了显著突破,但仍存在的不足之处为:首先,相较于原 YOLOv8n 模型,改进后的模型在计算复杂度和参数量上有所增加。因此,如何在提高检测精度的同时进一步降低计算成本仍然是一个亟待解决的挑战;其次,PVEL-AD 数据集中某些缺陷类型的样本数量较少,这可能会影响模型在这些类别缺陷上的表现。未来可以通过扩展到更具挑战性的数据集,进一步验证模型的普适性和鲁棒性。此外将研究更高效的特征融合策略,进一步提升检测精度,并设计更加轻量化网络结构,降低计算资源需求。

参考文献

- [1] 王欢,徐小力.一种新型光伏阵列在线故障检测方法研究[J].仪器仪表学报,2015,36(12):2765-2772. WANG H, XU X L. Research on a novel online fault detection method for photovoltaic arrays [J]. Chinese Journal of Scientific Instrument, 2015, 36(12): 2765-2772.
- [2] GUO J L, CHONG C F, ABREU P H, et al. Reparameterization convolutional neural networks for handling imbalanced datasets in solar panel fault classification [J]. Engineering Applications of Artificial Intelligence, 2025, 150: 110541.
- [3] 钱晓亮,张鹤庆,张焕龙,等.基于视觉显著性的太阳能电池片表面缺陷检测[J].仪器仪表学报,2017,38(7):1570-1578. QIAN X L, ZHANG H Q, ZHANG H L, et al. Surface defect detection of solar cells based on visual saliency [J]. Chinese Journal of Scientific Instrument, 2017, 38(7): 1570-1578.
- [4] 牛靖凯,翟帅,田欣,等.高辐照度下晶硅光伏电池板隐形缺陷成像系统优化[J].光学技术,2025,51(3):264-268. NIU J K, ZHAI SH, TIAN X, et al. Optimization of imaging system for latent defects in crystalline silicon photovoltaic panels under high irradiance [J]. Optical Technique, 2025, 51(3): 264-268.
- [5] 范思远,王煜,曹生现,等.积灰对光伏组件输出特性影响建模与分析[J].仪器仪表学报,2021,42(4):83-91. FAN S Y, WANG Y, CAO SH X, et al. Modeling and analysis of the impact of dust accumulation on output characteristics of photovoltaic modules [J]. Chinese

- Journal of Scientific Instrument, 2021, 42(4): 83-91.
- [6] TANG W Q, YANG Q, DAI Z, et al. Module defect detection and diagnosis for intelligent maintenance of solar photovoltaic plants: Techniques, systems and perspectives[J]. Energy, 2024, 297: 131222.
- [7] NIETO MORONE M B, ROSILLO F G, MUÑOZ GARCÍA M A, et al. Enhancing photovoltaic module sustainability: Defect analysis on partially repaired modules from Spanish PV plants[J]. Journal of Cleaner Production, 2024, 461:142575.
- [8] 刘玉淇,吴一全. 基于机器视觉的太阳能电池片缺陷检测算法综述[J]. 光学精密工程, 2024, 32(6): 868-900.
- LIU Y Q, WU Y Q. Review of machine vision-based defect detection algorithms for solar cells[J]. Optics and Precision Engineering, 2024, 32(6): 868-900.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [10] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision, 2016: 21-37.
- [11] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [12] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [13] 吕游,郑茜,齐欣宇,等. 基于改进 EfficientNet 的红外图像光伏组件故障识别研究[J]. 仪器仪表学报, 2024, 45(4): 175-184.
- LYU Y, ZHENG Q, QI X Y, et al. Research on fault identification of photovoltaic modules in infrared images based on improved EfficientNet[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 175-184.
- [14] 王育欣,张志,张家亮,等. 基于改进 YOLOv5 算法的光伏缺陷检测[J]. 太阳能学报, 2024, 45(12): 139-145.
- WANG Y X, ZHANG ZH, ZHANG J L, et al. Photovoltaic defect detection based on improved YOLOv5 algorithm [J]. Acta Energetica Solaris Sinica, 2024, 45(12): 139-145.
- [15] 陈亚芳,廖飞,黄新宇,等. 多尺度 YOLOv5 的太阳能电池缺陷检测[J]. 光学精密工程, 2023, 31(12): 1804-1815.
- CHEN Y F, LIAO F, HUANG X Y, et al. Solar cell defect detection based on multi-scale YOLOv5 [J]. Optics and Precision Engineering, 2023, 31(12): 1804-1815.
- [16] 项新建,汤卉,肖家乐,等. 基于多尺度特征融合 SSDLite 的光伏组件缺陷检测[J]. 太阳能学报, 2025, 46(1): 669-675.
- XIANG X J, TANG H, XIAO J L, et al. Defect detection in photovoltaic modules based on multi-scale feature fusion SSDLite[J]. Acta Energetica Solaris Sinica, 2025, 46(1): 669-675.
- [17] 廖力达,罗晓,黄斌,等. 复杂背景下的多晶硅太阳能电池缺陷检测[J]. 太阳能学报, 2024, 45(9): 295-303.
- LIAO L D, LUO X, HUANG B, et al. Defect detection of polycrystalline silicon solar cells under complex backgrounds [J]. Acta Energetica Solaris Sinica, 2024, 45(9): 295-303.
- [18] 王道累,李明山,姚勇,等. 改进 SSD 的光伏组件热斑缺陷检测方法[J]. 太阳能学报, 2023, 44(4): 420-425.
- WANG D L, LI M SH, YAO Y, et al. Improved SSD-based method for hotspot defect detection in photovoltaic modules [J]. Acta Energetica Solaris Sinica, 2023, 44(4): 420-425.
- [19] LIU Y Q, WU Y Q, YUAN Y B, et al. Deep learning-based method for defect detection in electroluminescent images of polycrystalline silicon solar cells [J]. Optics Express, 2024, 32(10): 17295-17317.
- [20] 季瑞瑞,梅远,杨思凡,等. 基于改进 Faster R-CNN 的光伏组件红外热斑检测算法[J]. 激光与红外, 2024, 54(4): 584-592.
- JI R R, MEI Y, YANG S F, et al. Infrared hot spot detection algorithm for photovoltaic modules based on improved Faster R-CNN[J]. Laser & Infrared, 2024, 54(4): 584-592.
- [21] CUI Y M, LIU M M, LI W, et al. An exploratory framework to identify dust on photovoltaic panels in offshore floating solar power stations[J]. Energy, 2024, 307: 132559.
- [22] LIU Y, SUN P, WERGELES N, et al. A survey and performance evaluation of deep learning methods for small object detection[J]. Expert Systems with Applications, 2021, 172: 114602.
- [23] VARGHESE R, SAMBATH M. YOLOv8: A novel object detection algorithm with enhanced performance and

- robustness[C]. International Conference on Advances in Data Engineering and Intelligent Computing Systems, 2024: 1-6.
- [24] HE K M, ZHANG X Y, REN SH Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [25] YANG L X, ZHANG R Y, LI L D, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks [C]. International Conference on Machine Learning, 2021: 11853-11864.
- [26] SU B Y, ZHOU ZH, CHEN H Y. PVEL-AD: A large-scale open-world dataset for photovoltaic cell anomaly detection[J]. IEEE Transactions on Industrial Informatics, 2022, 19(1): 404-413.
- [27] CHEN J R, KAO S H, HE H, et al. Run, Don't walk: Chasing higher FLOPS for faster neural networks [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 12021-12031.
- [28] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]. European Conference on Computer Vision, 2020: 213-229.
- [29] SALVADOR A, GIRÓ-I-NIETO X, MARQUÉS F, et al. Faster R-CNN features for instance search [C]. IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2016: 394-401.
- [30] SU B Y, CHEN H Y, CHEN P, et al. Deep learning-based solar-Cell manufacturing defect detection with complementary attention network [J]. 2016 IEEE Transactions on Industrial Informatics, 2021, 17(6): 4084-4095.

- [31] CAI ZH W, VASCONCELOS. Cascade R-CNN: Delving into high quality object detection [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 6154-6162.
- [32] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. 2027 IEEE International Conference on Computer Vision, 2017: 2999-3007.

作者简介



陈俊生(通信作者),2010年于重庆大学获得学士学位,2014年于重庆大学获得硕士学位,2019年于重庆大学获得博士学位,现为重庆邮电大学讲师,主要研究方向为机器学习、图像处理等在能源领域的应用等方向。

E-mail:chenjunsheng@cqupt.edu.cn

Chen Junsheng (Corresponding author) received his B. Sc. degree from Chongqing University in 2010, received his M. Sc. degree from Chongqing University in 2014, and received his Ph. D. degree from Chongqing University in 2019. He is currently a lecturer at Chongqing University of Posts and Telecommunications. His main research interest includes the application of machine learning, image processing, in energy-related fields, etc.



陈沂蒙,2023年于齐鲁工业大学获得学士学位,现为重庆邮电大学在读硕士研究生,主要研究方向为图像处理技术。

E-mail:3085048311@qq.com

Chen Yimeng received his B. Sc. degree from Qilu University of Technology in 2023. He is currently pursuing his M. Sc. degree at Chongqing University of Posts and Telecommunications. His main research interests is image processing technology.