

DOI: 10.13382/j.jemi.B2508345

基于 CCMW-YOLO11n 的光伏电池缺陷检测研究

邓玉澳 王丹豪 潘俊臻 彭道刚

(上海电力大学自动化工程学院 上海 200090)

摘要: 光伏电池的高效发电在推动绿色低碳循环发展中发挥着重要作用, 针对光伏电池缺陷图像中存在背景复杂与目标尺寸较小等问题, 提出一种改进 YOLO11n 的缺陷检测模型——CCMW-YOLO11n。首先, 在 YOLO11n 的骨干网络中提出跨阶段部分改进模块 (cross stage partial improvement, CSP-I), 该模块通过设计多头自注意力机制 (multi-head self attention, MHSA)、卷积门控线性单元 (convolutional gated linear unit, CGLU) 与传统卷积 (convolution, Conv) 相结合, 兼顾全局信息感知与局部特征提取, 增强了多尺度特征的提取效果; 其次, 在特征融合阶段采用内容感知特征重组上采样技术 (content-aware reassembly of features, CARAFE), 该方法实现了对特征图自适应重组和细节增强, 有效保留了细节特征, 提升了模型对复杂目标的感知能力; 然后, 在颈部网络中融入混合聚合网络改进模块 (mixed aggregation net enhancement, MAN-E), 进一步增强了特征表达能力; 最后, 针对基础模型中 CIoU 损失函数的不足, 结合 WIoUv3、Inner-IoU 和 SIoU, 提出一种新的边界框回归损失函数 Wise-Inner-SIoU, 以优化模型的回归效果。实验结果表明, 改进后的 CCMW-YOLO11n 模型召回率提升了 9.6%, mAP@0.5 和 mAP@0.5:0.95 分别达到 91.0% 和 61.1%, 较基础模型分别提高了 3.1% 和 2.0%, 实现了对光伏电池缺陷的高效检测。

关键词: 光伏电池缺陷检测; YOLO11n; 内容感知特征重组上采样; 跨阶段部分改进模块; Wise-Inner-SIoU 损失函数

中图分类号: TP391

文献标识码: A

国家标准学科分类代码: 520.2060

Research on photovoltaic cell defect detection based on CCMW-YOLO11n

Deng Yuao Wang Danhao Pan Junzhen Peng Daogang

(College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Efficient power generation of photovoltaic cells plays a crucial role in promoting green and low-carbon circular development. To address the challenges posed by complex backgrounds and small target sizes in photovoltaic cell defect images, this paper proposes an improved defect detection model based on YOLO11n, named CCMW-YOLO11n. Firstly, a cross stage partial improvement (CSP-I) module is introduced into the backbone network of YOLO11n. This module integrates the multi-head self attention (MHSA), convolutional gated linear unit (CGLU), and conventional convolution (Conv), balancing global information perception and local feature extraction, thereby enhancing the extraction of multi-scale features. Secondly, the content-aware reassembly of features (CARAFE) upsampling technique is employed during the feature fusion stage. This method adaptively reorganizes feature maps and enhances details, effectively preserving fine-grained features and improving the model's detection performance on complex targets. Additionally, the mixed aggregation net enhancement (MAN-E) module is incorporated into the neck network to further strengthen feature representation capabilities. Finally, addressing the limitations of the CIoU loss function in the baseline model, a novel bounding box regression loss function named Wise-Inner-SIoU is proposed by combining WIoUv3, Inner-IoU, and SIoU, optimizing the regression performance of the model. Experimental results demonstrate that the improved CCMW-YOLO11n model achieves a 9.6% increase in recall rate, with mAP@0.5 and mAP@0.5:0.95 reaching 91.0% and 61.1%, respectively, representing improvements of 3.1% and 2.0% over the baseline model, thereby realizing efficient detection of photovoltaic cell defects.

Keywords: photovoltaic cell defect detection; YOLO11n; CARAFE upsampling; CSP-I; Wise-Inner-SIoU loss function

0 引言

光伏电池作为可再生能源利用的重要载体,其生产和应用规模正随着全球能源转型的加速推进而持续扩大。然而,在光伏电池的全生命周期中,从制造、运输到安装运行的各个环节都可能产生多种类型的缺陷,这些缺陷不仅会降低发电效率,更可能引发热斑效应等安全隐患,严重时甚至会导致火灾事故^[1]。在此背景下,光伏电池缺陷检测技术的研究具有重要的工程应用价值。近年来,计算机视觉技术在工业检测领域取得了显著进展,基于深度学习的计算机视觉技术已成功应用于人脸识别^[2]、智能交通、光伏^[3]电站等多个行业。光伏电站的稳定运行是保障国家能源安全与实现双碳目标的重要基础。基于此,大量专家学者围绕着光伏电池缺陷检测开展了相应研究。Ma 等^[4]提出基于傅里叶单像素成像的方法,实现衬底完全去除与环境光抑制,采用4步相移重建准确提取多种缺陷,但在复杂环境下鲁棒性仍需提升。Liu 等^[5]设计结合跨阶段 Ghost 模块与全局注意力的多尺度邻域特征交互网络,显著提升了检测精度,但对极小缺陷的识别能力有限。Su 等^[6]构建了首个多晶硅电致发光异常检测数据集,丰富了缺陷类别和场景多样性。Li 等^[7]基于偏振图像改进 U-Net,实现微裂纹高精度分割与检测,但计算效率尚需优化以适应实时应用。Wang 等^[8]提出多尺度特征解耦与相似性蒸馏方法,增强了模型的增量学习能力,实现新旧类别有效识别,但面对大量类别的泛化能力有待验证。Zhang 等^[9]首次将神经架构搜索与知识蒸馏结合,提出轻量级高效模型,参数仅 1.85×10^6 ,准确率 91.74%,适合工业部署,但对极端缺陷类型适应性有限。Hassan 等^[10]基于大规模电致发光数据,发现复杂裂纹增多,系统年衰减率低于 1%,并采用语义分割提升自动检测精度。以上方法在泛化能力、实时性能及成本等方面仍存在不足,难以满足实际光伏电池缺陷检测的多样化需求。

随着深度学习技术的发展,学者们不断优化 YOLO 系列算法以满足光伏缺陷检测的需求。谢林森等^[11]通过融合 GhostNetV2、改进 DenseNet 及坐标注意力机制,提升了 YOLOv5s-GD 模型的检测精度和速度。管宽岐等^[12]结合改进 YOLOv4 与 DeeplabV3+,利用轻量化网络和 Dice 损失函数,实现了高效的无人机红外图像光伏板识别与热斑检测,然而对小尺度缺陷的捕捉能力仍有限。Zhang 等^[13]基于 YOLOv7,融合部分卷积及可切换空洞卷积,提高了缺陷检测的准确性与鲁棒性。Bao 等^[14]提出 CCA-YOLO,通过残差坐标卷积和多尺度定位模块显著提升检测性能,但模型复杂度和推理速度之间的平衡仍待优化。Zhu 等^[15]设计的 C2DEM-YOLO 引入跨空间多

尺度注意力和辅助回归框,虽增强了部分电致发光图像缺陷的识别能力,但整体精度仍有待提高。

在光伏电池缺陷检测任务中,复杂背景、缺陷目标小等均对缺陷的准确识别带来了巨大挑战,影响检测算法的精度。此外,光伏电池缺陷通常表现为形态变化多样的目标,使得传统检测方法在定位和分类方面面临较大困难,尤其是在高分辨率和实时检测需求下,检测性能难以满足工业应用标准。针对上述问题,本文提出了一种基于 YOLO11n 的光伏电池缺陷检测算法 CCMW-YOLO11n。首先,在骨干网络中设计了跨阶段部分改进模块(cross stage partial improvement, CSP-I),增强模型对全局信息的关注;接着在颈部网络中引用内容感知特征重组上采用技术(content-aware reassembly of features, CARAFE),该方法有效保留了模型对光伏电池 EL 图像的细节特征;然后加入混合聚合网络改进模块(mixed aggregation net enhancement, MAN-E)进一步增强了模型的特征表达能力;最后采用 Wise-Inner-SIoU 优化模型回归效果。改进模型有效抑制了复杂背景干扰,增强了对微小缺陷目标的感知能力,在保持参数稳定的同时对背景复杂、缺陷多样的光伏电池缺陷图像取得了较好的检测效果。

1 改进 YOLO11n 的光伏电池缺陷检测算法

1.1 YOLO11n 网络结构

YOLO11n 模型采用典型的 3 段式架构(主干网络、颈部网络、检测头),引入最新的特征提取模块和改进的颈部结构以增强多尺度特征提取,结合多头注意力机制模块提升特征表达能力,检测头使用深度可分离卷积(depthwise convolution, DW Conv)降低计算复杂度,实现了检测精度和速度的显著提升,适合计算效率与性能兼顾的场景。

尽管 YOLO11n 在检测速度和精度上优于多数主流模型,但其在光伏电池缺陷检测中特别是对星状、线状裂纹等尺寸较小且形态复杂的缺陷表现仍不理想。这些缺陷往往边缘模糊、形态多样,且在复杂背景下易被忽略,导致漏检和误检率较高,严重影响检测的可靠性和实用性。因此,针对 YOLO11n 在细节特征捕捉和小目标识别上的不足,本文对其网络结构进行改进以提升模型对微小缺陷的敏感度和鲁棒性。YOLO11n 网络结构如图 1 所示。

1.2 CCMW-YOLO11n 模型

本文对 YOLO11n 的 Backbone、Neck 和损失函数进行了改进,以提高模型对光伏电池缺陷检测的性能。主要工作如下:1) 在骨干网络提出 CSP-I 模块,提高对光

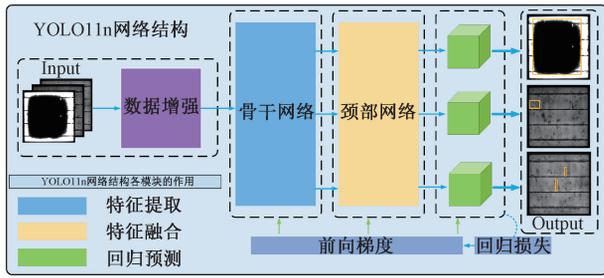


图 1 YOLO11n 网络结构

Fig.1 YOLO11n network structure

伏电池缺陷图像全局特征的提取能力;2)引入 CARAFE 上采样,能够保留更多目标细节信息,为后续提供更为细致的特征表示;3)对 MANet 模块进行结构优化,将 Faster_Block_CGLU 模块添加至最右侧分支中,增强颈部网络的特征表达能力;4)改进损失函数 CIoU 为 Wise-Inner-SIoU,提升网络边界框回归性能与光伏电池缺陷目标检测效果,改进后模型的网络结构如图 2 所示。

1.3 基于感受全局特征的跨阶段部分改进模块

在光伏电池缺陷检测任务中,准确捕获缺陷的多尺

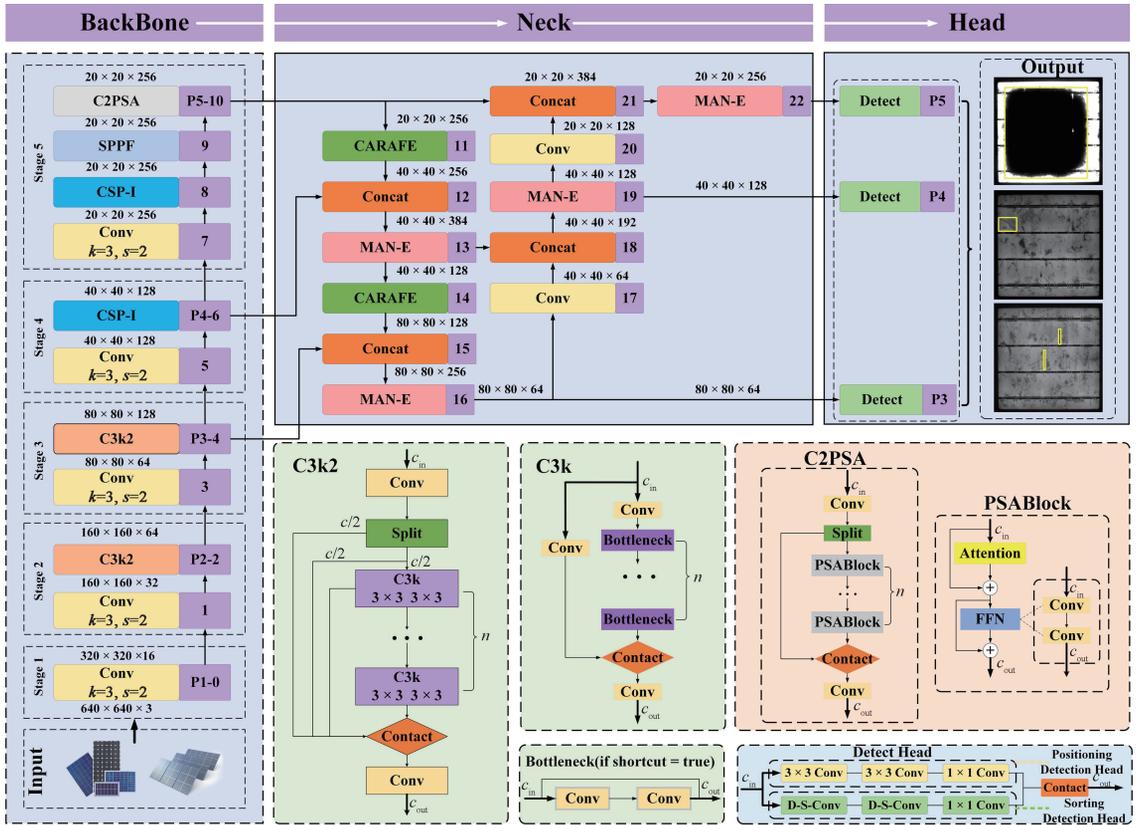


图 2 CCMW-YOLO11n 网络结构

Fig.2 CCMW-YOLO11n network structure

度特征对模型的感知能力提出了较高要求。YOLO11n 中的 C3k2 模块作为核心特征提取单元,采用多分支和多层嵌套设计增强局部特征表达,但在全局特征提取方面存在不足。该模块基于传统卷积神经网络,依赖堆叠 3×3 卷积核和残差连接提升局部感受野,但受限于深度与计算效率的平衡,难以覆盖大尺度目标,导致全局语义整合能力不足。此外,卷积核参数的空间不变性限制了对不同空间位置特征变化的适应,缺乏区域感知能力。相比之下,Transformer 的自注意力机制能更有效捕获全局特征。

针对上述问题,本文提出一种基于通道分割的混合

架构。该架构通过卷积神经网络 (convolutional neural network, CNN) 与变换器 (Transformer) 双分支并行处理,兼顾局部与全局特征提取。在通道分配模块中, CNN 分支负责局部特征提取,Transformer 分支利用多头自注意力捕获全局信息,形成互补的特征表达。为优化计算效率,Transformer 模块仅在部分通道应用,且主要部署于 Backbone 的深层 (P4 和 P5),避免浅层计算瓶颈。此设计在提升全局特征提取能力的同时有效控制了整体计算开销。

为充分发挥混合架构的性能,本文将 MHSA^[16] 与 CGLU 进行了融合,构建出一个新的模块 MHSA_CGLU。

在视觉特征处理方面, MHSa 模块通过其全局注意力机制有效建模光伏电池缺陷远距离像素之间的依赖关系, 显著增强了模型对图像全局语义的理解能力。同时, CGLU 将卷积运算与门控机制结合, 不仅提升了模型的

非线性表征能力, 还实现了对关键特征的自适应筛选与传递。这种设计使得 MHSa_CGLU 模块能够与普通卷积形成功能互补, 共同构建一个兼顾全局感知与局部特征提取的处理体系, CSP-I 网络结构如图 3 所示。

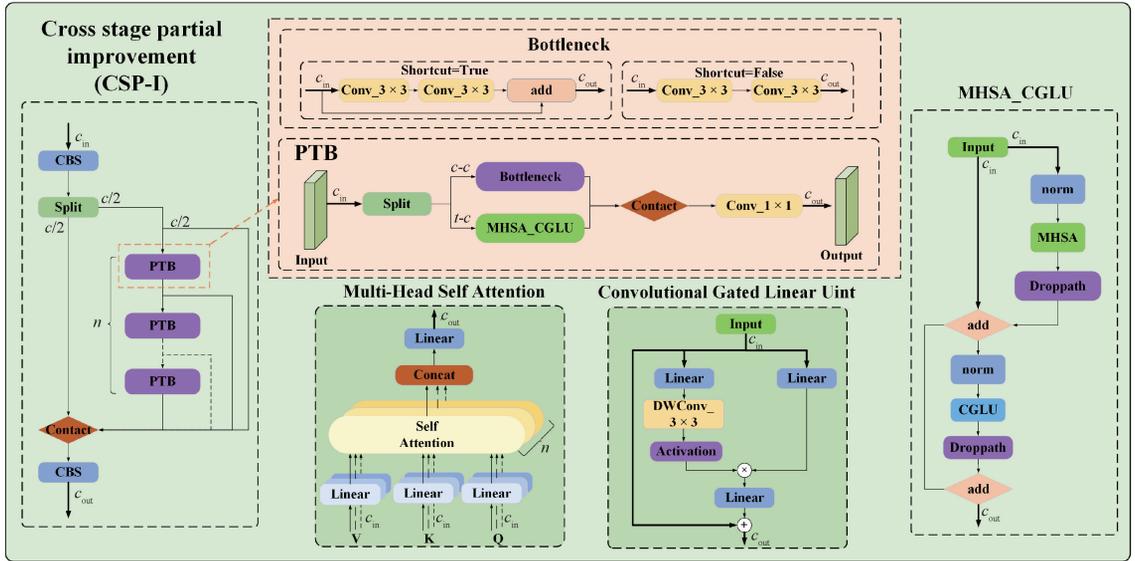


图 3 跨阶段部分改进模块网络结构

Fig. 3 Cross stage partial improvement model network structure

1.4 内容感知特征重组上采样方法

光伏电池缺陷区域通常尺寸较小、分布密集, 同时背景复杂且局部细节丰富, 特征上采样的质量直接影响检测模型对细微缺陷的识别能力。YOLO11n 的 Upsample 模块采用最近邻插值上采样方法, 该方法仅简单复制临近像素值, 可能导致特征失真和信息损失, 尤其在处理细节丰富且目标较小的光伏电池 EL 图像时表现效果一般。为此, 本文引入了内容感知特征重组上采样方法。CARAFE^[17] 是一种轻量且高效的上采样算子, 通过内容感知的方式动态生成上采样核, 从而减少失真并保留更多小目标的细节信息, 为后续特征学习提供更为细致的特征表示, 同时保持较低的计算成本。

CARAFE 模块由核预测模块和内容感知重组模块组成。第 1 步是根据内容预测每个目标位置的重组核, 第 2 步则是利用预测的核重新组装特征。核预测模块包括 3 个部分, 分别为通道压缩器、内容编码器和核归一化器。该模块首先通过一个 1×1 的卷积层压缩输入特征的通道数, 以减少后续步骤中的参数和计算成本。随后, 利用具有特定核大小的卷积层, 根据输入特征的内容生成重组核, 如式(1)所示。

$$W_{l'} = \psi(N(x_l, k_{encoder})) \quad (1)$$

式中: ψ 为核预测函数; $W_{l'}$ 表示重组和核; x 表示特征图, l 表示以 l 为中心的领域; $k_{encoder}$ 表示为计算 $W_{l'}$ 的领域范围。

在应用输入特征图之前, 每个重组核通过 softmax 函数进行空间归一化, 以确保特征图保持原有比例。生成的重组核能够更有效地捕捉光伏电池缺陷图像的纹理信息。随后, 内容感知重组模块重新组装局部区域内的特征, 从而提升光伏电池缺陷图像的特征上采样效果, 重组步骤如式(2)所示。

$$X'_{l'} = \phi(N(x_l, k_{up}), W_{l'}) \quad (2)$$

式中: ϕ 为加权操作函数; k_{up} 为加权求和所使用领域范围; X' 任意目标位置 l' 与 X 中的位置 l 相对应。

重组后的特征图具有比原始特征图更强的语义信息, 因为它能够更好地关注局部区域内相关点的信息。CARAFE 在较大感受野内聚合上下文信息, 它不是对所有样本使用固定内核, 而是根据特定实例进行内容感知处理, 从而即时生成自适应内核。核预测和内容感知特征重组为模型提供了更准确的特征表达, 进而提高了光伏电池缺陷图像的检测精度。CARAFE 算子的上采样结构如图 4 所示。

1.5 基于增强特征表达能力的混合聚合网络改进模块

为提升模型对光伏电池缺陷特征的捕获能力, 本文基于 MANet 架构对 YOLO11n 颈部的 C3k2 进行了改进, 提出了 MAN-E 模块。MANet 通过协同融合 1×1 旁路卷积、深度可分离卷积及 C2f 模块, 实现了通道特征重校准、空间特征高效处理及层次特征整合, 从而增强了不同阶段特征的语义表达。MAN-E 模块将 C2f 模块

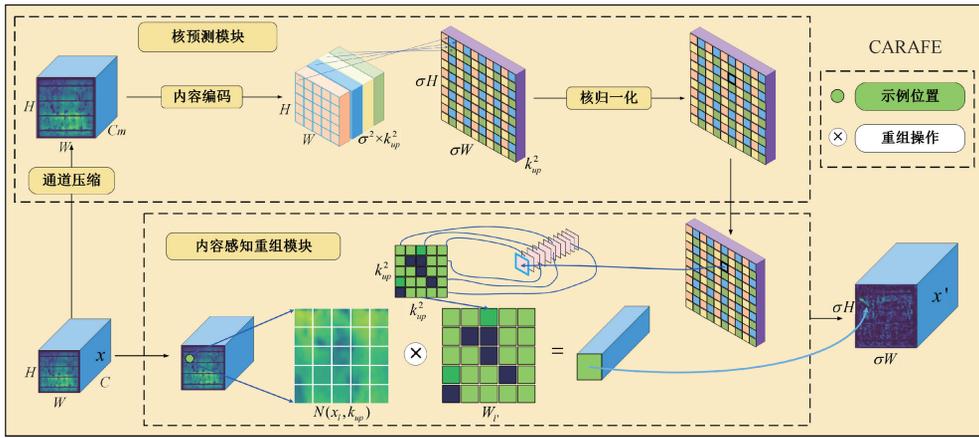


图 4 内容感知特征重组上采样结构

Fig. 4 Content-reassembly of features upsampling structure

中的 ConvNeck 替换为融合 FasterBlock 与 CGLU^[18] 的强化模块。FasterBlock 中引入的部分卷积 (partial convolution, PConv) 仅对输入通道的部分子集执行常规卷积操作以提取空间特征,其余通道保持不变。为保证内存访问的连续性和规则性,PConv 选取第一个或最后一个连续的通道子集代表整个特征图进行计算。在输入输出特征图通道数相同的情况下,PConv 有效减少了计算冗余与内存访问开销,其浮点运算量 (FLOPs) 如式 (3) 所示。

$$FLOPs = h \times w \times k^2 \times c_p^2 \quad (3)$$

式中: c 表示通道数; h 和 w 分别表示特征图的宽和高; c_p 表示部分通道数。

当分离比 $r = c_p/c = 1/4$ 时,PConv 的 FLOPs 仅为常规 Conv 的 1/16。在保证模型效率的同时,有效提取光伏电池缺陷图像中的局部空间特征。与此同时,CGLU 利用深度卷积为每个 Token 生成基于局部精细特征的个性化门控信号,有效避免了全局特征汇聚过于粗糙的问题。将 CGLU 与 Faster 网络结合形成的 Faster_Block_CGLU 模块,集成于 MANet 网络的 C2f 分支,从而构建了 MAN-E 模块,增强了颈部网络的特征表达能力,对应的 MAN-E 网络结构如图 5 所示。

1.6 Wise-Inner-SIoU 损失函数的构建

目标检测算法的性能优化与边界框回归损失函数的设计密切相关。CIoU 损失函数则通过增加长宽比惩罚项,构建了包含重叠面积、中心点距离和长宽比 3 个关键几何因素的完整优化目标,有效解决了传统交并比 (IoU) 在训练过程中可能出现的发散问题。

在 YOLO11n 基础模型的实现中,边界框回归任务采用 CIoU 作为损失函数,其数学表达式如下:

$$CIoU = IoU - \left(\frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \right) \quad (4)$$

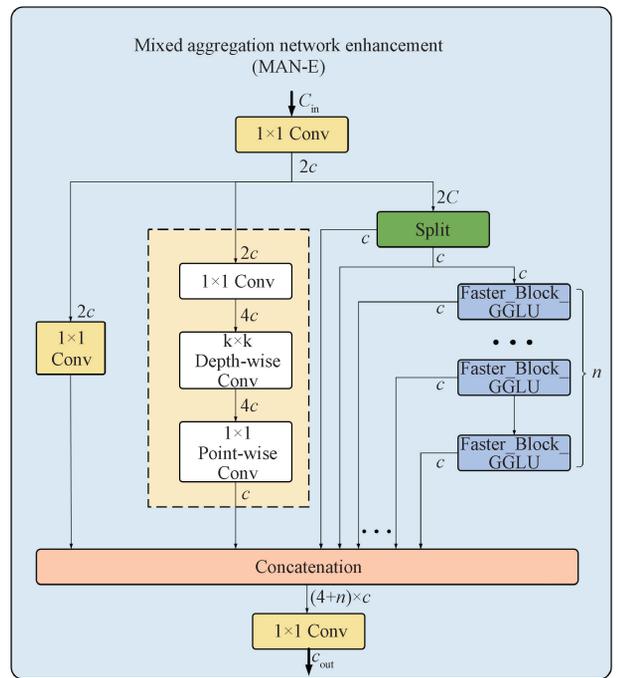


图 5 混合聚合网络改进模块

Fig. 5 Mixed aggregation net enhancement model

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (5)$$

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (6)$$

式中: α 表示平衡参数; v 用来衡量真实框和预测框之间的比例一致性; b, b^{gt} 分别表示预测框和真实框的中心点; ρ 表示两个中心点间的欧氏距离; c 表示能够同时包含预测框和真实框的最小闭包区域的对角线距离。

在光伏电池缺陷检测的实际场景中,得到的数据背景较为复杂,而传统的 CIoU 损失函数未能充分考虑数据

集中标注质量的差异, 忽视了低质量样本对检测性能的负面影响, 给缺陷检测带来一定挑战。为提升检测的准确性, 本文将基础模型中的 CIoU 损失函数替换为 Wise-Inner-SIoU 损失函数。WIoU 能够有效平衡高质量与低质量样本在边界框回归中的影响。本文采用 WIoU v3 作为新的边界框损失函数, 公式如下:

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty) \quad (7)$$

$$m = \frac{t \times n}{\sqrt{0.05}} \quad (8)$$

$$L_{WIoU} = \frac{\beta}{\delta \alpha_0^{\beta-\delta}} R_{WIoU} L_{IoU} \quad (9)$$

$$R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \quad (10)$$

$$L_{IoU} = 1 - IoU \quad (11)$$

式中: β 表示离群度; L_{IoU}^* 为变量 L_{IoU} 转换得到的常量, $\overline{L_{IoU}}$ 为动量的运行平均值; t 为迭代次数; n 为 batch size; (x, y) 与 (x_{gt}, y_{gt}) 分别表示预测框和真实框中心点坐标; W_g 和 H_g 最小的封闭框的大小; IoU 用来衡量真实框与预测框重叠程度; α_0, δ 为学习参数。

Wise-IoU 自身也存在局限性, Inner-IoU 引入了尺度因子 ratio, 通过调节辅助边框的不同尺度来优化损失计算方法。将 Inner-IoU 整合到现有的 IoU 损失函数中, 能够实现更快速且高效的边界框回归效果。Inner-IoU 如图 6 所示, 尺度因子 $ratio \in [0.5, 1.5]$, 当尺度因子小于 1 时, Inner-IoU 如图 6(a) 所示, 尺度因子大于 1 时 Inner-IoU 如图 6(b) 所示, 辅助边框要大于实际边框。

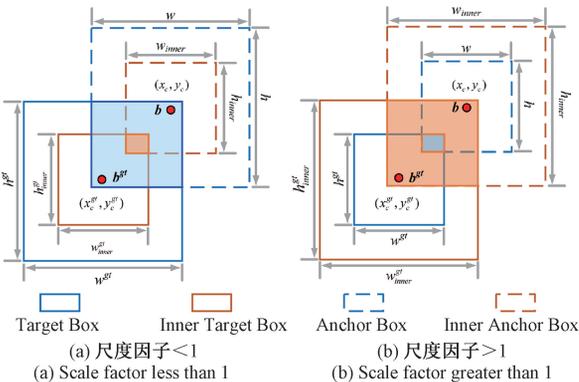


图 6 Inner-IoU 损失函数

Fig. 6 Inner-IoU loss function

Inner-IoU 可以与 SIoU 进行有效结合, SIoU 的损失函数由角度损失、距离损失、形状损失和 IoU 损失 4 部分组成。其中, IoU 损失具体计算公式如下:

$$L_{SIoU} = 1 - IoU + \frac{\Delta + \Omega}{2} \quad (12)$$

$$IoU = \frac{|B \cap B^{GT}|}{|B \cup B^{GT}|} \quad (13)$$

式中: $B \cap B^{GT}$ 与 $B \cup B^{GT}$ 为真实框与预测框交集与并集, $\Delta = \sum_{t=x,y} (1 - e^{-\rho_t})$, $\Omega = \sum_{t=w,h} (1 - e^{-\omega_t})^\theta$ 。

Inner-IoU 与 SIoU 结合得到 Inner-SIoU 如式 (14) 所示。

$$L_{Inner-SIoU} = L_{SIoU} + IoU - IoU^{inner} \quad (14)$$

将 Inner-SIoU 再与 WIoU^[19] 结合得到 Wise-Inner-SIoU 如式 (15) 所示, 既可以通过辅助边框计算 IoU, 同时引入了所需回归之间的向量角度, 又能降低低质量样本以及类别不平衡等问题对检测性能的危害, 针对光伏电池缺陷目标具有很好的检测效果, 提高了收敛速度。

$$L_{improved} = \frac{\beta}{\delta \alpha_0^{\beta-\delta}} \times \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \times \left(1 + \frac{\Delta + \Omega}{2} - IoU^{inner}\right) \quad (15)$$

2 实验与结果

2.1 实验环境与参数配置

实验平台采用基于 Linux 操作系统的服务器, 硬件配置包括主频为 3.6 GHz 的中央处理器, 32 GB 内存以及 NVIDIA Quadro P4000 显卡, 8 GB 显存。软件环境方面, 实验采用 Python 3.9 作为编程语言, 并基于 PyTorch 2.0.1 框架实现深度学习模型。实验参数设置如表 1 所示。

表 1 实验参数

Table 1 Experimental hyperparameters

| 实验参数 | 参数值 |
|------------|---------|
| epoch | 300 |
| batch size | 8 |
| image size | 640×640 |
| ratio | 0.7 |
| momentum | 0.937 |
| optimizer | SGD |
| worker | 8 |
| lr0 | 0.01 |

2.2 数据集

本文选用的数据集为 PVEL-AD 工业检测数据集, 数据集样例如图 7 所示。

本文从 12 个类别中筛选出 5 种典型缺陷类型作为主要研究对象, 具体包括黑芯 (black_core)、线状裂纹 (crack)、断栅 (finger)、星状裂纹 (star_crack) 和粗线 (thick_line)。针对公开数据集中存在的样本规模差异和类别不平衡问题, 采用差异化采样策略; 对易于检测的

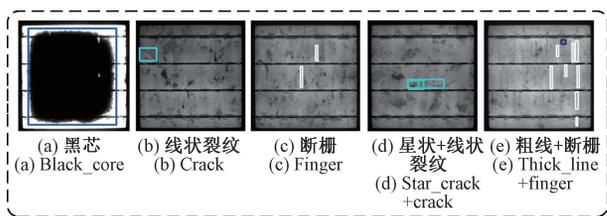


图 7 数据集样例

Fig. 7 Sample dataset

黑芯类别选取较少样本,同时保持包含断栅和线状裂纹的图片数量基本一致。数据集按 7 : 1.5 : 1.5 的比例划分为训练集、验证集和测试集。考虑到星状裂纹样本数量有限,研究中对训练集样本实施了多种数据增强技术,涵盖几何变换(仿射变换、旋转、裁剪)、空间变换(水平/垂直翻转)以及透视变换等方法,有效提升了样本多样性和模型泛化能力。最终获得的数据集构成如下:训练集 2 372 张、验证集 416 张、测试集 417 张。数据集的训练集、验证集、测试集标签分布如表 2 所示。

表 2 标签分布

Table 2 Label distribution

| instance | black_core | crack | finger | star_crack | thick_line | total |
|----------|------------|-------|--------|------------|------------|-------|
| train | 143 | 1 071 | 2 020 | 536 | 679 | 4 449 |
| val | 31 | 185 | 373 | 21 | 168 | 778 |
| test | 38 | 181 | 448 | 20 | 134 | 821 |

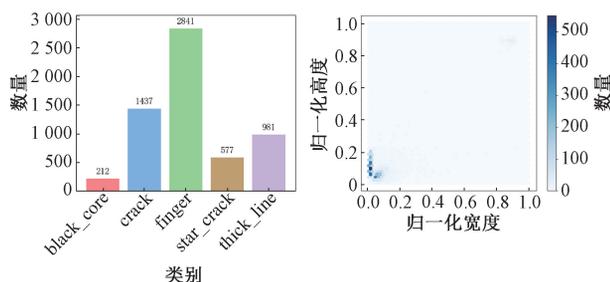
在 YOLO 格式的数据集中,目标框均经过归一化处理。对应的标注文件中,每个目标占据一行,每行包含 5 个参数。第 1 个参数为类别标签,例如在本文数据集中,数值 0 表示“黑芯”;第 2、第 3 个参数分别为边界框中心点的纵横坐标,其取值经过归一化处理,范围在 0~1 之间;第 4、第 5 个参数分别表示边界框的宽度和高度,相对于整幅图像宽度和高度的比例。本文对所有类别的标注文件中第 4、第 5 个参数进行了统计,分布如图 8 所示。从图 8(b)可以看出,大多数目标框属于小目标;右侧的颜色深浅则反映了不同类别目标数量的多少,颜色越深表示该类目标数量越大,数据集中每类光伏电池缺陷的数量如图 8(a)所示。

2.3 评价指标

为了系统评估 CCMW-YOLO11n 模型的性能,本实验选取了准确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mAP)、模型参数数量 (parameters) 以及浮点计算量作为主要评价指标。准确率、召回率和平均精度的计算公式具体如下:

$$P = \frac{TP}{TP + FP} \times 100\% \quad (16)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (17)$$



(a) 各类缺陷样本类别数量

(a) Number of sample categories for each type of defect

(b) 归一化目标框尺寸

(b) Normalized target box size

图 8 各类缺陷样本类别数量与归一化目标框尺寸

Fig. 8 Number of sample categories for each type of defect and normalised target frame size

$$AP = \int_0^1 P(R) dR \quad (18)$$

$$mAP = \frac{1}{N} \sum_N AP \quad (19)$$

式中: TP 表示实际为正样本且被正确识别为正例的样本数量; FP 表示实际为负样本但被误判为正例的样本数量; FN 表示实际为正样本但被错误判定为负例的样本数量; AP 表示针对单个类别的精确度; mAP 表示对所有类别的指标值进行算术平均后的结果。

2.4 消融实验

为了验证 CCMW-YOLO11n 的有效性,本文以 YOLO11n 网络模型为基准模型,分别引入 CARAFE、MAN-E、CSP-I 模块以及 Wise-Inner-SIoU 损失函数,在光伏电池缺陷数据集上开展消融实验,以评估各项改进措施对检测性能的影响。具体的消融实验结果如表 3 所示。

实验结果表明,每个模块单独改进都对 YOLO11n 有不同程度提升,在 YOLO11n 加入 CARAFE 上采样后,增强了特征表达能力, $mAP@0.5$ 与 $mAP@0.5:0.95$ 分别提升了 1.6% 和 0.4%。在此基础上,添加 MAN-E 模块,对应模型 5,相比于模型 2,参数量和计算量分别增加了 0.28×10^6 和 0.6 GFLOPs,但 $mAP@0.5$ 与 $mAP@0.5:0.95$ 又分别再次提升了 0.8% 和 0.1%,表明 MAN-E 模块进一步提升了对于光伏电池缺陷目标的检测性能。随后,加入 CSP-I 模块,兼顾全局与局部特征的信息提取,对应模型 7,相比于模型 5,参数量和计算量分别减少了 0.13×10^6 和 0.1 GFLOPs, $mAP@0.5$ 与 $mAP@0.5:0.95$ 分别提升了 0.2% 和 0.8%。最后,采用 Wise-Inner-SIoU 损失函数,对应于模型 8,相比于模型 7, $mAP@0.5$ 与 $mAP@0.5:0.95$ 分别提升了 0.5% 和 0.7%。综上,改进后的模型在参数量与计算量基本保持稳定的情况下显著提升了对光伏电池缺陷的检测精度。

表 3 消融实验结果
Table 3 Ablation results

| 模型 | CARAFE | MAN-E | CSP-I | Wise-Inner-SIoU | Precision/ % ↑ | Recall/ % ↑ | 参数量/ ($\times 10^6$) ↓ | 计算量/ GFLOPs ↓ | mAP@0.5/ % ↑ | mAP@0.5:0.95/ % ↑ |
|----|--------|-------|-------|-----------------|-------------------|----------------|-----------------------------|------------------|-----------------|----------------------|
| 1 | | | | | 84.1 | 79.3 | 2.58 | 6.3 | 87.9 | 59.1 |
| 2 | ✓ | | | | 87.2 | 83.5 | 2.72 | 6.6 | 89.5 | 59.5 |
| 3 | | ✓ | | | 86.2 | 82.2 | 3.38 | 7.6 | 90.2 | 59.9 |
| 4 | | | ✓ | | 87.6 | 84.5 | 2.46 | 6.2 | 90.0 | 60.5 |
| 5 | ✓ | ✓ | | | 86.5 | 83.2 | 3.00 | 7.2 | 90.3 | 59.6 |
| 6 | ✓ | | ✓ | | 81.7 | 88.2 | 2.59 | 6.4 | 89.6 | 60.2 |
| 7 | ✓ | ✓ | ✓ | | 84.1 | 84.2 | 2.87 | 7.1 | 90.5 | 60.4 |
| 8 | ✓ | ✓ | ✓ | ✓ | 82.5 | 88.9 | 2.87 | 7.1 | 91.0 | 61.1 |

为了评估改进模型在不同类型光伏电池缺陷目标上的检测性能,实验中将原始模型与改进模型在光伏电池缺陷数据集上进行了测试,结果如表4所示。结果表明,改进模型在4类缺陷的 mAP@0.5

均实现提升,尤其在线状裂纹和星状裂纹的检测中, mAP@0.5 分别提高了 4.0% 和 10.3%。实验表明,所提出的改进模型有效提升了光伏电池缺陷的检测精度。

表 4 各类光伏电池缺陷目标改进前后结果对比

Table 4 Comparison of results before and after target improvement of defects in various types of photovoltaic cells (%)

| Category | YOLO11n | | | | CCMW-YOLO11n | | | |
|------------|-------------|----------|-----------|----------------|--------------|----------|-----------|----------------|
| | Precision ↑ | Recall ↑ | mAP@0.5 ↑ | mAP@0.5:0.95 ↑ | Precision ↑ | Recall ↑ | mAP@0.5 ↑ | mAP@0.5:0.95 ↑ |
| black_core | 93.6 | 92.1 | 96.9 | 94.6 | 89.7 | 97.4 | 97.7 ↑ | 95.4 ↑ |
| crack | 70.3 | 76.2 | 75.2 | 48.8 | 70.6 | 81.1 | 79.2 ↑ | 48.8 |
| finger | 92.0 | 87.2 | 95.4 | 54.6 | 91.1 | 86.2 | 94.3 | 54.6 |
| star_crack | 74.5 | 58.4 | 79.4 | 45.5 | 74.9 | 89.4 | 89.7 ↑ | 54.5 ↑ |
| thick_line | 90.2 | 82.4 | 92.6 | 52.3 | 86.5 | 90.3 | 93.9 ↑ | 52.1 |

2.5 不同模型对比实验

为了更好验证 CCMW-YOLO11n 的性能表现,本文选取 YOLOv3-tiny^[20]、YOLOv5n^[21]、YOLOv8n^[22]、YOLOv9-

tiny^[23]、YOLOv10n^[24]、YOLO11n^[25]、YOLO12n^[26]、Hyper-YOLO11n^[27]、RT-DETR-R50^[28] 以及 RT-DETR-R101^[29] 等主流模型进行对比实验,实验结果如表5所示。

表 5 光伏电池缺陷数据集不同模型对比结果

Table 5 Comparison results of different models of PV defect dataset

| 模型 | 参数量/($\times 10^6$) ↓ | 计算量/GFLOPs ↓ | Precision/% ↑ | Recall/% ↑ | mAP@0.5/% ↑ | mAP@0.5:0.95/% ↑ |
|--------------|-------------------------|--------------|---------------|-------------|-------------|------------------|
| YOLOv3-t | 8.67 | 12.9 | 68.1 | 68.9 | 69.7 | 36.3 |
| YOLOv5n | 1.77 | 4.1 | 85.4 | 81.5 | 87.1 | 54.8 |
| YOLOv8n | 3.01 | 8.1 | 80.9 | 86.3 | 88.4 | 57.6 |
| YOLOv9-t | 2.61 | 10.7 | 80.9 | 85.6 | 89.1 | 60.1 |
| YOLOv10n | 2.27 | 6.5 | 85.8 | 83.5 | 87.7 | 59.0 |
| YOLO11n | 2.58 | 6.3 | 84.1 | 79.3 | 87.9 | 59.1 |
| YOLO12n | 2.50 | 5.8 | 83.0 | 84.5 | 88.1 | 59.4 |
| Hyper-YOLOn | 3.62 | 9.5 | 84.0 | 82.4 | 89.3 | 59.2 |
| RT-DETR-R50 | 41.94 | 125.6 | 83.1 | 77.5 | 83.0 | 56.1 |
| RT-DETR-R101 | 60.91 | 186.2 | 63.6 | 73.2 | 76.5 | 50.7 |
| 本文 | 2.87 | 7.1 | 82.5 | 88.9 | 91.0 | 61.1 |

实验结果表明,所提出的 CCMW-YOLO11n 在参数量较精度最高的 Hyper-YOLO 减少 0.75×10^6 的情况下, mAP@0.5 及 mAP@0.5:0.95 分别提高了 1.7% 和 1.9%。尽管 YOLOv5n 模型的参数量和计算量最低,但其 mAP@0.5 与 mAP@0.5:0.95 分别低于改进模型 3.9% 和

6.3%。此外,YOLOv10n 虽然在准确率上表现最佳,但其召回率和平均精度指标均不及 CCMW-YOLO11n。RT-DETR 系列模型的参数量及计算量明显高于 YOLO 系列,且在本文数据集上的检测效果不理想。相比于其他主流模型,改进后的模型平均精度指标 mAP@0.5 与

mAP@0.5:0.95 分别达到了 91.0% 和 61.1%，这 3 项指标均达到了最优，展现出优异的性能优势。

2.6 损失函数实验

1) 不同损失函数对比实验

为验证 Wise-Inner-SIoU 损失函数的有效性，本文在引入 CARAFE、MAN-E 和 CSP-I 模块的基础上开展实验，比较了 Focal Loss、Varifocal Loss、Qualityfocal Loss、EMASlide Loss、Slide Loss、WIoUv3 及其与 Inner-IoU、EIoU、GIoU、DIoU、CIoU、SIoU、MPDIoU 和 ShapeIoU 等多种组合损失函数的性能差异。实验结果如表 6 所示，其中 base 与 WIoUv2 之间的损失函数为分类损失函数，base 与 WIoUv2 及之后的损失函数为定位损失函数。从整体表现来看，分类损失函数在准确率和平均精度上的表现要略差于定位损失函数，特别是 Varifocal Loss 的 mAP@0.5 只有 83.4%。Qualityfocal Loss 的 mAP@0.5 虽达到 89.0% 但其准确率只有 75.3%，在所有损失函数的实验中处于最低。WIoUv3 及其组合损失函数在准确率和平均精度方面普遍优于 WIoUv2 及相关组合，实验结果进一步证明了 WIoUv3 损失函数优化了对光伏电池缺陷检测的回归效果，提升了检测精度。尽管 WIoUv3 与 SIoU 损失函数混合后准确率达到最高，但改进后损失函数的召回率、mAP@0.5 与 mAP@0.5:0.95 比其分别高出 7.9%、0.8% 和 0.1%。相比基础模型，改进后的模型在召回率、mAP@0.5 与 mAP@0.5:0.95 分别提高了 4.7%、0.5% 和 0.7%。结果表明，Wise-Inner-SIoU 损失函数有效增强了模型对不同类别光伏电池缺陷的检测精度。

表 6 不同损失函数对比实验

Table 6 Comparative experiments with different loss functions (%)

| 损失函数 | Precision ↑ | Recall ↑ | mAP@0.5 ↑ | mAP@0.5:0.95 ↑ |
|------------------------|-------------|-------------|-------------|----------------|
| CIoU (base) | 84.1 | 84.2 | 90.5 | 60.4 |
| Focal Loss | 78.0 | 85.0 | 87.6 | 58.2 |
| Varifocal Loss | 78.5 | 82.5 | 83.4 | 55.6 |
| Qualityfocal Loss | 75.3 | 87.1 | 89.0 | 60.2 |
| EMASlide Loss | 81.0 | 84.7 | 87.0 | 58.2 |
| Slide Loss | 84.2 | 83.5 | 88.6 | 59.3 |
| WIoUv2 | 79.2 | 82.9 | 88.9 | 59.3 |
| WIoUv3 | 86.4 | 85.8 | 89.8 | 60.3 |
| Wise-EIoU | 86.6 | 83.9 | 89.9 | 59.6 |
| Wise-GIoU | 85.8 | 82.6 | 88.8 | 59.9 |
| Wise-DIoU | 83.1 | 85.6 | 88.6 | 57.5 |
| Wise-CIoU | 85.8 | 79.3 | 88.0 | 58.9 |
| Wise-SIoU | 87.1 | 81.0 | 90.2 | 61.0 |
| Wise-MPDIoU | 85.3 | 85.8 | 90.3 | 59.5 |
| Wise-ShapeIoU | 85.9 | 80.5 | 88.1 | 59.3 |
| Wise-Inner-SIoU | 82.5 | 88.9 | 91.0 | 61.1 |

2) 损失函数改进前后收敛速度对比

为验证改进后的 Wise-Inner-SIoU 损失函数在收敛速度上的优势，本文通过可视化展示了两个损失函数的 result.csv 文件。图 9 所示为不同损失函数在训练和验证阶段的收敛情况，其中 box_loss 衡量了模型预测的目标边界框与真实边界框之间的差距；dfl_loss 通过将坐标框建模为离散的概率分布来提高定位精度；cls_loss 衡量了分类准确性。从图 9 可以直观看到，改进后的 Wise-Inner-SIoU 损失函数在训练和验证阶段的收敛速度明显优于原始的 CIoU 损失函数。特别是在训练初期，改进后的损失函数在 box_loss 和 dfl_loss 上表现出更快的收敛速度，表现为 Wise-Inner-SIoU 下降更为迅速。这一趋势在训练和验证阶段都得到了体现，表明改进后的损失函数能够在更短的时间内达到收敛。

3) 特征图可视化

为了验证改进后 Wise-Inner-SIoU 损失函数的可视化效果，本文以黑芯为例对深层网络 P5 层的特征图进行了绘制。由于特征图浅层的分辨率较高，难以直观呈现效果，因此，本文通过对比分析深层网络特征图中的聚集效果，并基于实验结果进行了详细讨论。CIoU、Wise-SIoU 和 Wise-Inner-SIoU 损失函数所对应的特征图如图 10~12 所示。

由图 10 可知，CIoU 损失函数的特征图表现为更加分散的激活模式，较多区域显示出不规则的图案，激活不够集中。

Wise-SIoU 损失函数的特征图相比 CIoU 有所改进，激活模式更加集中，但仍然表现出一定的分散性。

Wise-Inner-SIoU 损失函数的特征图表现为最为集中，主要集中在目标当中。这表明该模型在关注目标方面具有更好的能力，这与实验结果一致，即 Wise-Inner-SIoU 在召回率和平均精度上表现最好，显示出更强的检测性能。

2.7 可视化分析

1) 检测效果可视化

为验证所改进模型的检测能力，本文从测试集中选取了 8 张图像进行可视化分析。通过对 YOLO11n 与 CCMW-YOLO11n 改进模型在检测效果上的对比，如图 13 所示，进一步验证了改进算法的有效性。图 13(a) 中，YOLO11n 模型未能成功检测出黑芯目标，存在漏检现象；图 13(e) 中，YOLO11n 在断栅目标的检测过程中发生了误检；而在图 13(h) 中，YOLO11n 出现了对断栅和粗线的漏检问题。这些问题表明，YOLO11n 模型在处理多类别不同类型目标时，可能面临漏检与误检的挑战。相比之下，CCMW-YOLO11n 在同一测试集中的检测精度明显提高，优化了特征提取和目标定位能力，能够有效减少漏检和误检。

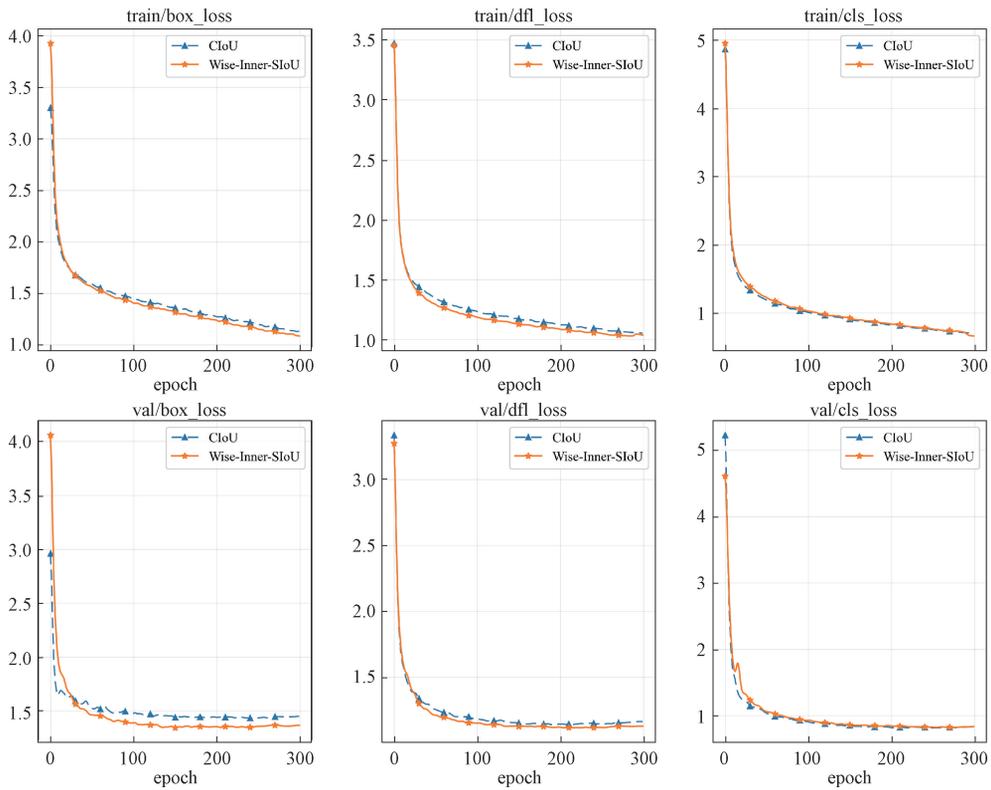


图 9 损失函数改进前后收敛速度对比

Fig. 9 Comparison of convergence speed before and after loss function improvement

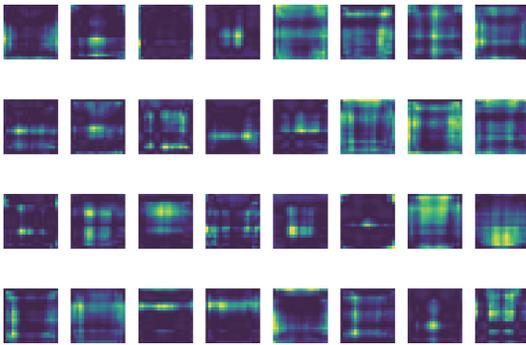


图 10 CIoU-特征图

Fig. 10 CIoU-feature map

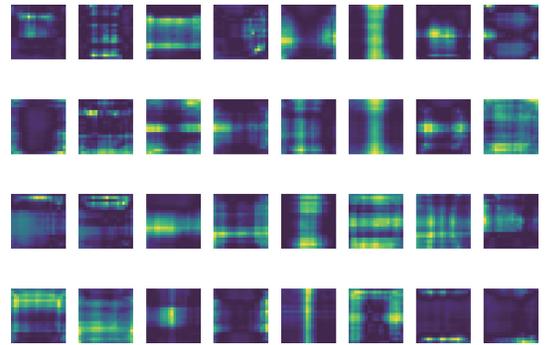


图 11 Wise-SIoU 特征图

Fig. 11 Wise-SIoU feature map

2) 热力图分析

为在浅层生成可靠的类激活图并获取更精确的细粒度目标定位信息,本文引入 LayerCAM 技术用于热力图生成。与传统的 Grad-CAM 方法相比,LayerCAM 通过重新审视特征图与对应梯度之间的关系,能够在定位中取得更佳效果。不同于以往仅考虑特征图整体信息的注意力方法,LayerCAM 借助梯度突出特征图中各个位置对特定类别的重要性,从而有效保留目标对象的细粒度细节并去除背景噪声。该方法具有如下优势:首先,LayerCAM 不仅能够从最终卷积层生成可靠的类激活图,

还可以在浅层应用,从而同时获得粗粒度空间定位信息与精细目标细节;其次,不同层生成的类激活图通常具有互补性,将其融合能够生成更精确且完整的类特定目标区域,显著提升弱监督任务的性能;最后,LayerCAM 可直接应用于现有的基于 CNN 的图像分类器,无需对网络结构或反向传播机制进行修改,因而具有更高的通用性与易用性。此外,从 CNN 浅层提取的细粒度定位信息亦可应用于工业场景中,以精确识别微小缺陷。为进一步验证方法的有效性,本文开展了多种模型的热力图对比实验(YOLO11n 结合 Grad-CAM 与 LayerCAM,以及本文提

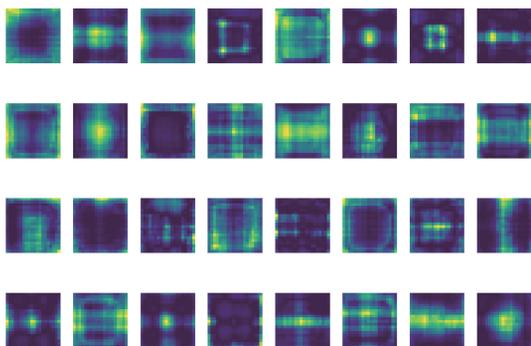


图 12 Wise-Inner-SIoU 特征图

Fig. 12 Wise-Inner-SIoU feature map

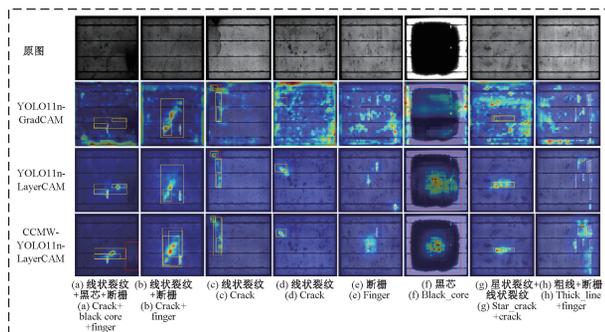


图 14 不同模型的热力图效果对比

Fig. 14 Comparison of the effect of heat maps of different models

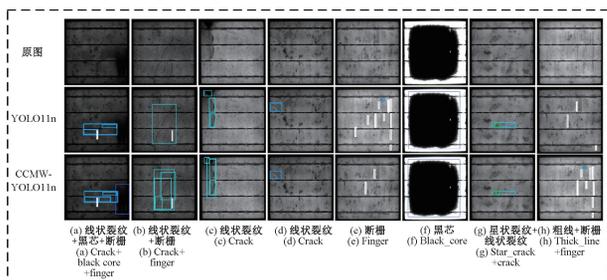


图 13 改进前后模型的可视化效果对比

Fig. 13 Comparison of visualization effects before and after model improvement

出的改进算法结合 LayerCAM 的热力图激活实验),如图 14 所示。实验结果表明,与普通可视化方法相比,热力图可视化能够更好地反映检测框内激活区域的集中效果;与传统 Grad-CAM 相比,LayerCAM 能够更聚焦于检测目标,而本文的改进算法在此基础上实现了更为准确的目标区域聚焦,在特征提取与目标定位方面展现出显著优势。

为进一步分析图 14 中各检测框的激活效果,本文对其中激活像素占比进行分析。统计每个检测框内激活区域的平均像素占比,并根据激活强度使用红、黄、绿 3 种颜色进行高亮显示。为区分背景与有效检测区域,设定 40% 的阈值。此外,除了分析激活区域的像素占比外,本文还考虑了聚焦程度这一因素,聚焦程度可通过直接观察热力图来进行评估,同时还应考虑误检和漏检的影响,实验结果如表 7 所示。结果表明,YOLO11n-GradCAM、YOLO11n-LayerCAM 和 CCMW-YOLO11n-LayerCAM 的热力图激活像素平均占比分别为 28.2%、34.3% 和 38.2%,在本文数据集上,LayerCAM 技术在热力图激活实验中表现良好,YOLO11n-LayerCAM 与 YOLO11n-GradCAM 相比,激活像素占比增加了 6.1%。此外,CCMW-YOLO11n 的热力图激活占比为 38.2%,为所有模型中的最高值。在聚焦程度方面,CCMW-YOLO11n 的检测框表现出更强的聚焦效果,同时在检测精度上也表现优异,反映出其漏检和误检率较低。综合来看,CCMW-YOLO11n 在激活占比、聚焦程度和检测精度方面均展现出较为优异的性能。

表 7 热力图激活区域分析实验

Table 7 Heatmap activation region analysis experiment

(%)

| 模型 | 图 14(a) ↑ | 图 14(b) ↑ | 图 14(c) ↑ | 图 14(d) ↑ | 图 14(e) ↑ | 图 14(f) ↑ | 图 14(g) ↑ | 图 14(h) ↑ | 平均占比 ↑ | 聚焦程度 |
|----|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|--------|------|
| 1 | 10.7 | 38.5 | 23.8 | 37.0 | 71.0 | 18.1 | 6.1 | 20.1 | 28.2 | 差 |
| 2 | 24.7 | 31.9 | 27.1 | 23.1 | 75.3 | 30.1 | 38.7 | 23.8 | 34.3 | 较好 |
| 3 | 27.1 | 36.1 | 28.3 | 35.2 | 50.2 | 25.7 | 78.1 | 24.7 | 38.2 | 较好 |

注:1 表示 YOLO11n-GradCAM;2 表示 YOLO11n-LayerCAM;3 表示 CCMW-YOLO11n-LayerCAM

3 结论

针对光伏电池缺陷检测中因背景复杂而导致的漏检、误检等问题,本文提出了一种基于 YOLO11n 的改进模型——CCMW-YOLO11n。该模型在骨干网络中提出了 CSP-I 模块,增强了模型对全局与局部特征的综合提取能力;在颈部网络中采用了 CARAFE 上采样技术,该

方法能够根据局部特征内容灵活调整权重,有效保留光伏电池的边缘、纹理等细节信息,增强了模型对小目标以及复杂结构的识别;同时融入 MAN-E 模块进一步增强了颈部网络的特征表达能力;此外,提出了 Wise-Inner-SIoU 损失函数替代传统的 CIoU 损失,进一步优化了定位性能。实验结果表明,改进后的模型在复杂背景的光伏电池缺陷数据集上,mAP@0.5 和 mAP@0.5:0.95 分别达到了 91.0% 和 61.1%,较原始 YOLO11n 模型分别提升了

3.1%和2.0%,实现了对光伏电池缺陷的有效检测。然而,该模型目前主要针对5类常见缺陷表现优异,后续工作将致力于扩展数据集,涵盖更多缺陷类型,以进一步提升模型在多样化缺陷检测任务中的适应性和精度。

参考文献

- [1] DHIMISH M. Micro cracks distribution and power degradation of polycrystalline solar cells wafer: Observations constructed from the analysis of 4000 samples[J]. *Renewable Energy*, 2020, 145: 466-477.
- [2] ZHU B, LI L, HU X, et al. DEFOG: Deep learning with attention mechanism enabled cross-age face recognition [J]. *Tsinghua Science and Technology*, 2024, 30(3): 1342-1358.
- [3] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展 [J]. *仪器仪表学报*, 2022, 43(1): 198-219.
- ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(1): 198-219.
- [4] MA J, GAO X, WANG J, et al. Surface defect detection of solar cells based on Fourier single-pixel imaging for removal of substrates interference [J]. *Optics and Lasers in Engineering*, 2024, 176: 108073.
- [5] LIU Y C, HUA Q, CHEN L L, et al. A Multi-scale neighbourhood feature interaction network for photovoltaic cell defect detection [J]. *Knowledge-Based Systems*, 2025, 309: 112882.
- [6] SU B, ZHOU Z, CHEN H. PVEL-AD: A large-scale open-world dataset for photovoltaic cell anomaly detection [J]. *IEEE Transactions on Industrial Informatics*, 2022, 19(1): 404-413.
- [7] LI W, WANG F, SUN Z. Semantic segmentation method of photovoltaic cell microcracks based on EL polarization imaging [J]. *Solar Energy*, 2025, 291: 113364.
- [8] WANG S, CHEN H, ZHANG Z, et al. Multi-scale feature decoupling and similarity distillation for class-incremental defect detection of photovoltaic cells [J]. *Measurement*, 2024, 225: 113997.
- [9] ZHANG J, CHEN X, WEI H, et al. A lightweight network for photovoltaic cell defect detection in electroluminescence images based on neural architecture search and knowledge distillation [J]. *Applied Energy*, 2024, 355: 122184.
- [10] HASSAN S, DHIMISH M. Broad-scale electroluminescence analysis of 5 million+ photovoltaic cells for defect detection and degradation assessment [J]. *Renewable Energy*, 2024, 237: 121868.
- [11] 谢林森, 朱文忠, 谢康康, 等. 基于改进YOLOv5s的光伏电池EL缺陷图像检测模型 [J]. *国外电子测量技术*, 2023, 42(6): 93-102.
- XIE L S, ZHU W ZH, XIE K K, et al. Improved YOLOv5s-based image detection model for EL defects in photovoltaic cells [J]. *Foreign Electronic Measurement Technology*, 2023, 42(6): 93-102.
- [12] 管宽岐, 蔺雨桐, 赵雨薇, 等. 基于深度学习的航拍光伏板红外图像热斑检测方法研究 [J]. *电子测量技术*, 2022, 45(22): 75-81.
- GUAN K Q, LIN Y T, ZHAO Y W, et al. Research on thermal spot detection method for aerial photovoltaic panel infrared images based on deep learning [J]. *Electronic Measurement Technology*, 2022, 45(22): 75-81.
- [13] ZHANG J, YANG W, CHEN Y, et al. Fast object detection of anomaly photovoltaic (PV) cells using deep neural networks [J]. *Applied Energy*, 2024, 372: 123759.
- [14] BAO J, YUAN X, WU Q, et al. CCA-YOLO: Channel and coordinate aware-based YOLO for photovoltaic cell defect detection in electroluminescence images [J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 5009412.
- [15] ZHU J, ZHOU D, LU R, et al. C2DEM-YOLO: Improved YOLOv8 for defect detection of photovoltaic cell modules in electroluminescence image [J]. *Nondestructive Testing and Evaluation*, 2025, 40(1): 309-331.
- [16] 冯哲, 王彬, 黄鹏程, 等. 小天体表面着陆区岩石目标检测算法 [J]. *仪器仪表学报*, 2024, 45(4): 194-205.
- FENG ZH, WANG B, HUANG P CH, et al. Algorithm of detection rock object in landing zone of small celestial body surface [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(4): 194-205.
- [17] 袁磊, 唐海, 陈彦蓉, 等. SGCNet: 一种轻量化的新能源汽车电池集流盘缺陷检测模型 [J]. *电子测量与仪器学报*, 2023, 37(10): 172-182.
- YUAN L, TANG H, CHEN Y R, et al. SGCNet: A lightweight defect detection model for new energy vehicle battery collector tray [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(10): 172-182.
- [18] 沈骞, 张磊, 张宇翔, 等. 基于改进YOLOv8n的轻量化分心驾驶行为检测方法 [J]. *电子测量技术*, 2024, 47(24): 65-75.
- SHEN Q, ZHANG L, ZHANG Y X, et al. Lightweight distracted driving behavior detection method based on

- improved YOLOv8n [J]. *Electronic Measurement Technology*, 2024, 47(24): 65-75.
- [19] 冉险生, 李锐, 贺帅. 基于改进 YOLOv5s 的道路障碍物检测算法 [J]. *电子测量技术*, 2023, 46(22): 177-185.
- RAN X SH, LI R, HE SH. Road obstacle detection algorithm based on improved YOLOv5s [J]. *Electronic Measurement Technology*, 2024, 46(22): 177-185.
- [20] SHEN L, TAO H, NI Y, et al. Improved YOLOv3 model with feature map cropping for multi-scale road object detection [J]. *Measurement Science and Technology*, 2023, 34(4): 045406.
- [21] DUAN S, ZHANG M, QIU S, et al. Tunnel lining crack detection model based on improved YOLOv5 [J]. *Tunnelling and Underground Space Technology*, 2024, 147: 105713.
- [22] CAO Y, PANG D, ZHAO Q, et al. Improved YOLOv8-GD deep learning model for defect detection in electroluminescence images of solar photovoltaic modules [J]. *Engineering Applications of Artificial Intelligence*, 2024, 131: 107866.
- [23] AN R, ZHANG X, SUN M, et al. GC-YOLOv9: Innovative smart city traffic monitoring solution [J]. *Alexandria Engineering Journal*, 2024, 106: 277-287.
- [24] MEI J, ZHU W. BGF-YOLOv10: Small object detection algorithm from unmanned aerial vehicle perspective based on improved YOLOv10 [J]. *Sensors*, 2024, 24(21): 6911.
- [25] ZHAO Y, JIANG Z. YOLO-WWBi: An optimized YOLO11 algorithm for PCB defect detection [J]. *IEEE Access*, 2025, 13: 74288-74297.
- [26] CUI B, LIU Z, YANG Q. UAV-YOLO12: A multi-scale road segmentation model for UAV remote sensing imagery [J]. *Drones*, 2025, 9(8): 533.
- [27] FENG Y, HUANG J, DU S, et al. Hyper-YOLO: When visual object detection meets hypergraph computation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 47(4): 2388-2401.
- [28] KUMARAN S Y, JEYA J J, MAHESH R T, et al. Explainable lung cancer classification with ensemble transfer learning of VGG16, Resnet50 and InceptionV3 using grad-cam [J]. *BMC Medical Imaging*, 2024, 24(1): 176.
- [29] NAWAZ S A, LI J, SHOUKAT M U, et al. Hybrid

medical image zero watermarking via discrete wavelet transform-ResNet101 and discrete cosine transform [J]. *Computers and Electrical Engineering*, 2023, 112: 108985.

作者简介



邓玉澳, 2023 年于郑州航空工业管理学院得学士学位, 现为上海电力大学硕士研究生, 主要研究方向为深度学习、目标检测。

E-mail: deng_yuao@163.com

Deng Yuao received his B. Sc. degree from Zhengzhou University of Aeronautics in 2023. Now he is a M. Sc. candidate at Shanghai University of Electric Power. His main research interests include deep learning and object detection.



王丹豪 (通信作者), 2025 年于上海电力大学获得博士学位, 现为上海电力大学讲师, 主要研究方向为智能巡检机器人以及智慧电厂相关软件的开发。

E-mail: danhao.wang@shiep.edu.cn

Wang Danhao (Corresponding author) received his Ph. D. degree from Shanghai University of Electric Power in 2025. Now he is a lecturer at Shanghai University of Electric Power. His main research interests include intelligent inspection robots and the development of software related to smart power plants.



潘俊臻, 2023 年于上海电力大学获得硕士学位, 现为上海电力大学博士研究生, 主要研究方向为深度学习和目标检测。

E-mail: panjunzhen0712@163.com

Pan Junzhen received his M. Sc. degree from Shanghai University of Electric Power in 2023. Now he is a Ph. D. candidate at Shanghai University of Electric Power. His main research interests include deep learning and object detection.



彭道刚, 2009 年于同济大学获博士学位, 现为上海电力大学教授, 主要研究方向为智能发电、综合智慧能源。

E-mail: pengdaogang@126.com

Peng Daogang received his Ph. D. degree from Tongji University in 2009. Now he is a professor at Shanghai University of Electric Power. His main research interests include intelligent power generation, integrated smart energy.