

DOI:10.19651/j.cnki.emt.2518490

基于改进 YOLOv8 的光伏电池缺陷检测^{*}

刘闯闯¹ 袁金丽¹ 郑美曼¹ 吴晨曦¹ 郭志涛^{1,2}

(1. 河北工业大学电子信息工程学院 天津 300130; 2. 河北工业大学创新研究院(石家庄) 石家庄 050299)

摘要: 针对传统视觉方法在太阳能电池检测中面临的小目标缺陷识别准确率低、不同尺度特征捕获能力不足等问题,本文提出了一种基于跨尺度特征增强与动态参数优化的 YOLOv8 改进算法。首先,以多分支残差结构为核心,融合重参数化技术与可调膨胀卷积,设计膨胀重参数残差模块,通过跨层级特征交互增强目标缺陷的上下文感知能力,提高检测精度;其次,在 C2f 模块中嵌入可变形卷积,结合辅助检测模块构建动态特征适应网络,提升对微小缺陷的几何特征提取;最后,引入具有动态聚焦机制的损失函数优化边界框匹配,提高回归精度。实验结果表明,改进模型在 3.03 M 参数量下实现 91.8% 的平均精度,较基准模型提升 4%,保持轻量参数同时提高了检测性能。

关键词: 光伏缺陷; YOLOv8; 膨胀残差; 重参数; 可变形卷积; 辅助检测

中图分类号: TN41 文献标识码: A 国家标准学科分类代码: 520.6040

Enhanced YOLOv8 for photovoltaic cell defect detection

Liu Chuangchuang¹ Yuan Jinli¹ Zheng Meiman¹ Wu Chenxi¹ Guo Zhitao^{1,2}

(1. College of Electronic Information Engineering, Hebei University of Technology, Tianjin 300130, China;

2. Innovation Research Institute, Hebei University of Technology (Shijiazhuang), Shijiazhuang 050299, China)

Abstract: To address the challenges of low recognition accuracy for small target defects and insufficient multi-scale feature capture capability in traditional vision-based methods for solar cell inspection, this study proposes an improved YOLOv8 algorithm based on cross-scale feature enhancement and dynamic parameter optimization. First, a multi-branch residual structure is designed as the core, integrating re-parameterization techniques and adjustable dilated convolution to construct the dilation-enhanced reparametrized residual block, which enhances contextual awareness of target defects through cross-layer feature interaction, thereby improving detection accuracy. Second, deformable convolutional networks version 2 are embedded into the C2f module, combined with an auxiliary detection module to build a dynamic feature adaptation network, improving geometric feature extraction for micro-defects. Finally, a wise intersection over union loss function with a dynamic focusing mechanism is introduced to optimize bounding box matching and enhance regression precision. Experimental results demonstrate that the improved model achieves a mean average precision of 91.8% with only 3.03 M parameters, outperforming the baseline model by 4% while maintaining lightweight architecture and improved detection performance.

Keywords: photovoltaic defects; YOLOv8; dilated residual; reparameterization; deformable convolution; auxiliary detection

0 引言

光伏产业的高速发展推动了太阳能电池板的规模化应用。然而在制造、运输和使用全周期中,电池板易产生隐裂、断栅等缺陷,导致光电转换效率衰减与使用寿命缩短,引发安全风险。因此,发展基于计算机视觉的智能缺陷检测技术,对保障光伏电站安全稳定运行具有重要工程价值。

目前国内外在光伏电池缺陷检测领域有多种方法,人工检测法虽然可以检测出太阳能电池板的缺陷,但存在效率低下、误检率高等局限性,难以适配规模化生产需求。而伏安测量、光致发光和电致发光等方法虽具备缺陷检测能力,但在检测范围、精度和速度上需要进一步优化^[1-3]。近年来,深度学习技术特别是卷积神经网络(convolutional neural network,CNN)在图像处理领域取得突破性进展,基于

收稿日期:2025-04-01

* 基金项目:河北工业大学创新研究院(石家庄)石家庄市科技合作专项基金(SJZZXB23005,SJZZXC24011)项目资助

CNN 的工业级太阳能电池缺陷检测展现出巨大潜力。相比传统机器学习方法,CNN 模型具有更强的通用性、出色的泛化能力和更高的综合性能^[4]。当前主流检测模型可分为一阶段算法(YOLO 系列等)和两阶段算法(Faster-RCNN 等)。相较于两阶段检测算法,一阶段模型在保持接近的检测精度前提下展现出更优的推理速度,这一特性使其在工业实时检测场景中具有更强的技术适配性^[5]。

为了提升检测性能,现有检测算法在原有基础上进行了多方面改进。Zhang 等^[6]提出了一种改进的 SSD 算法,通过关键特征层通道连接与默认框尺寸调整增强小目标检测能力。徐威等^[7]在 YOLOv7-tiny 框架中引入轻量化 PSDConv 模块与解耦全连接注意力机制,强化目标缺陷的特征表征能力并提高检测速度。Su 等^[8]设计 BAF-Detector 检测器,构建双向注意力特征金字塔网络并将其集成至 Faster-RCNN + FPN 框架,提升多类别缺陷检测效果。汪方斌等^[9]在 U-Net 网络模型中融入 MobileNet 深度可分离卷积与 ECA 注意力机制,通过改进激活函数设计与损失函数优化策略,提升光伏缺陷的检测效率与分割精度。Tu 等^[10]在 YOLOv5 框架中引入对比学习机制,通过设计联合损失函数(目标检测损失与对比损失协同优化),增强背景与目标特征的区分度,进而提升检测性能。张冀等^[11]在 YOLOv8 模型融入感受野坐标注意力机制与重参数模块,结合辅助检测机制抑制背景干扰并优化小目标检测性能。

当前缺陷检测算法在工程应用中仍面临多方面技术瓶颈:传统卷积网络对微小缺陷的特征表征能力不足,易因局部信息丢失导致漏检;多尺度特征融合机制难以兼顾浅层定位信息与深层语义信息的有效互补,影响复杂背景下的检测精度和鲁棒性;常规损失函数对低质量样本的权重分配机制存在敏感性,导致模型泛化能力受限。针对上述问题,本文提出基于 YOLOv8n 的改进方案,旨在保持 YOLO 模型轻量化优势的同时,提高检测精度和鲁棒性,为光伏电池质量检测提供可靠的技术方案,主要工作如下:

1) 设计膨胀重参数残差特征提取模块,通过残差连接^[12]强化梯度传播、膨胀卷积扩展感受野、参数重参化优化特征复用效率,提升微小缺陷的特征表征能力并降低模型复杂度。

2) 将可变形卷积集成至 C2f 层,利用动态调整卷积核自适应匹配缺陷形态,结合辅助检测模块实现多尺度特征的空间融合,突破传统卷积感受野限制,提升对复杂形变的特征提取精度。

3) 基于动态梯度权重调节机制优化损失函数,通过抑制低质量样本的梯度主导效应,缓解模型训练过程中的优化偏差,提升模型收敛效率。

1 研究方法

1.1 YOLOv8 结构与工作原理

YOLOv8 作为单阶段目标检测算法的典型代表,凭借

其快速响应和高精度特性在工业检测领域展现重要应用价值^[13]。该模型由主干网络(Backbone)、颈部网络(Neck)和检测头(Head)3 部分组成,具体结构如图 1 所示。

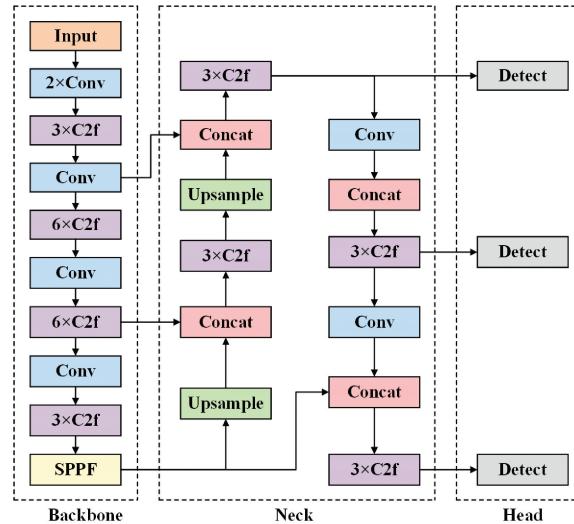


图 1 YOLOv8 网络结构

Fig. 1 YOLOv8 network structure

Backbone 采用 CSPDarknet 结构,由卷积层、C2f 模块以及 SPPF 模块组成。卷积层执行图像尺寸调整与通道数变换,完成初级特征提取;C2f 模块通过跨层分支连接优化梯度传播,支持不同模型尺寸的灵活适配。SPPF 模块通过自适应池化处理将输入特征图的动态尺寸转换为统一维度的特征向量。

Neck 结构包含 C2f 模块、上采样层和 Concat 模块,其中上采样层用于扩大特征图分辨率以提升小目标识别能力,Concat 模块则实现深层语义特征与浅层定位特征的融合。

Head 部分作为网络输出层集成多级检测分支,输出不同尺度的检测结果,并通过损失函数计算网络预测值与真实标签间的误差以便优化网络参数^[14-15]。

1.2 改进的 YOLOv8 检测模型

为解决光伏电池板缺陷检测中小尺寸缺陷检测精度低、遮挡场景下识别稳定性差的问题,本文对 YOLOv8 模型进行改进。改进后的模型结构如图 2 所示,其中(a)、(b)分别展示了膨胀重参数残差模块和可变形卷积在 C2f 中的融合结构。

1) 膨胀重参数残差特征提取模块

在目标尺度差异较大或背景复杂的检测场景下,YOLOv8 模型难以有效提取跨尺度上下文信息,导致微小缺陷误检率升高。为此,本文提出膨胀重参数残差特征提取模块(dilation-enhanced reparametrized residual block, DRRB),通过动态残差学习与膨胀卷积增强了多尺度特征提取能力,同时结合结构重参数化技术提升跨层级特征融合效率,从而增强模型检测精度与鲁棒性。

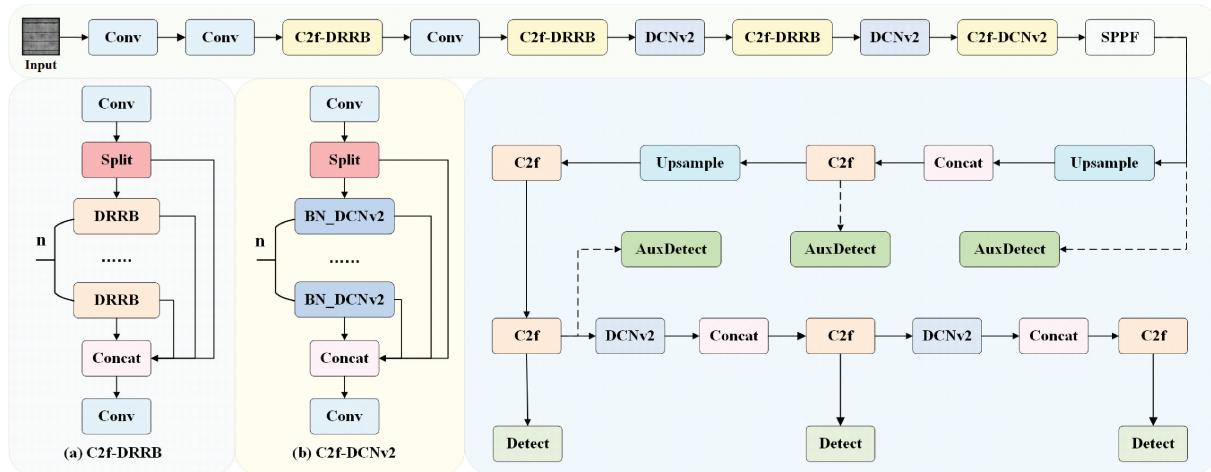


图 2 改进后 YOLOv8 的整体网络结构

Fig. 2 Improved YOLOv8 overall structure diagram

DRRB 的核心组件是膨胀残差模块 (dilation-wise residual, DWR)，其结构如图 3 所示，该模块采用残差结构，通过两阶段残差化策略实现高效多尺度特征提取，并将生成的感受野特征图进行融合^[16]。其中 RR 和 SR 分别表示区域残差 (region residuals) 和语义残差 (semantic residuals)，c 表示不同分支通道数。

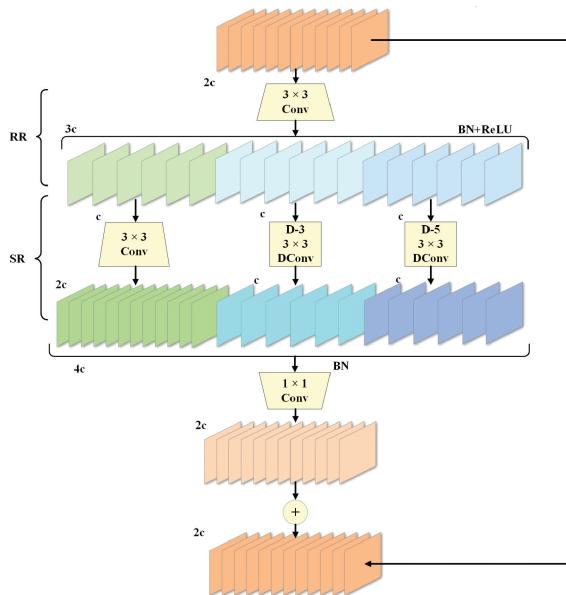


图 3 DWR 模型结构

Fig. 3 DWR model structure

一阶段为区域残差化，通过通道动态分配策略 ($1c/2c/4c$ 分支) 形成不同尺度的区域表达^[17]，其中小通道分支聚焦局部细节，大通道分支捕获广域上下文，为形态学滤波提供适配性输入；二阶段为语义残差化，对不同通道分支施加差异化膨胀率 ($d1/3/5$) 的深度卷积，使高通道分支优先处理大感受野特征，低通道分支专注精细结构，实现计

算资源与特征表达的动态匹配，确保局部细节与全局语义的高效协同。

为了进一步增强 DWR 模块的特征提取能力并降低冗余计算量，在其中引入重参数机制，替换普通卷积为膨胀重参数化块 (dilated reparam block, DRB)^[18]。如图 4 所示，该模块通过参数融合方式将大核卷积层与平行的轻量级分支 (小核卷积与膨胀卷积) 进行拓扑整合，输出在批处理归一化层之后相加。大核卷积层负责提取大尺度空间特征，轻量级分支通过膨胀卷积扩展小目标缺陷的感知范围，二者借助参数共享机制实现跨粒度特征互补。

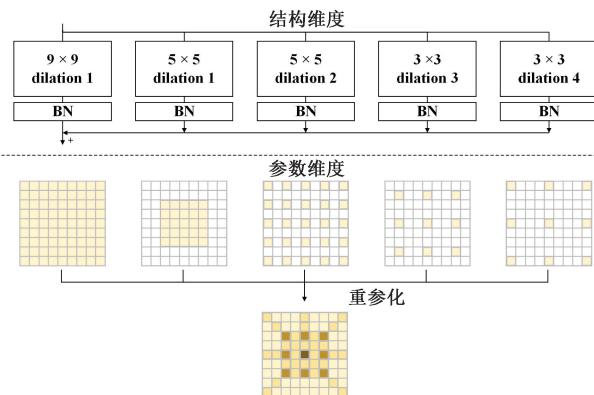


图 4 DRB 结构

Fig. 4 DRB structure

将 DRRB 融合进 Backbone 部分的 C2f 模块，在训练阶段利用密集跨层连接捕获多粒度空间特征，推理阶段通过线性等效转换提升计算效率，保持轻量参数的同时提升小目标检测中的细节信息提取与空间判别能力。

2) 可变形卷积模块

普通卷积在处理具有不规则形状和复杂背景的目标时，可能存在适应性不足的问题，导致信息提取不完全。在 YOLOv8 中引入可变形卷积 (deformable convolutional

networks version 2, DCNv2),使得卷积核能够动态调整,从而灵活适应不同物体的形状和姿态。

可变形卷积模块由可变形卷积层、批归一化层和 ReLU 激活函数构成^[19]。如图 5 所示,可变形卷积通过两个独立卷积分支分别预测空间偏移量与调制系数。其中,偏移量分支通过 $2N$ 通道的卷积层生成 N 个采样点的坐标偏移量,调制分支则通过 N 通道卷积层输出对应采样点的权重调整系数。

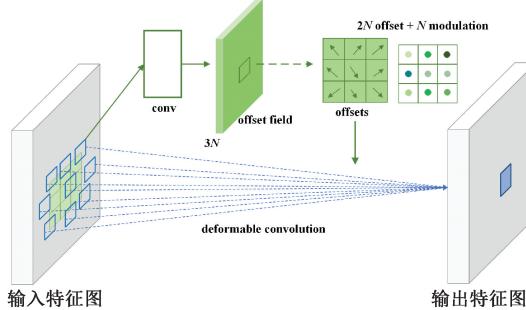


图 5 可变卷积层示意图

Fig. 5 DCNv2 structure

两组参数通过双线性插值实现不规则位置的特征聚合,逐步建立对目标几何形变的自适应能力。如图 6 所示,DCNv2 替换标准卷积后有效突破固定感受野限制,使检测网络聚焦于裂纹区域(红色高响应区),实现自适应采样。在此基础上,DCNv2 与 C2f 模块的融合进一步拓宽了小尺度缺陷特征提取时的感受野,增强模型对全局场景的理解能力,提升对小样本缺陷的识别精度。

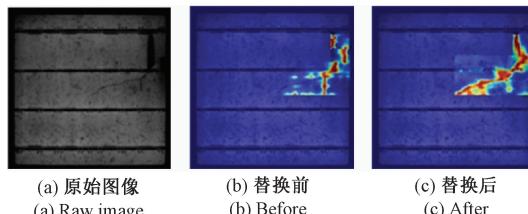


图 6 引入 DCNv2 模块前后的热力图

Fig. 6 Heatmaps with/without DCNv2

3) 辅助检测模块

YOLOv8 模型在处理较大尺寸缺陷时,容易因上采样和特征融合过程丢失全局信息,导致浅层特征融合不足,进而影响小目标缺陷的检测精度。为此,本文通过在网络中增加辅助检测模块(auxiliary detection module, Aux Detect),结合多尺度特征融合和辅助损失的策略,能够加强模型对不同尺度目标的感知能力,提升检测性能。

如图 7 所示,在网络中间层中集成 3 个辅助检测头完成标签分配。该方法通过对真实标签与预测结果计算对齐分数,依据真实框与预测框的对齐度排序,筛选匹配度最高的预测框作为正样本^[20]。公式为:

$$t = s^e \times \mu^\beta \quad (1)$$

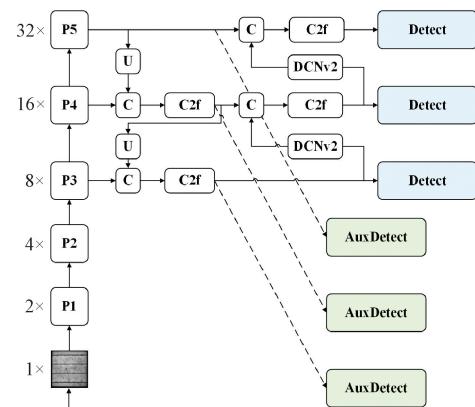


图 7 辅助检测头改进模型

Fig. 7 Improved model of auxiliary detection head

其中, t 为对齐分数, s 为预测类别置信度, μ 为预测框与真实框的交并比, α 与 β 为超参数权重。

主检测头执行细粒度标签分配以提升定位精度,辅助检测头则采用粗粒度标签分配扩大样本覆盖率。如图 8 所示,主检测头通过标签分配器生成高精度样本,辅助检测头则生成低精度样本,分别进行损失计算。该设计通过辅助检测头的监督域扩展增强微小缺陷的识别能力,同时利用主检测头的置信度阈值筛选机制保留优质预测框,在提升辅助检测头召回率、降低漏检风险的同时,有效规避低精度样本对最终检测结果的干扰。

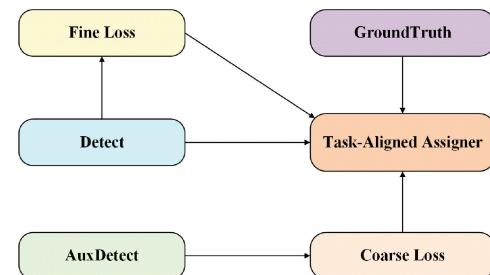


图 8 辅助头训练策略

Fig. 8 Auxiliary head training strategies

4) Wise-IoU 损失函数

针对 YOLOv8 模型在训练过程中因低质量样本导致的泛化能力受限问题,使用具有动态聚焦机制的损失函数(wise intersection over union, Wise-IoU)替换原有损失函数,引入动态非单调聚焦机制,提高模型的定位精度^[21]。

Wise-IoU 通过异常度来识别和减轻低质量样本的负面影响,其损失函数 $LWIoUv3$ 通过动态调整梯度增益来优化模型的训练效果,定义为:

$$LWIoUv3 = rLWIoUv1, r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \quad (2)$$

$$LWIoUv1 = RWIoU LIoU \quad (3)$$

$$RWIoUv3 = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \quad (4)$$

如图 9 所示, W_g 和 H_g 等是最小包围框的参数; r 是动态非单调聚焦系数, 用于控制聚焦程度; δ, α 用于调整 r 的动态特性。锚框的异常程度 β 的表达式为:

$$\beta = \frac{L^* IoU}{L IoU} \in [0, +\infty] \quad (5)$$

$$L IoU = 1 - IoU = 1 - \frac{H_i W_i}{S_u} \quad (6)$$

其中, $L^* IoU$ 是当前锚框的 IoU 值, S_u 是锚框与目标框的并集面积。

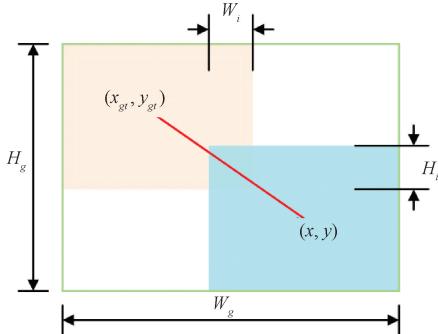


图 9 最小包围框示意图

Fig. 9 Minimum bounding box schematic diagram

通过动态非单调聚焦和梯度增益分配机制, W -IoU 能够更有效地处理低质量样本, 提高模型的训练效率和最终检测精度。

2 实验设计与结果分析

2.1 实验配置

本实验配备一块 16 GB 显存的 RTX 2080 Ti 显卡, 满足深度学习模型训练的硬件要求。操作系统为 Windows10, 学习框架为 PyTorch 2.0.0 和 CUDA 11.7。输入图像尺寸设置为 640×640 , 训练周期 epochs 设定为

500 轮, 批量 batch 设置为 4, 学习速率设为 0.001。

2.2 数据集预处理

本文选用 PVEL-AD 公开数据集作为基础, 该数据集包含 36 543 张多晶硅异常缺陷图像, 涵盖裂纹、黑芯等 12 类缺陷。经筛选后, 重点选取了 6 类常见缺陷进行后续研究^[22], 具体包括: 线性裂纹 (line crack)、星形裂纹 (star crack)、断栅 (finger)、黑芯 (black core)、垂直错位 (vertical dislocation) 和水平错位 (horizontal dislocation), 相关样本示例如图 10 所示。

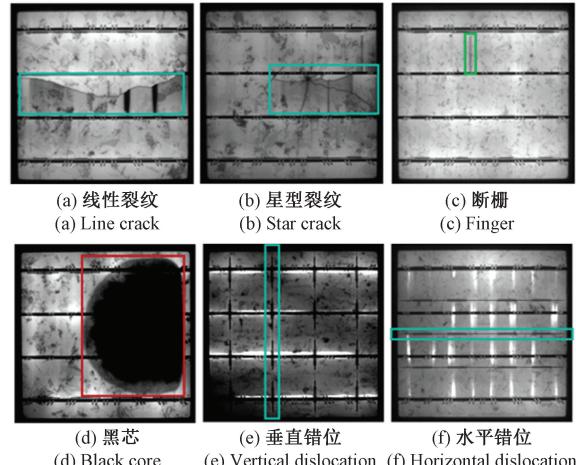


图 10 光伏电池缺陷样本示例

Fig. 10 Photovoltaic cell defects sample examples

其中, 星形裂纹 (103 张) 和垂直错位 (34 张) 两类样本数量偏少, 会影响最终检测精度。为此, 本文采用几何变换、空间调整等数据增强方法对图像进行优化, 最终获得 4 065 张有效图像, 然后按照训练集、验证集和测试集 7:2:1 的比例对数据进行划分, 具体缺陷类别和划分如表 1 所示。

表 1 扩增后标签分布

Table 1 Label distribution after amplification

数据集	Ck	Fr	Bk	S_Ck	Hl	Vl	Total
Train	521	882	789	336	216	104	2 848
Valid	149	266	213	89	65	32	814
Test	98	120	109	55	10	12	403
Total	768	1 268	1 111	480	291	148	4 065

注: 当单张图像中存在多个同类缺陷时, 仅作单次计数处理。Ck 等缩写指代前述 6 种缺陷类别。

2.3 模型性能评估指标

本研究通过 4 项核心指标对改进模型的性能表现进行评估, 各项指标及功能如表 2 所示。

mAP 的计算公式如下:

$$Pr = \frac{TP}{TP + FP} \quad (7)$$

$$Re = \frac{TP}{TP + FN} \quad (8)$$

表 2 性能评估指标

Table 2 Performance evaluation metrics

评价指标	功能
平均精度 (mAP)	衡量综合检测能力
参数量 (Params)	反映模型复杂度
计算量 (Flops)	表征运算资源需求
帧率 (FPS)	评估实时处理效能

$$AP = \int_0^1 P(r)dr \quad (9)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i/N \quad (10)$$

其中, P_r 表示准确率, R_e 表示召回率; TP 表示正确预测的正类样本量, FP 表示正确预测的负类样本量, FN 表示错误预测的正类样本量; AP 的计算基于精确率与召回率构成的 P-R 曲线下的面积,所有类别 AP 值的均值构成全局 mAP 指标。

2.4 检测结果与分析

模型训练完成后,通过分析训练日志指标并绘制可视化曲线和表格进行性能评估,改进前后的 YOLOv8 单类缺陷 AP 值和整体 mAP 值对比如表 3、图 11 所示。改进后的 YOLOv8 算法预测裂纹的 AP 值为 71.3%,较改进前提升 6.3%;断栅的 AP 值为 95.8%,提升 1.1%;黑芯 AP 值为 99.5%,无提升;星形裂纹 AP 值为 90.7%,提升 13.9%;水平错位 AP 值为 97.7%,提升 1%;垂直错位 AP 值为 95.7%,提升 1.7%;六类缺陷的 mAP 值为 91.8%,提升 4%。实验结果表明,改进后的模型对裂纹、断栅等小目标缺陷的检测精度提升显著,而对于已接近 100% 的大目标如黑芯,则未表现出明显改善。

2.5 消融实验

本文采用模块化消融策略进行对比实验,通过逐项激活核心改进模块分析其性能增益,具体实验结果如表 4 所示。

表 4 消融实验
Table 4 Melting experiment

模型	WIoU	DRRB	DCNv2	AuxDetect	FPS	Params/M	FLOPs/G	mAP/%
YOLOv8n	—	—	—	—	96.6	3.01	8.1	87.8
1	✓	—	—	—	91.7	3.01	8.1	88.4
2	✓	✓	—	—	82.3	2.84	7.8	89.8
3	✓	—	✓	—	94.2	3.04	8.0	89.3
4	✓	—	—	✓	97.1	3.01	8.1	88.6
5	✓	—	✓	✓	90.5	3.10	8.0	90.5
6	✓	✓	✓	—	86.1	3.01	7.6	90.9
7	✓	✓	✓	✓	88.6	3.03	7.9	91.8

由表 4 可知,模型 1 将 YOLOv8n 的损失函数替换为 Wise-IoU(后续实验保持不变), mAP 提升 0.6%;模型 2 在主干部分的 C2f 层融合 DRRB 模块,膨胀残差和重参数技术的使用使参数量下降 0.17 M,计算量下降 0.3 G, mAP 提升 2%;模型 3 使用 DCNv2 替换部分标准卷积,增强卷积的几何转换能力, mAP 提升 1.5%;对比模型 4 和 5,单独添加辅助检测头时检测精度提升不明显,但与 DCNv2 和 WIoU 结合后,网络的表达能力增强, mAP 提升 2.7%;模型 6 通过联合应用 DRRB 与 DCNv2 模块优化特征提取结构,相较于单一模块配置, mAP 显著提升 3.2%;模型 7 在模型 6 的基础上增加 DRRB 模块,尽管 FPS 略有

表 3 AP 值对比表
Table 3 AP value comparison

缺陷类型	AP/%	
	YOLOv8n	Ours
线性裂纹	65.0	71.3
星形裂纹	76.8	90.7
断栅	94.7	95.8
黑芯	99.5	99.5
垂直错位	94.0	95.7
水平错位	96.7	97.7
平均精度	87.8	91.8

注:改进前后的 mAP 值最高点已在图 11 中标出,由于引入早停机制,实际收敛过程在 200 多 epochs 完成。

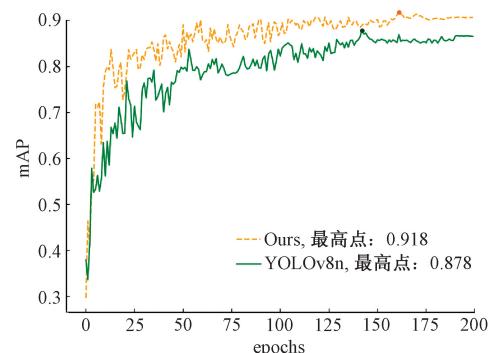


图 11 mAP 值对比图

Fig. 11 mAP value comparison

下降,但计算效率提升,精度进一步提升 1.3%。综合评估,改进后的模型在保持较小帧率损失的基础上,提升了训练速度和检测精度。

2.6 对比实验

1) 损失函数对比

为了验证 WIoU 损失函数的有效性,本文将其与 DIoU、GIoU、PIoU 和 SIoU 四种主流损失函数进行对比实验,结果如表 5 所示。实验表明,使用 WIoU 损失函数后模型的 mAP 提升 0.6%,在对比组中提升幅度最高,FPS 小幅下降;GIoU 与 WIoU 在 mAP 上的增益效果相近,但 FPS 下降更明显;DIoU 和 PIoU 的 mAP 相比改进前降低,

未实现性能优化;SIOU 的 mAP 提升较少且 FPS 降幅最大,效果不佳。综上,WIoU 损失函数在损失较少的 FPS 值的情况下,有效提高了检测精度。

表 5 损失函数对比结果

Table 5 Loss function comparison results

模型	Params/M	FLOPs/G	mAP/%	FPS
YOLOv8n	3.01	8.1	87.8	91.3
+DIoU	3.03	8.2	87.5	86.5
+GIoU	3.01	8.1	88.3	89.1
+PIoU	3.04	8.0	87.3	87.6
+SIOU	3.04	8.0	87.9	86.2
+WIoU	3.01	8.1	88.4	87.4

2)与其他模型对比

为系统评估模型的改进效果,本研究在 EL 数据集上开展多模型对比实验。对比模型包括 Faster-RCNN、SSD、YOLO 系列(YOLOv5s、YOLOv7-tiny、YOLOv10n)以及文献[9]和文献[12]的改进方法。实验重点针对检测精度与计算效率等核心指标进行系统性对比分析,具体实验结果如表 6 所示。

实验结果表明,改进后模型在多项指标上展现优势:与原始 YOLOv8n 相比,mAP 提升 4.0%且计算效率维持稳定;与轻量级 YOLOv10n 相比,参数量仅高出 0.34 M,但 mAP 提升 3%;相比两阶段模型 Faster-RCNN,mAP 提升幅度达 6.6%,且计算资源消耗大幅降低;文献[9]提出的 Faster-RCNN 改进模型参数量和计算量过高,且 mAP 值低于本文模型;相较于文献[12]的改进方案,本文模型在参数量增加更小的前提下实现更高的检测精度提升,较

表 6 模型检测性能对比

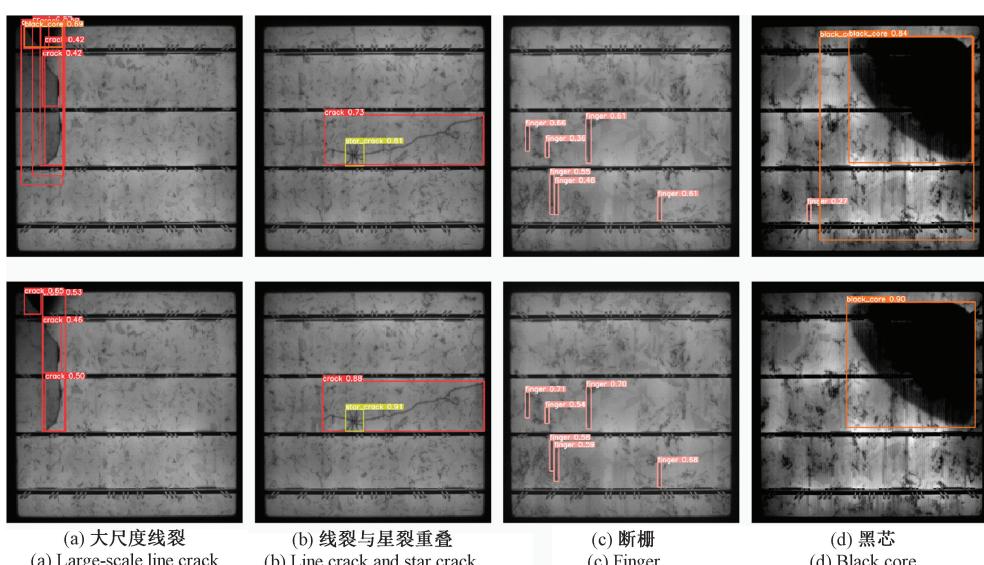
Table 6 Model detection performance comparison

模型	Params/M	FLOPs/G	mAP/%
Faster-RCNN	138.27	83.4	85.2
SSD	54.13	54.6	84.2
YOLOv5s	9.21	23.8	88.6
YOLO7-tiny	6.02	13.2	87.5
YOLOv8n	3.01	8.1	87.8
YOLOv10n	2.69	8.2	88.8
文献[9]	120.87	72.5	90.3
文献[12]	3.23	8.7	89.4
Ours	3.03	7.9	91.8

其提升 2.4%;在与 YOLOv5s、YOLO7-tiny 和 SSD 的对比中,改进模型在检测精度与训练速度方面均表现更优。上述数据验证了改进模型在精度提升与计算效率优化方面的平衡性优势。

2.7 检测效果对比

为了直观展示改进模型的性能提升,本文对测试集中部分图像进行检测,结果如图 12 所示。图 12(a)大尺寸线状裂纹缺陷场景中,YOLOv8n 因全局特征提取不足导致多次分段检测,而改进模型通过多尺度特征融合机制有效整合全局信息,实现完整缺陷检测;图 12(b)和(c)微小裂纹与断栅缺陷检测中,改进模型展现出更优的小目标捕捉能力;图 12(d)复杂背景下的黑芯缺陷检测场景,改进模型通过增强背景感知能力有效抑制原始模型的误判现象。综上,本文模型具有更强的特征融合能力和背景感知能力,有效减少误检和漏检,提升了整体检测性能。



注:上述 4 组对比样本中,每组上方图像为 YOLOv8n 检测结果,下方图像为改进后模型检测结果。

图 12 检测结果对比

Fig. 12 Detection results comparison

3 结 论

针对光伏电池缺陷检测的实际需求,本文提出一种基于 YOLOv8 的改进模型,在主干网络上将 DRRB 和 DCNv2 融合进 C2f 层,通过残差连接与动态感受野调整机制增强特征提取能力,提升微小缺陷的检测灵敏度。检测部分提出 AuxDetect 检测头结构,使用 DCNv2 替换普通卷积,进一步提升检测速度和精度;最后,使用 Wise-IoU 替换原有损失函数,精准优化边界框回归过程。实验结果表明,改进模型的 mAP 值达到了 91.8%,较 YOLOv8n 模型提升 4%,显示出更优的检测性能。在保持较低 FPS 损失的情况下,该模型在检测精度、参数计算量等性能指标上均有所提升。但改进后的模型仍存在漏检、误检的情况,实时性与精度的平衡表现欠佳,未来的研究需重点关注模型的轻量化实验,在保证帧率不变或提升的同时提高检测精度。

参考文献

- [1] 杨丽,杨晨晨,杨耿煌,等.改进 YOLOv8 的光伏电池缺陷检测算法[J].电子测量技术,2025,48(1): 92-99.
YANG L, YANG CH CH, YANG G H, et al. Improved YOLOv8-based defect detection algorithm for photovoltaic cells [J]. Electronic Measurement Technology, 2025, 48(1): 92-99.
- [2] 曹邵文,周国庆,蔡琦琳,等.太阳能电池综述:材料、政策驱动机制及应用前景[J].复合材料学报,2022,39(5):1847-1858.
CAO SH W, ZHOU G Q, CAI Q L, et al. Review of solar cells: materials, policy-driven mechanisms and application prospects [J]. Acta Materiae Compositae Sinica, 2022, 39(5):1847-1858.
- [3] 王巍,余欣,缪佳欣,等.基于改进 YOLOv5s 太阳能电池片表面缺陷检测算法[J].电子测量技术,2025,48(5):128-136.
WANG W, YU X, MIAO J X, et al. Improved YOLOv5s-based surface defect detection algorithm for solar cells [J]. Electronic Measurement Technology, 2025, 48(5): 128-136.
- [4] 胡志强,吴一全.基于机器视觉的芯片缺陷检测研究进展[J].仪器仪表学报,2024,45(7):1-26.
HU ZH Q, WU Y Q. Research progress on machine vision-based chip defect detection [J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 1-26.
- [5] 杨长春,贺轩轩,王睿,等.基于改进 YOLOv8 光伏板缺陷检测算法[J].电子测量技术,2024,47(23): 181-192.
YANG CH CH, HE X X, WANG R, et al. Improved YOLOv8-based defect detection algorithm for photovoltaic panels [J]. Electronic Measurement Technology, 2024, 47(23): 181-192.
- [6] ZHANG X, ZHANG Y N, GAO T, et al. A novel SSD-based detection algorithm suitable for small object [J]. IEICE Transactions on Information and Systems, 2023, 106(5): 625-634.
- [7] 徐威,李为相,方志,等.基于改进 YOLOv7-tiny 的光伏电池缺陷检测算法[J].计算机工程与应用,2024,60(15):336-343.
XU W, LI W X, FANG ZH, et al. Photovoltaic cell defect detection algorithm based on improved YOLOv7-tiny [J]. Computer Engineering and Applications, 2024, 60(15): 336-343.
- [8] SU B Y, CHEN H Y, ZHOU ZH. BAF-detector: An efficient CNN-based detector for photovoltaic cell defect detection [J]. IEEE Transactions on Industrial Electronics, 2021, 69(3): 3161-3171.
- [9] 汪方斌,李文豪.基于改进轻量化 U-Net 模型的光伏电池 EL 图像缺陷检测[J].电子测量技术,2024,47(5):102-111.
WANG F B, LI W H. Defect detection in EL images of photovoltaic cells based on improved lightweight U-Net model [J]. Electronic Measurement Technology, 2024, 47(5): 102-111.
- [10] TU X G, YUAN Z H, LIU B K, et al. An improved YOLOv5 for object detection in visible and thermal infrared images based on contrastive learning [J]. Frontiers in Physics, 2023, 11: 1193245.
- [11] 张冀,王文彬,余洋.基于 RFCARep-YOLOv8n 的光伏电池缺陷检测算法[J].计算机工程与应用,2025,61(3):131-143.
ZHANG J, WANG W B, YU Y, et al. Photovoltaic cell defect detection algorithm based on RFCARep-YOLOv8n [J]. Computer Engineering and Applications, 2025, 61(3): 131-143.
- [12] 慕晓冬,魏轩,曾昭菊.基于注意力残差网络的航天器测控系统故障诊断[J].仪器仪表学报,2022,43(9): 81-87.
MU X D, WEI X, ZENG ZH J, et al. Fault diagnosis of spacecraft telemetry, tracking and command system based on attention residual network [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 81-87.
- [13] 杨丽,邓靖威,段海龙,等.基于重参数化的光伏电池缺陷检测算法[J].电子测量技术,2025,48(5):184-192.
YANG L, DENG J W, DUAN H L, et al. Reparameterization-based defect detection algorithm for photovoltaic cells [J]. Electronic Measurement Technology, 2025, 48(5): 184-192.

- Technology, 2025, 48(5): 184-192.
- [14] 刘航,李明,刘志坚,等.基于轻量化改进 YOLOv8n 绝缘子自爆缺陷检测方法[J].电子测量与仪器学报,2025,39(1):57-69.
- LIU H, LI M, LIU ZH J, et al. Lightweight improved YOLOv8n-based defect detection method for insulator self-explosion [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39 (1): 57-69.
- [15] 刚帅,刘培胜,郭希旺.改进基于 YOLOv8n 的轻量化钢材表面缺陷检测算法[J].电子测量技术,2025,48(3):74-82.
- GANG SH, LIU P SH, GUO X W, et al. Lightweight improved YOLOv8n-based surface defect detection algorithm for steel materials[J]. Electronic Measurement Technology, 2025, 48(3): 74-82.
- [16] WEI H R, LIU X, XU SH CH, et al. DWRSeg: Rethinking efficient acquisition of multi-scale contextual information for real-time semantic segmentation [J]. ArXiv preprint arXiv:2212.01173, 2022.
- [17] CHEN X B, LIU CH, WANG SH, et al. LSI-YOLOv8: An improved rapid and high accuracy landslide identification model based on YOLOv8 from remote sensing images[J]. IEEE Access, 2024, 12: 97739-97751.
- [18] DING X H, ZHANG Y Y, GE Y X, et al. Unireplknet: A universal perception large-kernel convnet for audio video point cloud time-series and image recognition [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5513-5524.
- [19] ZHU X ZH, HU H, LIN S, et al. Deformable convnets v2: More deformable, better results [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308-9316.
- [20] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [21] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism[J]. ArXiv preprint arXiv:2301.10051, 2023.
- [22] 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.

作者简介

刘闯闯,硕士研究生,主要研究方向为光伏电池缺陷检测、深度学习。

E-mail:2447999350@qq.com

袁金丽,副教授,主要研究方向为医学图像处理。

E-mail:2005051@hebut.edu.cn

郑美曼,硕士研究生,主要研究方向医学图像分割算法研究、深度学习。

E-mail:1307927431@qq.com

吴晨曦,硕士研究生,主要研究方向为自动调制识别、深度学习。

E-mail:wcx202321902027@163.com

郭志涛(通信作者),教授,主要研究方向为物联网、智能传感器、智能优化算法。

E-mail:2002089@hebut.edu.cn