

唐钊,唐东峰,江拼,等. 基于改进 YOLOv8 的太阳能电池板缺陷检测[J].湖南科技大学学报(自然科学版),2025,40(4): 67-78. doi:10.13582/j.cnki.1672-9102.2025.04.008

TANG Z, TANG D F, JIANG P, et al. Solar Panel Defect Detection Based on Improved YOLOv8 [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2025, 40(4):67-78. doi:10.13582/j.cnki.1672-9102.2025.04.008

基于改进 YOLOv8 的太阳能电池板缺陷检测

唐钊,唐东峰*,江拼,陈鑫

(湖南科技大学 信息与电气工程学院,湖南 湘潭 411201)

摘要:太阳能电池板在光伏系统中的广泛应用,使其性能和可靠性的监控变得尤为重要.光照条件复杂以及背景干扰严重,使传统检测算法在太阳能电池板缺陷检测中的表现不佳.为此,基于 YOLOv8 算法提出了一种改进方法 YOLOv8-LZW,针对当前检测难点进行了优化,首先利用了 LNA-Conv 模块,结合平均池化和最大池化,能够高效提取多尺度特征,降低计算成本,提升检测的速度与精度.此外设计了新型探头 ZTDC-Detect,该探头通过任务动态对齐,有效地提升了目标特征的对齐能力,通过采用动态卷积机制,结合任务分解模块,分别优化了分类与边界框回归特征,显著增强了对目标和复杂背景下缺陷的检测能力;最后引入损失函数 $WIoU_v3$,该损失函数采用动态非单调聚焦机制进行锚框质量评估,同时引入一种智能的梯度增益分配策略,提高了边界框回归对复杂缺陷区域的预测精度,增强了模型在检测微小裂纹和模糊缺陷时的鲁棒性.在太阳能电池板缺陷数据集展现 YOLOv8-LZW 的优越性能,其 mAP@0.5 与计算量均优于原始 YOLOv8,充分满足了太阳能电池板进行高效、准确检测需求.

关键词:太阳能电池板;缺陷检测;任务分解;YOLOv8-LZW;损失函数

中图分类号:TP391.41

文献标志码:A

文章编号:1672-9102(2025)04-0067-12

Solar Panel Defect Detection Based on Improved YOLOv8

TANG Zhao, TANG Dongfeng, JIANG Pin, CHEN Xin

(School of Information and Electrical Engineering, Hunan University of Science and Technology, Xiangtan 411201, China)

Abstract: The wide application of solar panels in photovoltaic systems makes the monitoring of their performance and reliability particularly important. The performance of traditional detection algorithms in solar panel defect detection is poor due to complex lighting conditions and serious background interference. Therefore, this paper, based on YOLOv8 algorithm, proposes an improved method, i.e. YOLOv8-LZW, which is optimized for current detection difficulties. First, the LNA-Conv module, combined with average pooling and maximum pooling, can efficiently extract multi-scale features, reduce computing costs, and improve the speed and accuracy of detection. In addition, a new probe ZTDC-Detect is designed, which effectively improves the alignment ability of target features through dynamic alignment of tasks. The classification and boundary box regression features are optimized respectively, which significantly enhances the detection ability of defects in the target and complex background. Finally, $WIoU_v3$ is introduced to evaluate the quality of the anchor frame using a dynamic non-monotone focusing mechanism, and an intelligent gradient gain allocation strategy is introduced to improve the prediction accuracy of the complex defect region by boundary frame regression, and enhance the robustness of the model in detecting small cracks and fuzzy defects, and demonstrate the superior performance of YOLOv8-LZW on the solar panel

defect data set. Its mAP@0.5 and computational capacity are superior to the original YOLOv8, fully meeting the demand for efficient and accurate detection of solar panels.

Keywords: solar panel; defect detection; mode decomposition; YOLOv8-LZW; loss function

太阳能作为一种清洁、可再生的能源形式,在全球范围内得到广泛应用.太阳能电池板作为光伏系统核心组件^[1],其运行性能直接影响着整个系统的发电效率和经济效益.在长期使用过程中,太阳能电池板容易受到环境因素(如风沙、雨雪、温度变化)和内部制造缺陷(如微裂纹、焊接不良)的影响,产生一系列如裂纹、热斑、污渍和脱层等缺陷^[2].这些缺陷不仅会降低光伏系统的发电效率,还可能引发安全隐患^[3].因此,开发高效精准的太阳能电池板缺陷检测技术对保障光伏产业的健康发展具有重要意义.

深度学习在计算机视觉的应用经历了从基础模型到优化算法的发展过程,逐步实现了从初步探索到高精度、高效率检测的飞跃.在深度学习普及之前,主要使用传统机器学习方法,如支持向量机(Support Vector Machine, SVM)、随机森林(Random Forest, RF)等.这些方法不仅需要手动设计特征,而且在复杂场景下效果有限.随着深度学习的兴起,研究者开始尝试将卷积神经网络(Convolutional Neural Networks, CNN)应用于计算机视觉领域^[4].早期工作如基于浅层网络的研究,主要聚焦于缺陷分类任务.通过训练这些网络,能够实现对简单缺陷类型的初步分类.在此阶段的工作,通常仅关注分类任务,缺乏对缺陷的定位能力;且模型规模较小,检测精度和泛化能力有限.随着目标检测技术的发展,基于深度学习的检测模型如 Faster R-CNN(Faster Region-based Convolutional Neural Networks),YOLO(You Only Look Once),SSD(Single Shot MultiBox Detector)被广泛应用于目标定位和分类任务.这些模型为缺陷检测提供了新的解决方案:Faster R-CNN 作为两阶段检测模型的代表^[5],通过区域建议网络 RPN 生成候选区域,并在精细分类中表现出较高的准确性.一些研究利用 Faster R-CNN 进行缺陷检测取得了较好的效果.但对于微小缺陷以及复杂背景下的目标识别,仍存在较高误检和漏检率.郭建等^[6]设计的使用 BEGAN 生成对抗网络进行数据增强,在颈部网络中使用 BiFPN 双向特征金字塔网络,通过提取不同层次的特征信息以融合更多的缺陷特征,从而减少光伏组件复杂背景的干扰,提高检测性能,但是运用在小目标检测中效果不佳;LI 等^[7]通过引入新的结构和损失函数来提高检测效果,优化了特征表达能力,并有效地减少了模型参数,通过增强深层特征的表达,提升了模型对小目标缺陷的识别精度,不过其容易受到环境干扰;常光超等^[8]在 YOLOv8 网络中引入细粒化卷积模块以替代传统的卷积下采样,并且添加多头自注意力机制 MHSA,最后在头部增加一个小目标的检测层,使得改进后的模型在定位微小目标时具有更优越的精准性和检测能力,但其同样也受背景影响较大;冯庆贺等^[9]将深度神经网络模型中添加注意力机制,可以促进深度神经网络模型对重要信息和次要信息权重配置.全局注意力机制 GAM 作为一种重要的注意力机制,其主要用于保留通道和空间方面的信息以提升特征图之间全局信息交互,使得被集成网络模型具有更高的鲁棒性,不足点在于提升效果较差.

综上所述,深度学习在太阳能电池板缺陷检测方面有很好的应用前景,但目前对微小缺陷和环境干扰下的缺陷检测能力有待提高^[10].因此,需要一种既能提升检测精度,又能满足在环境干扰下表现稳定的算法.

1 YOLOv8 目标检测模型

YOLOv8 是目标检测领域的一款重要深度学习模型,延续了 YOLO 系列模型在实时性和检测精度方面的优势,并在结构设计与性能表现上实现了显著提升.该模型统一支持目标检测、实例分割和关键点检测任务,具备良好的通用性和适应性.YOLOv8n 作为其轻量化子版本,在资源受限环境中表现优异,适用于嵌入式和移动设备等对实时性要求较高的场景.模型整体结构包括主干网络 Backbone、颈部网络 Neck 及检测头 Head.其中,主干部分引入 YOLOv7 中的 ELAN 结构和 SPPF 模块^[11]增强特征表达能力;颈部采用 PANet 结构以实现多尺度特征融合;检测头则通过解耦设计有效地缓解分类与回归任务间的冲突,提升检测性能.尽管 YOLOv8 在速度与精度之间取得良好平衡,其在小目标检测方面仍存在优化空间,后续

可通过结构改进以进一步降低误检与漏检率,以满足特定应用需求.

2 改进的 YOLOv8 目标检测模型

2.1 改进的 YOLOv8 网络模型

针对在复杂场景下电池板检测精度不高、容易发生漏检及误检的情况,本文提出了一种基于 YOLOv8n 改进的太阳能电池板检测模型,该模型融合了高效卷积模块 LNA-Conv、新型探头 ZTDC-Detect 与损失函数 $WIoU_{v3}$,显著提升了模型检测的精确性.首先,使用高效卷积模块 LNA-Conv 代替传统卷积模块,LNA-Conv 结合平均池化和最大池化技术,能够高效提取多尺度特征的同时降低计算成本,提升了检测的速度与精度;其次,设计新型探头 ZTDC-Detect,相较于传统检测头,ZTDC-Detect 通过任务动态对齐探头有效提升了目标特征的对齐能力,同时采用动态卷积机制结合任务分解模块,优化了分类与边界框回归特征,显著增强了对小目标和复杂背景下的缺陷检测能力;最后,通过添加损失函数 $WIoU_{v3}$,引入区域重要性加权策略, $WIoU_{v3}$ 损失函数提高了边界框回归对复杂缺陷区域的预测精度,使模型在检测微小裂纹和模糊缺陷时效果更优.改进后的 YOLOv8-LZW 网络模型如图 1 所示.




图 1 YOLOv8-LZW 网络模型

2.2 LNA-Conv 卷积

在原本 YOLOv8 中,传统卷积在通过下采样时丢弃部分像素信息实现特征图尺寸的缩减.这种操作可能导致细小特征的丢失^[13],在低层特征中更加明显;在小目标检测任务中会造成目标信息不完整,从而影响定位和分类精度.

如图 2 所示,LNA-Conv 作为一个下采样模块,采用了多路径处理策略.引入平均池化 AvgPool2d 和最大池化 MaxPool2d,分别处理特征图的不同部分,从而增强特征提取效果^[14],减少细节特征的丢失.假设输入特征图为 x ,其形状为 (B, C_1, H, W) ,其中 B 是批量大小, C_1 是输入通道数, H 和 W 分别是高度和宽度.输入特征图首先进行全局平均池化,目的是对整体特征进行均衡化的下采样.输入 x 经过平均池化操作:

$$x_{\text{pool}} = \text{AvgPool2d}(x, \text{kernel_size} = 2, \text{stride} = 1, \text{padding} = 0). \quad (1)$$

输出 x_{pool} 的形状为 (B, C_1, H', W') ,其中 $H' = H-1, W' = W-1$.

之后将特征在通道维度上分为两部分 x_1 和 x_2 , x_1 的形状为 $(B, C_1/2, H', W')$, x_2 的形状为 $(B, C_1/2, H', W')$, 各自负责不同的特征处理任务. x_1 使用卷积处理, 该分支负责全局特征的提取. 输出 x_1' 的形状为 $(B, C_2/2, H'', W'')$.

$$x_1' = \text{Conv}(x_1, \text{kernel_size} = 3, \text{stride} = 2, \text{padding} = 1). \quad (2)$$

x_2 首先应用最大池化强化局部显著特征.

$$x_2' = \text{MaxPool2d}(x_2, \text{kernel_size} = 3, \text{stride} = 2, \text{padding} = 1). \quad (3)$$

输出 x_2' , 然后通过卷积层进行特征映射, 进一步提取高层特征, 最后在通道维度将 x_1 和 x_2 的输出进行拼接形成融合特征 y .

LNA-Conv 的多路径策略让分支结构提供了不同的特征处理方式, 增强了特征提取的多样性. 其中最大池化操作可以强化局部特征, 结合传统卷积和特征映射可以保留更多细节, 提升模型检测的精确性; LNA-Conv 模块设计简洁, 仅需使用基本卷积、池化和拼接操作, 计算量需求低.




图2 LNA-Conv 结构

2.3 ZTDC-Detect 探头

传统的 YOLOv8 检测头采用的是静态卷积操作, 缺乏对输入特征的动态适应能力, 限制了其在复杂或多样化场景下的表现; 此外, 由于分类与回归任务共用特征容易引发任务冲突, 尤其在小目标与密集目标检测中表现不佳; 同时传统检测头缺乏显式的特征对齐机制, 导致预测框与关键特征位置匹配度不足, 影响模型的泛化能力和检测精度^[15].

为克服上述问题, 本文创新性地提出一种新型检测头模块 ZTDC-Detect (图 3), 通过使用动态特征对齐与任务分解机制, 提升检测性能与精度. 该模块首先利用 Conv_GN 提取初步特征, 并通过多层 DEConv_GN 解卷积实现多尺度融合; 接着采用自适应平均池化 (不依赖固定的卷积核和步长, 是自动根据目标输出尺寸来适配任意大小的输入特征图) 提取全局特征, 并分支执行分类与回归任务; 之后融合特征进一步生成偏移量与掩码, 通过 DyDCNv2 动态卷积对回归特征进行空间对齐, 分类特征则经 CRCS 计算分类概率. 最终两类特征分别输入分类与定位分支, 实现精确预测.

ZTDC-Detect 创新性地使用多层动态卷积提升特征对齐精度, 引入全局特征增强小目标检测能力, 并采用任务解耦策略缓解任务冲突. 同时, 多尺度融合与参数共享机制兼顾表达能力与计算效率, 为复杂场景下的目标检测提供了有效解决方案.




图 3 ZTDC-Detect 检测头

2.3.1 Conv_GN 模块

传统的卷积层在训练过程中,当批量大小较小时,往往会面临梯度消失、梯度爆炸等问题,导致模型训练过程不稳定.为解决上述问题我们提出一种新型的归一化结构,如图 4 所示,相比于传统的归一化在卷积层基础上使用了 GN(Group Normalization)层^[16],GN 的核心思想是将输入特征图的通道分成若干组,并在每组内进行归一化.假设输入特征图为 x ,其形状为 (N, C, H, W) ,其中 N 是批量大小, C 是通道数, H 和 W 是高度和宽度.组归一化的计算公式如下:

$$y = \frac{x - \mu_g}{\sqrt{\sigma_g^2 + \epsilon}} \gamma + \beta; \quad (4)$$

$$\mu_g = \frac{1}{C/GHW} \sum_{i \in \text{group}} \sum_{h=1}^H \sum_{w=1}^W x_{i,h,w}; \quad (5)$$

$$\sigma_g^2 = \frac{1}{C/GHW} \sum_{i \in \text{group}} \sum_{h=1}^H \sum_{w=1}^W (x_{i,h,w} - \mu_g)^2. \quad (6)$$

式中: μ_g 为每组特征的均值; σ_g^2 为每组特征的方差,两者都是在组内通道计算所得; ϵ 为一个很小的常数,用于数值稳定性; γ, β 为可学习的缩放和偏移参数.

GN 通过将特征通道划分为多个组并在组内进行归一化,避免了对整个批量的依赖,克服了 Batch Normalization 在小批量和非独立同分布数据下的性能限制.Conv_GN 将标准卷积与 GN 结合,在深层网络结构中展现出更高的稳定性与适应性.GN 在卷积后对特征进行标准化,有效提升了模型的训练稳定性与泛化能力,尤其适用于检测、分割等任务.




图 4 归一化原理

2.3.2 DEConv_GN 模块

DEConv_GN 是对 DEConv 进行归一化处理,如图 5 所示,DEConv 首先获取 Conv2d_ad 至 Conv2d_dd 的权重与偏置^[17],并将其与 Conv2d 的权重和偏置合并;再将融合后的权重和偏置对输入特征图进行卷积计算,得到输出特征图,最后对卷积输出特征图归一化.Conv2d_ad 至 Conv2d_dd 的功能如下所示:

Conv2d_ad:局部特征自适应调整,增强特征表达能力.

Conv2d_bd:加强径向信息提取,适合处理辐射状或中心化结构.

Conv2d_cd:提取水平边缘或水平纹理特征.

Conv2d_dd:提取垂直边缘或垂直纹理特征.

其中各卷积操作的核心公式为

$$y(p) = \sum_{k=1}^K \omega_k x(p + p_k) + b. \quad (7)$$

式中: x 为输入特征图; ω_k 为卷积核的权重; p_k 为卷积核的采样位置; b 为偏置; $y(p)$ 为输出特征图在位置 p 的值.

DEConv 卷积与 GN 相结合,在有效地提升了模型精确性的同时还显著降低了模型计算量,有效地提升了模型的综合性能.




图 5 DEConv_GN 结构

2.3.3 Task 模块

如图 6 所示,Task 通过将特征图分解为适用于不同任务,比如分类和回归的特征表示,优化了模型在多任务学习中的性能.这种结构不仅提升了模型对不同任务的表达能力,而且引入全局精细化的特征分解,进一步提高了模型的检测精度.




图 6 Task 结构

2.3.4 DyDCNv2 模块

DyDCNv2^[18] 是一个结合可调变形卷积和归一化层的卷积模块,主要用于目标检测中的特征提取部分.如图 7 所示,首先进行可变形卷积操作,处理输入偏移量和掩码得到卷积结果,再对卷积结果进行归一化处理.DyDCNv2 通过学习特征图中每个位置的偏移量和掩码来调整回归特征的位置,提高目标检测任务中边界框回归的精度.这种动态对齐机制使得模型能够更好地处理目标的位置变化、尺度变换等问题.

传统的卷积操作是在固定的规则网格上进行采样,而可变形卷积通过学习偏移量,使得采样位置可以动态调整.输出特征图的位置 p 的值 $y(p)$ 可以表示为

$$y(p) = \sum_{k=1}^K \omega_k x(p + p_k). \quad (8)$$

式中: x 为输入特征图; ω_k 为卷积核的权重; p_k 为卷积核的固定采样位置.对于可变形卷积,采样位置 p_k 被调整为 $p_k + \Delta p_k$,其中 Δp_k 是学习到的偏移量.此外,DCNv2 还引入了调制因子 m_k .因此,可变形卷积的输出为

$$y(p) = \sum_{k=1}^K \omega_k x(p + p_k + \Delta p_k) m_k. \quad (9)$$




图 7 DyDCNv2 结构

2.3.5 CRCS 模块

如图 8 所示,CRCS 由 2 个卷积和 2 个激活函数构成,目的是生成分类置信度特征图.输入的特征图通过 2 个卷积层(1 个 1×1 卷积降维和 1 个 3×3 卷积提取局部特征),使用 relu 激活函数引入非线性,并通过 sigmoid 激活函数将输入特征图转换为一个单通道的概率图,每个像素的值表示该位置属于目标类别的概率.在保留了输入特征图的空间信息的同时,实现了从特征提取到概率映射的完整过程.




图 8 CRCS 结构

2.4 WIOU 损失函数

目标检测的检测性能在很大程度上依赖于边界框损失函数的设计.现有方法多关注增强损失函数对高质量样本的拟合能力,忽视了训练集中低质量样本的干扰作用.针对该问题,本文使用了 $WIoU_{v3}$ 边界框损失函数.该方法使用动态非单调聚焦机制,以“离群度”替代传统 IoU 作为锚框质量评估指标,结合优化的梯度分配策略^[19],抑制了高质量锚框间的过度竞争,降低了低质量样本对训练过程的负面影响. $WIoU_{v3}$ 能更有效地聚焦于中等质量样本,显著提升检测器的整体性能. $WIoU_{v3}$ 的定义为

$$L_{WIoU_{v3}} = \frac{\beta}{\delta \alpha^{\beta-\delta}} R_{WIoU} L_{IoU}; \quad (10)$$

$$R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right); \quad (11)$$

$$L_{IoU} = 1 - IoU. \quad (12)$$

式中: $(x, y), (x_{gt}, y_{gt})$ 为锚框与目标框的中心点坐标; W_g, H_g 为最小包围框的尺寸; R_{WIoU} 用于衡量预测框与真实框的匹配程度; L_{IoU} 用于评估两者的重叠程度; 参数 α 和 δ 通常设定为 1.9 和 3.0^[20]. 离群度 β 的计算公式为

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty). \quad (13)$$

式中: L_{IoU}^* 为单调聚焦系数的梯度增益, 其定义与 L_{IoU} 相同, 而 * 表示在训练过程中会根据每个目标检测的具体情况动态计算和调整; $\overline{L_{IoU}}$ 为动量 m 的滑动平均值, 用于自动调节增益. 离群度 β 与锚框质量呈现负相关, 离群度越大, 锚框质量越低. 这种动态划分锚框质量的方法能够使模型以动态非单调的方式聚焦于普通样本, 从而提升模型的泛化能力和整体性能.

3 实验结果与分析

3.1 实验环境搭建

实验环境设置如表 1 所示.

表 1 实验配置

配置环境	配置名称
操作系统	Windows11
CPU	12th Gen Intel(R) Core(TM) i5-12400F
GPU	NVIDIA GeForce RTX 4060(8G)
编译器	Python3.8.19
深度学习框架	1.3.0
加速模块	CUDA11.7

实验参数设置如表 2 所示.

表 2 实验参数

参数	含义	数值
Epochs	迭代轮数	300
Patience	早停触发轮数	50
Batch_size	批量数	32
Images_size	图像尺度	640×640
lr	初始学习率	0.01
Momentum	学习率动量	0.937

3.2 实验数据

实验数据集来源于 Kaggle 与网络上的太阳能电池板缺陷数据集, 这些图片的光照、距离、角度不同, 背景较为复杂, 使实验场景更具挑战性. 图片数据使用 XML 格式进行标注(图 9), 标注目标包含清洁(clean)、裂纹(cracked)、灰尘(dust)这 3 种, 共有 4 482 张图片. 这些样本展示了太阳能电池板在不同视角和场景下的多样性和复杂特征. 通过构建这一综合性的数据集, 可以更全面地模拟真实场景, 为本文的实验提供丰富的测试条件, 从而有效提升模型的性能与泛化能力.




图 9 部分数据集图片

3.3 评价指标

为了评估算法的性能,本文选择平均精度(mAP)、召回率(R)、精确率(P)、模型参数(Param)以及计算量(GFLOPs)等5个指标作为检测性能的评价指标。

R 表示模型在所有正类样本中成功检测出的正类样本比例.高召回率意味着模型能够全面捕捉正类目标,漏检的情况较少.对于需要更高覆盖率的场景,召回率尤为关键.计算公式为

$$R = \frac{TP}{TP + FN}. \quad (14)$$

P 表示被预测为正类样本中实际为正类样本的比例,高精确率表明模型的误检情况较少,预测结果更加可靠.这在误报成本高的场景中具有重要意义.计算公式为

$$P = \frac{TP}{TP + FP}. \quad (15)$$

mAP 是多类目标检测任务的综合评价指标,通过计算每个类别的精确率 P 和召回率 R 的积分来评估模型性能.mAP@0.5 表示当 IoU 阈值为 0.5 的不同类别的平均精度.反映了模型在所有类别中的平均检测能力,是衡量目标检测模型整体有效性的重要指标.计算公式为

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i; \quad (16)$$

$$AP = \int_0^1 P(R) dR. \quad (17)$$

式中: TP 为模型正确地将正类样本预测为正类的样本数;FP 为模型错误地将负类样本预测为正类的样本数;FN 指的是模型错误地将正类样本预测为负类的样本数。

Param 表示模型中所有可学习参数的总数,通常以百万(M)参数计量,参数越大,模型训练变难、容易过拟合以及部署成本更高;GFLOPs(Giga Floating-point Operations Per second)表示模型在一次前向推理中所需的浮点运算次数,GFLOPs 越高,说明模型计算越复杂,推理耗时越长。

3.4 消融实验

为了验证本文提出的改进模型的有效性,以 YOLOv8n 模型为基础,分别添加 LNA-Conv,ZTDC-Detect,WIoU_{v3}这3种改进方法进行实验分析如表3所示,以对比每个改进方法的作用。

表3 消融实验结果分析

LNA-Conv	ZTDC-Detect	WIoU _{v3}	mAP@0.5	R	P	Params/M	GFLOPs
			0.780	0.751	0.813	3.0	8.1
✓			0.792	0.755	0.835	2.6	7.4
	✓		0.807	0.749	0.849	2.5	7.1
		✓	0.796	0.731	0.842	3.0	8.1
✓	✓		0.817	0.771	0.824	2.1	6.4
	✓	✓	0.812	0.775	0.850	2.5	7.1
✓		✓	0.811	0.795	0.805	2.6	7.4
✓	✓	✓	0.822	0.792	0.856	2.1	6.4

“✓”表示该改进方法的引入.根据表3的结果,引入 LNA-Conv 模块后,mAP@0.5 提高了 1.2%, R 提高了 0.4%, P 提高了 2.2%.这表明 LNA-Conv 模块有效增强了模型的精确率,尤其是在减少误检方面表现突出.虽然召回率略有提升,但提高的幅度较小,表明该模块对精确率的提升作用更为明显.LNA-Conv 模块可能通过更细致的卷积操作来增强模型对关键特征的捕捉能力,从而使得模型对目标的定位更为准确.引入 ZTDC-Detect 模块后,mAP@0.5 提高了 2.7%, P 提高了 3.6%.ZTDC-Detect 模块显著提升了模型的精确率,尤其是在减少误检方面表现优异.mAP@0.5 和 P 的显著提高表明,ZTDC-Detect 模块在提高模型对目标的准确检测方面发挥了重要作用,可能通过优化特征传递和自适应信息选择来减少冗余信息,从而提高精度.引入 WIoU_{v3} 损失函数后,mAP@0.5 提高了 1.6%, P 提高了 2.9%.WIoU_{v3} 损失函数的引入提升了精

确率和 $mAP@0.5$, 表明它在减少误检和提高目标检测的总体效果方面起到了重要作用. 总体来看, $WIoU_{v3}$ 通过优化损失函数和关注关键目标区域, 提高了模型的准确度和精确性.

最终改进的算法与 YOLOv8n 基础模型相比, $mAP@0.5$ 提升了 4.2%, R 提升了 4.1%, P 提升了 4.3%, 模型参数减少接近 1/3, 同时计算量减少了 1.7GFLOPs. 从实验结果可以得出 YOLOv8-LZW 对比 YOLOv8n 在检测精度有了较为明显的提升的同时, 计算负担也有显著降低.

3.5 模型对比实验

为了评估 YOLOv8-LZW 在太阳能电池板缺陷检测上的效果, 将 YOLOv8-LZW 与 RT-DETR^[21]、YOLOv5^[22]、YOLOv11^[23] 这些目前主流的目标检测算法以及最新提出的 YOLOv11 进行比较, 在数据增强策略、训练集与测试集划分方式、实验参数设定以及评价指标方面, 均与前述实验保持一致, 以保证对比的公平性与一致性. 实验结果如表 4 与图 10 所示.

表 4 对比实验结果分析

Model	$mAP@0.5$	R	P	Params/M	GFLOPs
Faster R-CNN	0.753	0.737	0.792	24.2	114.9
RT-DETR	0.756	0.720	0.837	28.5	100.6
SSD	0.674	0.657	0.724	7.8	28.4
YOLOv5	0.810	0.745	0.841	2.5	7.2
YOLOv6	0.791	0.739	0.834	4.2	11.9
YOLOv10	0.791	0.742	0.835	2.7	8.4
YOLOv11	0.793	0.722	0.835	2.6	6.4
YOLOv8-LZW	0.822	0.792	0.856	2.1	6.4




图 10 $mAP@50$ 对比实验结果

将本文所设计的 YOLOv8-LZW 与 Faster R-CNN, RT-DETR, SSD, YOLOv5, YOLOv6, YOLOv10, YOLOv11 这 6 个先进算法相比较. 从实验结果可以得出: 所设计的 YOLOv8-LZW 在 $mAP@0.5$, R , P , Param 以及 GFLOPs 指标上均表现优异. $mAP@0.5$ 值分别提高 6.9%, 6.6%, 14.8%, 1.2%, 3.1%, 3.1%, 2.9%, R 值分别提高了 5.5%, 7.2%, 13.5%, 4.7%, 5.3%, 5.0%, 7.0%, P 值分别提高了 6.4%, 1.9%, 13.2%, 1.5%, 2.2%, 2.1%, 2.1%. 模型参数与计算量也有了显著下降. 综上所述, 本文所设计的算法在具有较高精度的同时减小了计算负担, 可以满足太阳能电池板缺陷的检测需求.

为了验证 YOLOv8-LZW 模型的泛化性, 本文在 Gitcode 风机叶片缺陷数据集上进行了实验. 该数据集包含了 3 种缺陷类型: injure (损伤)、corrosion (腐蚀)、attach (附着物). 数据集的增强、划分、实验参数设置和评价指标与之前保持一致. 实验结果如表 5 所示, YOLOv8-LZW 算法在 Gitcode 风机叶片缺陷数据集的 $mAP@0.5$ 达到了 72.8%, 比基准模型提高了 5.7%. 结果表明 YOLOv8-LZW 算法在目标检测任务中表现出

更强的性能.此外,该算法在参数量和计算量方面也展现了显著的优势,进一步验证了其在不同数据集上的优越泛化能力.

表 5 泛化性实验分析

Model	mAP@ 0.5	<i>R</i>	<i>P</i>	Params/M	GFLOPs
YOLOv8n	0.671	0.617	0.669	3.0	8.1
YOLOv8-LZW	0.728	0.705	0.674	2.1	6.4

3.6 可视化分析

为便于直观呈现本文算法相较于其他算法的改进效果,选取了部分具有代表性的太阳能电池板图像进行可视化分析如图 11 所示,可以看出在太阳能电池板缺陷检测任务中,改进后的算法在不同复杂背景下对目标缺陷的识别效果显著提高.




图 11 可视化对比结果

4 结论

1) 提出了一种改进的 YOLOv8-LZW 模型用于太阳能电池板缺陷检测任务.实验结果表明:该模型将精度提升到 82.2%的同时,将计算参数量减少了 1.7M,与 YOLOv8n 及其他经典检测算法相比,本模型在检测精度、计算量方面均展现出明显优势.

2) 模型为复杂环境下的太阳能电池板缺陷检测提供了一种高效、轻量化的解决思路.然而,在极端光照、复杂背景及极小缺陷检测条件下,模型性能仍存在一定局限.考虑到模型在实际应用中可能面临的资源受限问题,未来研究将进一步探索更轻量化的网络结构以及与边缘计算设备的适配,同时扩充多样化的缺陷样本数据集,以提升模型的泛化能力和检测精度,推动太阳能电池板智能缺陷检测的深入发展.

参考文献:

[1] 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.

[2] 陈光耀,陈田,高学海,等.跨层融合的轻量化太阳能电池片缺陷分割方法[J].电子测量技术,2024,47(24):1-11.

[3] DHIMISH M, D' ALESSANDRO V, DALIENTO S. Investigating the impact of cracks on solar cells performance: analysis based on nonuniform and uniform crack distributions[J]. IEEE Transactions on Industrial Informatics, 2022, 18(3):1684-1693.

[4] AKRAM M W, LI G Q, JIN Y, et al. CNN based automatic detection of photovoltaic cell defects in electroluminescence images[J]. Energy, 2019, 189: 116319.

[5] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV). IEEE, 2015: 1440-1448.

[6] 郭建,黄颖驹.基于改进 YOLOv5 的光伏太阳能电池片缺陷检测[J].组合机床与自动化加工技术,2024(11):104-109.

- [7] LI Y C, LIU M, LI Z, et al. CSSAdet: real-time end-to-end small object detection for power transmission line inspection[J]. IEEE Transactions on Power Delivery, 2023, 38(6): 4432–4442.
- [8] 常光超, 任传成. 基于改进 YOLOv8 的太阳能电池板表面缺陷检测算法[J]. 德州学院学报, 2024, 40(4): 39–43.
- [9] 冯庆贺, 江铭凯, 郝巧红, 等. 一种改进的 YOLOv8 太阳能电池板缺陷识别方法[J]. 广西电力, 2024(4): 46–52.
- [10] REDDY K V B, MURALI A, P A R, et al. Analysis of a grid-connected photovoltaic/wind hybrid power system's performance[C]//2025 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI). IEEE, 2025: 1–6.
- [11] WANG C Y, BOCHKOVSKIY A, LIAO H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2023: 7464–7475.
- [12] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 8759–8768.
- [13] 冀天阳, 赵强, 余文涛, 等. 基于增强小目标特征提取的 PCB 板缺陷检测模型[J]. 仪器技术与传感器, 2023(04): 87–92.
- [14] LI J Y, CHEN Y J, NIU M Q, et al. ADS-YOLO: a multi-scale feature extraction remote sensing image object detection algorithm based on dilated residuals[J]. IEEE Access, 2025, 13: 26225–26234.
- [15] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 4510–4520.
- [16] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[M]//Computer Vision – ECCV 2014. Cham: Springer International Publishing, 2014: 818–833.
- [17] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 1577–1586.
- [18] FENG C J, ZHONG Y J, GAO Y, et al. TOOD: task-aligned one-stage object detection[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2021: 3490–3499.
- [19] SONG Z F, ZHANG Y, ABU EBAYYEH A A R M. EDNet: edge-optimized small target detection in UAV imagery-faster context attention, better feature fusion, and hardware acceleration[C]//2024 IEEE Smart World Congress (SWC). IEEE, 2024: 829–838.
- [20] CHEN P W, LYU W T, GUO Q, et al. EMS-net: efficient multiscale perceptual enhancement tiny object detector for remote sensing images[J]. IEEE Geoscience and Remote Sensing Letters, 2025, 22: 6007805.
- [21] WANG Z X, LEI X M, ZHOU S S. Traffic sign detection based on lightweight RT-DETR[C]//2024 IEEE 2nd International Conference on Sensors, Electronics and Computer Engineering (ICSECE). IEEE, 2024: 1593–1597.
- [22] ZHANG X P, FAN H H, ZHU H J, et al. Improvement of YOLOV5 model based on the structure of multiscale domain adaptive network for crowdscape[C]//2021 IEEE 7th International Conference on Cloud Computing and Intelligent Systems (CCIS). IEEE, 2021: 171–175.
- [23] ZHANG Y, ZHAO H Y, LI X D, et al. MERS-net: a lightweight and efficient remote sensing image object detector[J]. IEEE Geoscience and Remote Sensing Letters, 2025, 22: 6009005.