

基于改进 YOLOv8n 的光伏电池缺陷检测算法

王 涛,黎远松,石 睿,侯宪庆

四川轻化工大学 计算机科学与工程学院,四川 宜宾 644000

摘 要:目的 在光伏电池电致发光(Electroluminescence, EL)材料生产过程中,存在背景复杂、缺陷尺度差别大、缺陷类别不平衡等问题,导致漏检、误检的情况。针对此类问题,提出一种基于改进 YOLOv8n 的光伏电池缺陷检测算法。方法 首先,在改进 YOLOv8n 的主干部分,将 C2f 模块替换为 C2f-Faster 模块,最大程度降低模型参数数量的同时,提升了模型的检测速度和特征融合能力;其次,在颈部引入可变卷积,增大局部感受野,进而精确定位缺陷,降低识别误差;最后,引入 WIoU(Wise Intersection over Union)损失函数,替换原模型的 CIoU(Compleat Intersection over Union)损失函数,改善数据集标签不平衡的问题,提高模型对小目标缺陷的检测性能。结果 改进后的 YOLOv8n 算法在实验数据集上 mAP@0.5 达到 93.2%,检测速度达到 110 FPS,计算量仅为 6.7 GFLOPs;该算法相较于 YOLOv8n 基准算法,mAP@0.5 提升了 2.2%,参数数量下降 13.3%,计算量下降 17.2%。结论 通过消融实验并与主流目标检测模型进行对比证明了改进模型的有效性,改进后的模型在轻量化的同时又提升了模型的准确率,且具有实时性,相较于其他算法具有一定优势,满足工业部署要求。

关键词:缺陷检测;深度学习;YOLOv8n;WIoU

中图分类号:TP391.41;TP183;TM914.4 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2026.0004.006

Defect Detection Algorithm for Photovoltaic Cells Based on Improved YOLOv8n

WANG Tao, LI Yuansong, SHI Rui, HOU Xianqing

School of Computer Science and Engineering, Sichuan University of Science & Engineering, Yibin 644000, Sichuan, China

Abstract: Objective In the production process of electroluminescence (EL) materials for photovoltaic cells, there are problems such as complex background, large difference in defect scale, and imbalance of defect categories, which lead to missed and false detections in defect detection. To address these problems, a photovoltaic cell defect detection algorithm based on an improved YOLOv8n is proposed. **Methods** Firstly, the backbone of YOLOv8n was improved by replacing the C2f module with the C2f-Faster module. This change significantly reduced the number of model parameters while enhancing the model's detection speed and feature fusion capability. Secondly, deformable convolution was introduced in the neck to increase the local receptive field, thereby precisely locating defects and reducing recognition errors. Finally, the wise intersection over union (WIoU) loss function was introduced to replace the complete intersection over union (CIoU) loss function of the original model. This change addressed the issue of label imbalance in the dataset and improved the model's performance in detecting small-target defects. **Results** The improved YOLOv8n algorithm achieved an mAP@0.5 of 93.2% on the experimental dataset, with a detection speed of 110 FPS and a computational load of only 6.7 GFLOPs. Compared with the YOLOv8n benchmark algorithm, the proposed method improved mAP@0.5 by 2.2%,

收稿日期:2024-05-14 **修回日期:**2024-09-25 **文章编号:**1672-058X(2026)04-0042-10

基金项目:国家自然科学基金项目资助(42374227)。

作者简介:王涛(2000—),男,河南信阳人,硕士研究生,从事目标检测与深度学习研究。

通信作者:黎远松(1970—),男,四川自贡人,教授,从事信息安全与深度学习研究。Email:yuansongli@suse.edu.cn。

引用格式:王涛,黎远松,石睿,等.基于改进 YOLOv8n 的光伏电池缺陷检测算法[J].重庆工商大学学报(自然科学版),2026,43(4):42-51.

Wang Tao, Li Yuansong, Shi Rui, et al. Defect detection algorithm for photovoltaic cells based on improved YOLOv8n[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(4): 42-51.

reduced the number of parameters by 13.3%, and decreased computational load by 17.2%. **Conclusion** Ablation experiments and comparisons with mainstream object detection models demonstrate the effectiveness of the improved model. The proposed model achieves higher accuracy while maintaining a lightweight structure and real-time performance. It exhibits clear advantages over other methods and meets the requirements for industrial deployment.

Keywords: defect detection; deep learning; YOLOv8n; WIoU

随着“碳达峰”和“碳中和”理念的提出,光伏能源成为发展可持续能源的首选。光伏电池具有无污染、易回收、易再生的特点,被广泛应用各个行业。随着光伏产业的不断扩大,光伏电池在生产过程中出现的裂纹、粗线、断栅等缺陷问题日益严重,这些缺陷不仅会导致设备故障、电源短路,还可能威胁到财产安全和人身安全。因此,有效检测光伏电池生产缺陷,保证光伏电池的生产质量变得十分重要。

传统的光伏电池缺陷检测方法有基于物理特性的方法和基于图像的方法。基于物理特性的缺陷检测方法主要是通过声波、共振、施加电流等来检测光伏电池片在生产过程中的一些物理特性,并据此判断光伏电池是否有缺陷。这些方法需要与电池片进行直接接触,可能会因为工人的操作不当对电池片产生二次伤害。基于图像的缺陷检测方法是利用多种成像方式来获得光伏电池片的图像信息,常见的成像方式有可见光红外热成像、电致发光成像、光致发光成像等。通过多步骤处理,对获取图像的颜色、亮度等特征进行全面分析,进而确定光伏电池片内是否存在缺陷。这些方法虽然避免了与光伏电池的直接接触,但仍存在检测效率低,生产成本高的问题。

目前,随着计算机视觉领域的不断发展,越来越多的学者开始使用深度学习方法来进行光伏电池缺陷识别的研究。常见的深度学习算法主要有两类,一类是以 RCNN 和 Faster-RCNN 为代表的两阶段目标检测,另一类是以 YOLO 系列和 SSD 为代表的一阶段目标检测算法。在两阶段检测算法方面,伊欣同等^[1]提出一种基于 Faster-RCNN 的残差通道注意力算法,能够有效检测光伏电池内部缺陷;Ge 等^[2]构建了一个称为混合模糊卷积神经网络的算法(HFCNN),以解决光伏电池数据集的不确定性,以更少的参数提高精度。但两阶段目标检测算法普遍存在检测速度较慢的问题。在一阶段目标检测算法方面,唐政等^[3]通过对 YOLOv4 目标检测算法进行改进,将原始模型中的主干网络替换为 DenseNet-121 网络,利用 DenseNet-121 网络实现特征图像信息的密集连接,从而有效提高检测的准确性和速度,但模型复杂度高,不适用于工业部署;Lu 等^[4]提出一种优化的 YOLOv5 模型,该模型结合数据

增强方式,通过引入 CA(Coordinate Attention)注意力机制,提高模型的特征提取能力,最后将检测头替换成解耦头,以提高模型的检测精度,但模型的参数量较大,推理速度较慢;彭兴辉等^[5]提出一种基于数据增强的缺陷研究方法,使用生成对抗网络 GAN(Generative Adversarial Networks)解决光伏电池数据集不足造成的检测精度低的问题,但并未解决检测模型本身识别率低的问题;周颖等^[6]提出一种基于 GauGAN 的数据增强方式,有效解决了裂纹缺陷在数据集中存在的标签不平衡问题,但对其他缺陷的适用性不强;徐威等^[7]提出一种基于改进 YOLOv7-tiny 的光伏电池缺陷检测算法,将 GSConv 中的 DW(DepthWise)卷积替换为 Partial 卷积,降低了模型内存访问量并提升了检测速度,通过引入解耦全连接注意,在轻量化的同时提升了模型的检测能力,但轻量化后的模型体积仍然较大;Cao 等^[8]将 DW 卷积应用于 YOLOv8 骨干网络,并将双向特征金字塔网络添加到架构中,有效提升了精度,减少了模型体积,但是检测模型的时间复杂度较高。

除以上两种检测方法外,Xie 等^[9]在 Swin Transformer 网络基础上进行改进,提出一种新型 Transformer 网络,用于高效检测光伏电池板的缺陷,使用基于跨窗口的多头自注意力增强全局语义特征的提取,利用特征聚合模块融合多尺度特征,充分利用每个层级的特征信息,实现较高的分类性能,但检测速度仍有待提升。

综上所述,以往研究的方法中普遍存在检测精度、模型复杂度、检测速度不能兼顾的问题。针对这些问题,本文提出一种基于改进 YOLOv8n 的光伏电池缺陷检测算法。该方法通过目标检测算法识别光伏电池生产过程中产生的裂纹、黑芯、断栅、粗线等缺陷,在轻量化模型的同时提升了模型的检测精度,保持模型的检测速度。新算法为提高光伏电池的生产质量,实现未来光伏电池的大面积推广提供了有效的保障。

1 YOLOv8 网络构建及其改进

1.1 YOLOv8 算法

YOLO^[10](You Only Look Once)作为实时目标检测算法的代表经过不断更新迭代,目前已经发展到 YOLOv10。YOLOv8 是 Ultralytics 公司推出的 YOLO

的主流版本^[11],是一种由输入部分、主干部分、颈部网络和输出部分组成的快速单阶段目标检测方法。输入端对输入图像执行拼接、数据增强、自适应锚点计算和自适应灰度填充。主干网络(BackBone)模块和颈部网络(Neck)模块构成了 YOLOv8 网络的中心结构。通过多个 Conv 模块和 C2f 模块对输入图像的不同特征尺度进行信息提取。YOLOv8 将 YOLOv5 中 PAN-FPN(Path Aggregation Network with Feature Pyramid

Network)上采样阶段中的卷积结构删除,同时也将 C3 模块替换为 C2f 模块,在轻量化网络结构的同时获取了更多可用信息;SPPF(Spatial Pyramid Pooling Fast)模块对输出的特征图进行处理,它采用不同内核大小的池化对特征图进行组合,然后将结果传递给颈部层。YOLOv8 包含 n、s、l、m、x 模型,为了考虑企业部署的实际需求,本文选择 n 模型。YOLOv8n 算法的结构如图 1 所示。




图 1 YOLOv8n 结构图

Fig. 1 Structure of the YOLOv8n network

1.2 C2f-Faster 模块

在原始 YOLOv8n 主干网络中,C2f 模块由标准卷积和多个瓶颈(Bottleneck)模块组成^[12],因此造成原模型复杂度高,推理速度慢,不适用于光伏电池的缺陷检测任务。为了最大程度减少计算冗余并优化主干部分的参数量,本文使用 FasterBlock^[13]模块替换 C2f 模块中的 Bottleneck 模块,以降低模型的参数量和计算复杂度。

FasterBlock 模块是基于部分卷积(Partial Convolution, PConv)^[14]模块和传统分层 Transformer^[15]思想改进而来的。与普通卷积相比,PConv 只会对部分输入通道提取空间特征,而不对其他通道进行操作。具体来说,对于连续或常规的内存访问,PConv 会选择前面或后面一定数量的连续通道作为整个特征映射的代表进行计算,保持其余通道不变,在特征提取过后,再将两部分通道拼接。Conv 图 2(a)和 PConv 图 2(b)的结构如下所示。




图 2 Conv 和 PConv 结构图

Fig. 2 Structures of Conv and PConv

在输入与输出通道具有相同数量的情况下,相较于标准卷积,PConv 具有更小的计算量,其浮点运算量较少,浮点运算量 C_p 为

$$C_p = h \times w \times k^2 \times c_p^2 \quad (1)$$

同时 PConv 具有更小的内存访问量 V , 通过减小内存访问量从而提升模型的计算速率。内存访问量的计算公式如下:

$$V = h \times w \times 2c_p^2 + k^2 \times c_p \approx h \times w \times 2c_p^2 \quad (2)$$

当卷积操作的通道数为 $1/4$ 时, PConv 的计算量仅为普通卷积的 $1/16$, 内存访问量仅为常规卷积的 $1/4$ 。其中, h 为输入张量的高, w 为输入张量的宽, k 为过滤器尺寸, c_p 为空间特征提取的通道数。

FasterBlock 模块通过将 PConv 与普通 Conv 结合, 仅在中间层放置批量归一化 BN (Batch Normalization) 和线性整流函数 RELU (Rectified Linear Unit), 在保持特征多样性的同时实现更低的延迟。FasterBlock 模块结构如图 3 所示。




图 3 FasterBlock 模块结构图

Fig. 3 Structure of the FasterBlock module

由于传统的 Bottleneck 模块之间存在大量的跳层连接和额外的分割 (Split) 操作, 导致网络结构复杂, 计算量大。为了解决这个问题, 本文对原 C2f 网络进行改进: 去除原 C2f 网络中的 Split 操作并删除 Bottleneck 模块中多余的跳层连接, 将改进后的 C2f 网络与 FasterBlock 模块进行融合, 构建新的 C2f-Faster 模块。相对于原始的 C2f 模块, 改进后的 C2f 模块在不损失检测精度的前提下, 实现了检测速度和计算复杂度的优化。C2f-Faster 模块的结构如图 4 所示。




图 4 C2f-Faster 结构图

Fig. 4 Structure of the C2f-Faster module

1.3 C2f-DCNv2 模块

由于光伏电池具有复杂的缺陷特征, 因此在提取特征时使用普通卷积会导致一系列问题。引入可变形卷积 DCN (Deformable Convolution) [16] 网络可以捕捉到有效的细粒度细节, 尤其是在面对大面积裂纹时, 可变卷积可以进一步扩大感受野, 进而精确地定位缺陷, 降低识别误差。

DCN 模块由可变卷积层、批量归一化以及 Hardswish 激活函数构成。图 5 是普通卷积和可变形卷积的采样方式: 图 5(a) 表示常规的 3×3 卷积, 而图 5(b)、图 5(c)、图 5(d) 展示了通过添加偏移量后转换成的可变形卷积核, 蓝色点代表新增的卷积采样位置, 箭头表示偏移方向。




图 5 普通卷积和可变形卷积采样方式

Fig. 5 Sampling methods of standard convolution and deformable convolution

设 x 为输入特征图, y 为输出特征图, p_0 代表输出特征图的当前位置。对于一个普通的 3×3 卷积, 要输出 $y(p_0)$, 要在 x 上采样 9 个位置, 这 9 个位置是由中心点 $x(p_0)$ 向四周均匀扩散得到的, 其中扩散位置表示为 $R = \{(-1, 1), (-1, 0), \dots, (0, 1), (1, 1)\}$ 。 $y(p_0)$ 的表达方式如下:

$$y(p_0) = \sum_{k=1}^K w_k \cdot x(p + p_k) \quad (3)$$

其中, w 是卷积核, p_k 是卷积核的位置, k 代表采样点的位置, K 代表采样点总量。可变卷积并没有改变原卷积的计算操作, 而是在原卷积操作的基础上引入了一种新的可学习参数 Δp_k 。对于输出 $y(p_0)$, 依然要从中心位 $x(p_0)$ 上采样, 但是由于引入的 Δp_k 采样点扩散呈非均匀分布, 新的 $y(p_0)$ 的表达方式如下:

$$y(p_0) = \sum_{k=1}^K w_k \cdot x(p_0 + p_k + \Delta p_k) \quad (4)$$

为了进一步增强网络对空间支持区域的控制能力,可变形卷积 DCNv2 (Deformable ConvNets v2) 网络引入了一种调节机制^[17]。通过调节机制,网络可以在学习过程中决定如何调节不同位置或区域的特征幅度,从而进一步调整对输入特征的感知和响应。这意味着在模块输出之前,网络可以对输入特征进行更细粒度的调节,将不同位置或区域的特征幅度调整为更适合网络任务的值。在极端情况下,调节机制允许网络将某些位置或区域的特征幅度调整为零,从而使模块可以选择性地不感知来自特定位置或区域的信号,使得模块能够减少或完全消除来自某些空间位置的图像内容对输出的影响。这种灵活性使得网络模块能够更好地适应不同的场景和任务要求,增强了其空间支持区域的调节能力^[18]。可变卷积的调节机制表达式如下:

$$y(p_0) = \sum_{k=1}^K w_k \cdot x(p_0 + p_k + \Delta p_k) \Delta m_k \quad (5)$$

其中, Δp_k 和 Δm_k 分别是第 k 个位置的学习偏移和调制标量, Δp_k 和 Δm_k 都是通过应用于相同输入特征 x 的单独卷积获得。DCNv2 的结构如图 6 所示。




图 6 DCNv2 结构图

Fig. 6 Structure of DCNv2

通过引入可变卷积的采样方式和调节机制,网络能更好地关联各种有效特征分布。因此本文将 C2f 中 Bottleneck 使用的卷积块全部替换为 DCNv2 卷积块,构建新的 C2f-DCNv2 模块。

1.4 WIoU 损失函数

模型的检测精度与损失函数有重要关联,在原网络中,使用 CIoU 作为回归损失函数。设 w, h 分别代表预测框的宽和高, w_g, h_g 代表真实框的宽和高, w_c 和 h_c 代表真实框和预测框最小外接矩形的宽和高, b, b_g 代表预测框和真实框的边界中心点, IoU 代表两个预测框的交并比, ρ 代表两个中心点间的最近距离,则 CIoU 的计算公式如下:

$$L_{\text{CIoU}} = 1 - L_{\text{IoU}} + \frac{\rho^2(b, b_g)}{(w_c)^2 + (h_c)^2} + \alpha v \quad (6)$$

$$\alpha = \frac{v}{1 - L_{\text{IoU}} + v} \quad (7)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w}{h} - \arctan \frac{w_g}{h_g} \right)^2 \quad (8)$$

其中, α 是权重函数,用于平衡参数, v 是纵横比度量函数,用于宽高比一致性。本数据集存在缺陷样本类别不平衡和小目标缺陷较多的问题,这可能造成训练损失波动大,检测准确度低。为了解决传统损失函数对评估结果造成的偏差,替换原损失函数 CIoU 为 WIoU^[19]。WIoU 使用动态非单调聚焦机制对锚框质量进行评估,通过度量预测框与真实框的 IoU 得分,判断它们的重叠程度,然后计算两个框的中心点距离,确定回归框的最大距离,根据重叠区域,计算区域间的权重系数,使用权重系数进一步加强 IoU 得分,通过对不同区域的像素进行加权,有效避免了传统 IoU 分数对小目标缺陷处理不够敏感的问题^[20]。改进后的损失函数对比原损失函数不仅有更快的收敛速度,而且收敛后的损失值更小。WIoU 可以动态优化小目标的损失权重,有助于更精确地评估目标检测的准确性和关联性^[21]。WIoU 的表达式如下:

$$L_{\text{WIoU}} = 1 - \frac{\sum_{i=1}^n w_i * L_{\text{IoU}}(b_i, g_i)}{\sum_{i=1}^n w_i} \quad (9)$$

其中, n 代表标注缺陷的数量, b_i 表示第 i 个预测框的坐标, g_i 表示第 i 个真实框的坐标, $\text{IoU}(b_i, g_i)$ 表示对应预测框与真实框之间的 IoU 值, w_i 表示权重。

1.5 改进后的网络模型

为了轻量化网络模型,首先,使用 C2f-Faster 模块替换原始 YOLOv8n 主干部分的 C2f 模块;其次,将可变卷积 DCNv2 引入颈部检测头前的 3 个 C2f 模块中,增大局部感受野;最后,将原损失函数 CIoU 替换为 WIoU,以改善数据集类别不平衡、小目标缺陷检测精度低等问题。改进后的 YOLOv8n 网络模型如图 7 所示。




图 7 改进后的 YOLOv8 网络模型

Fig. 7 Improved YOLOv8 network model

2 仿真实验与结果分析

2.1 数据集介绍

本实验数据集来自河北工业大学和北京航空航天大学联合发布的公开数据集 PVEL-AD^[22]。数据是在光伏电池生产过程中由专业的工业相机采集,包含 36 543 张正常和具有各种生产缺陷的图像,根据实验需求,选择 7 类常见缺陷^[23],共计 4 430 张图片进行研究,使用 labeling 软件对缺陷进行标注,数据集展示如图 8 所示。




图 8 无异常与缺陷样本

Fig. 8 Normal and defective samples

2.2 实验环境

实验配置环境如表 1 所示。输入图片大小为 640×640,初始化学学习率为 0.01,优化器为 SGD,批次训练数

据量 batch 为 16,训练次数 epochs 为 200 次。随机选取数据集中的 447 张图片作为测试集,其余 3 983 张图片按照 8 : 2 的比例划分为训练集、验证集。

表 1 实验环境

Table 1 Experimental environment

名 称	参 数
操作系统	ubuntu 1. 81
CPU	Intel(R) Xeon(R) Silver4214R CPU@ 2. 40GHz
GPU	NVIDIA RTX3080Ti, 12GB
编程语言	Python 3. 8
框架	Pytorch1. 31+CUDA12. 1

2.3 评估标准

本实验采用召回率(Recall, R)、精确率(Precision, P)、平均精度(mean Average Precision, mAP)、参数量(Params)、计算量(GFLOPs)、帧率(Frames Per Second, FPS)作为评价指标。其中召回率、精准率、平均精度和平均精度均值的计算公式如下:

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \tag{10}$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \tag{11}$$

$$f_{AP} = \int_0^1 P(R) dR \tag{12}$$

$$f_{mAP} = \frac{\sum_{i=1}^N AP_i}{N} \tag{13}$$

N_{TP} 、 N_{FP} 、 N_{FN} 表示真正例、假正例、假反例, N 代表样本数量;mAP 代表不同类别的平均精确度;mAP@ 0. 5 表示当 IOU 阈值为 0. 5 时,不同类别的平均精确度。

2.4 基准模型对比实验

为了验证选择 YOLOv8 系列中 n 模型的优势,本文在 n、s、m、l、x 基准模型上进行对比实验,实验结果如表 2 所示。

表 2 基准模型对比实验

Table 2 Comparison of benchmark models

模 型	$f_{mAP@0.5}/\%$	Params/M	FPS
YOLOv8n	91. 0	3. 0	116
YOLOv8s	91. 5	11. 1	91
YOLOv8m	90. 3	25. 8	61
YOLOv8l	90. 1	43. 6	45
YOLOv8x	90. 6	68. 2	31

由表 2 可知,YOLOv8n 模型的参数量和推理速度

都优于其他基准模型,但在检测精度上,虽然不如 YOLOv8s 模型,考虑到企业部署时需要满足实时性和轻量化的特点,允许损失部分检测精度,因此,本文选择 YOLOv8n 模型作为基准模型。

2.5 不同位置添加可变形卷积模块的对比实验

YOLOv8n 基准网络中共设置 3 个检测头,尺寸大小分别为 20×20 、 40×40 、 80×80 ,不同尺寸可以捕获不同尺度的目标信息。作为全局信息捕获的关键,SPPF 模块融合了可变形卷积,这对提升网络的特征捕获能力具有重要作用。为此,本文设计 5 组对比实验,分别在 5 个不同位置添加可变形卷积模块,验证不同位置添加可变形卷积的合理性。A 组为在 SPPF 模块前的 C2f 模块添加可变形卷积模块,B 组为在 20×20 检测头前的 C2f 模块添加可变形卷积模块,C 组为在 40×40 检测头前的 C2f 模块添加可变形卷积模块,D 组为在 80×80 检测头前的 C2f 模块添加可变形卷积模块,F 组为在 3 个检测头前的 C2f 模块均添加可变形卷积模块。实验结果如表 3 所示。

表 3 添加可变卷积模块对比实验

Table 3 Performance comparison with deformable convolutions added at different positions /%

实 验	P	R	$f_{\text{mAP@0.5}}$
A	86.1	86.0	90.3
B	86.6	87.0	91.3
C	86.5	87.7	91.5
D	86.4	87.8	91.5
F	86.6	87.9	91.9

表 5 消融实验

Table 5 Ablation experiments

YOLOv8n	C2f-Faster	C2f-DCNv2	WIoU	$f_{\text{mAP@0.5}}/\%$	Params/M	GFLOPs	FPS
✓	—	—	—	91.0	3.0	8.1	116
✓	—	—	✓	92.3	3.0	8.1	114
✓	—	✓	—	91.9	3.1	7.9	107
✓	✓	—	—	91.8	2.5	7.0	121
✓	✓	✓	—	92.4	2.6	6.7	112
✓	✓	✓	✓	93.2	2.6	6.7	110

由表 5 可知,在原始 YOLOv8n 的基础模型下,检测模型的 mAP@0.5 为 91.0%。在原模型的基础上分别引入 WIoU 损失函数、C2f-DCNv2 模块、C2f-Faster 模块,模型 mAP@0.5 分别提升 1.3%、0.9%、0.8%,证明了添加各个模块的有效性。

通过更全面的评价指标可知,在将主干部分的 C2f 模块替换为 C2f-Faster 模块后,检测模型的参数量降低 0.5 M, mAP@0.5 提升 0.8%,GFLOPs 下降 1.1, FPS

由表 3 可知,可变形卷积的添加位置影响模型的准确率、召回率以及 mAP@0.5 指标,由实验 B、C、D 可知,当可变形卷积添加在不同检测头前的 C2f 模块时,模型精度均有提升,当检测头前的 3 个 C2f 模块均添加可变形卷积后,模型的检测精度达到最高。

2.6 不同损失函数的对比实验

为验证更换不同损失函数对实验的有效性,分别在 YOLOv8n 的基础模型上替换不同的损失函数进行实验,实验结果如表 4 所示。由表 4 可知,将损失函数 CIoU 替换成 WIoU 后,模型的准确率、召回率以及 mAP@0.5 指标都优于其他损失函数,改进损失函数后,模型对缺陷的检测更加准确。

表 4 损失函数对比实验

Table 4 Comparison of loss functions /%

损失函数	P	R	$f_{\text{mAP@0.5}}$
CIoU	86.6	87.0	91.0
GIoU	86.1	87.9	92.0
DIoU	87.6	87.7	92.0
SIoU	87.7	87.6	92.1
WIoU	89.8	87.9	92.3

2.7 消融实验

为了验证改进 YOLOv8n 检测模型的有效性和合理性,本文在保留原网络结构的基础上,单独引入各个模块和改进损失函数进行实验,证明各个模块的有效性,并依次添加各部分模块以验证融合后模型的合理性。消融实验结果如表 5 所示。

略微提升,说明引入的 C2f-Faster 模块,不仅降低了参数量,提升了计算速度,而且对于全局信息的获取量更高;当在颈部 C2f 位置引入 DCNv2 模块后,参数量仅上升 0.1 M, mAP@0.5 再次提升 0.6%,GFLOPs 下降 0.3,说明引入的 DCNv2 模块能够更好地获取缺陷信息;最后通过替换原损失函数 CIoU 为 WIoU,在保持检测速度基本不变的情况下,进一步提升 0.8%的 mAP@0.5 。通过依此添加各个模块,证明了融合后

网络的合理性。

2.8 不同检测模型的对比试验

为充分验证本算法的优越性,将本文算法与 Faster-RCNN、SSD、DETR、YOLOv5n、YOLOv7-tiny、YOLOX-tiny、YOLOv8n 以及最新的 YOLOv9-c、YOLOv10-n 进行对比实验。实验结果如表 6 所示。

表 6 对比实验

算 法	Param/M	$f_{mAP@0.5}/\%$	FPS
Faster-RCNN	25.6	68.0	24
SSD	24.4	77.0	65
DETR	19.9	87.0	54
YOLOv5n	1.9	90.6	98
YOLOX-tiny	5.4	80.2	58
YOLOv7-tiny	6.2	67.2	95
YOLOv8n	3.0	91.0	116
YOLOv9-c	25.3	91.6	75
YOLOv10-n	2.3	90.2	80
本文算法	2.6	93.2	110

由表 6 可以看出,Faster-RCNN、SSD、DETR 对于复杂背景下 EL 图像的缺陷检测效果不佳,并且参数量巨大。对比 YOLO 系列可知,YOLOv5n 与本文算法相比,参数量虽然减少 0.7 M,但是精度下降 2.6%,检测速度慢 10.9%。YOLOX-tiny、YOLOv7-tiny 虽然参数量相比传统算法大大降低,但是 mAP@0.5 仅有 80.2%和 67.2%。本文算法与原始 YOLOv8n 算法相比,不仅参数量下降 0.4 M,并且 mAP@0.5 提升 2.2%,推理速度略微降低。本文算法与最新 YOLOv9-c、YOLOv10-n 模型相比,在 mAP@0.5 和推理速度指标上仍有领先,本文算法的参数量仅为 2.6 M,mAP@0.5 达到 93.2%,检测帧率达到 110 FPS。

为直观展示算法改进前后的检测效果,本文选择对测试集中部分包含线性裂纹 (line_crack)、断栅 (finger)、粗线(thick_line)、星型裂纹 (star_crack) 缺陷的 EL 图像与 YOLOv8n 算法进行检测对比,检测效果如图 9 所示。






图 9 算法改进前后检测效果对比

Fig. 9 Comparison of detection results before and after improvement

由检测效果图 9 可知,改后的模型对于线性裂纹、断栅、粗线、星型裂纹的检测效果更好,由此可知改进后的模型对于 EL 光伏电池缺陷检测有明显的提升。YOLOv8n 算法以及本文改进算法全部类别的 P-R 曲线如图 10 所示。



(a) YOLOv8n 算法 P-R 曲线



(b) 本文算法 P-R 曲线

图 10 YOLOv8n 算法与本文算法 P-R 曲线对比

Fig. 10 Comparison of P-R curves of YOLOv8n and the proposed algorithm

3 结 论

针对光伏电池板缺陷尺度差异大,传统检测方法检测效率低的问题,提出一种基于 YOLOv8n 的改进模

型。该模型通过在主干部分引入 C2f-Faster 模块,有效降低了检测模型的参数量和计算量;使用 DCNv2 模块与检测头前的 C2f 模块融合,减少了线性裂纹、断栅、星型裂纹、黑芯等的漏检率,并且进一步降低了计算量;通过更换损失函数,再次提升了检测的准确率。改进的 YOLOv8n 模型不仅精度得到了提升,而且参数量、计算量得以减少,检测速度基本保持不变,满足工业生产需求,适合部署到嵌入式设备。

本文算法的优势在于提升缺陷检测精度的同时降低了模型的参数量和计算量,同时保持了检测速度基本不变。本文算法的劣势在于虽然在一定程度上降低了参数量但是模型的体积还是很大,并且检测精度仍有待提升。在未来的工作中,将进一步减少模型参数量,通过引入剪枝和蒸馏技术,在保持精度的同时,实现轻量化部署,以减低企业生产成本,提高工业生产效率。

参考文献(References):

- [1] 伊欣同, 单亚峰. 基于改进 Faster R-CNN 的光伏电池内部缺陷检测[J]. 电子测量与仪器学报, 2021, 35(1): 40-47.
Yi Xintong, Shan Yafeng. Photovoltaic cell internal defect detection based on improved Faster R-CNN[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(1): 40-47.
- [2] Ge C, Liu Z, Fang L, et al. A hybrid fuzzy convolutional neural network based mechanism for photovoltaic cell defect detection with electroluminescence images[J]. IEEE Transactions on Parallel and Distributed Systems, 2020, 32(7): 1653-1664.
- [3] 唐政, 张会林, 马立新. 密集主干网络算法对太阳能电池的缺陷检测[J]. 激光与光电子学进展, 2023, 60(14): 246-252.
Tang Zheng, Zhang Huilin, Ma Lixin. Defect detection for solar cells using dense backbone network algorithm[J]. Laser & Optoelectronics Progress, 2023, 60(14): 246-252.
- [4] Lu S, Wu K, Chen J. Solar cell surface defect detection based on optimized YOLOv5[J]. IEEE Access, 2023, 11: 71026-71036.
- [5] 彭兴辉, 田建平, 吴相东, 等. 基于数据增强的光伏电池片缺陷检测方法研究[J]. 中国测试, 2023, 49(7): 29-34.
Peng Xinghui, Tian Jianping, Wu Xiangdong, et al. Research on defect detection method of photovoltaic cell based on data enhancement[J]. China Measurement & Test, 2023, 49(7): 29-34.
- [6] 周颖, 颜毓泽, 陈海永, 等. 基于改进 YOLOv8 的光伏电池缺陷检测[J]. 激光与光电子学进展, 2024, 61(8): 245-255.
Zhou Ying, Yan Yuze, Chen Haiyong, et al. Defect detection

- of photovoltaic cells based on improved YOLOv8[J]. *Laser & Optoelectronics Progress*, 2024, 61(8): 245–255.
- [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/OL]. *计算机工程与应用*. <https://link.cnki.net/urlid/11.2127.TP.20240430.1335.016>. Xu Wei, Li Weixiang, Fang Zhi, et al. Photovoltaic cell defect detection algorithm based on improved YOLOv7-tiny[J/OL]. *Computer Engineering and Applications*. <https://link.cnki.net/urlid/11.2127.TP.20240430.1335.016>.
- [8] 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.
- [9] Xie X, Liu H, Na Z, et al. DPiT: detecting defects of photovoltaic solar cells with image transformers[J]. *IEEE Access*, 2021, 9: 154292–154303.
- [10] Jiang P, Ergu D, Liu F, et al. A review of yolo algorithm developments[J]. *Procedia Computer Science*, 2022, 199: 1066–1073.
- [11] Hussain M. YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection[J]. *Machines*, 2023, 11(7): 677.
- [12] 刘岩,周孟然. 融合知识蒸馏和注意力制的安全帽佩戴检测[J/OL]. *重庆工商大学学报(自然科学版)*. <https://link.cnki.net/rldid/50.1155.N.20240425.1723.004>. Liu Yan, Zhou Mengran. Helmet wearing detection based on knowledge distillation and attention mechanism[J/OL]. *Journal of Chongqing Technology and Business University (Natural Science Edition)*. <https://link.cnki.net/urlid/50.1155.N.20240425.1723.004>.
- [13] Yang Q, Meng H, Gao Y, et al. A real-time object detection method for underwater complex environments based on FasterNet-YOLOv7[J]. *Journal of Real-Time Image Processing*, 2023, 21(1): 8.
- [14] Cai B, Kong L, Zhou Y, et al. Small object detection for mobile behavior recognition based on Wasserstein distance and partial convolution[C]//*Proceedings of the Optoelectronic Imaging and Multimedia Technology X. SPIE*, 2023: 246–252.
- [15] Han K, Wang Y, Chen H, et al. A survey on vision transformer[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(1): 87–110.
- [16] Zhu X, Hu H, Lin S, et al. Deformable ConvNets V2: more deformable, better results[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2019: 9308–9316.
- [17] 戴林华,黎远松,石睿. YOLOv8-SSDW: 基于YOLOv8的带钢表面缺陷检测算法[J/OL]. *重庆工商大学学报(自然科学版)*. <https://link.cnki.net/urlid/50.1155.N.20240204.1531.002>. Dai Linhua, Li Yuansong, Shi Rui. YOLOv8-SSDW: strip surface defect detection algorithm based on YOLOv8[J/OL]. *Journal of Chongqing Technology and Business University (Natural Science Edition)*. <https://link.cnki.net/urlid/50.1155.N.20240204.1531.002>.
- [18] Hu D, Yu M, Wu X, et al. DGW-YOLOv8: a small insulator target detection algorithm based on deformable attention backbone and WIoU loss function[J]. *IET Image Processing*, 2024, 18(4): 1096–1108.
- [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 Xiansheng, Li Rui, He Shuai. Road obstacle detection algorithm based on improved YOLOv5s[J]. *Electronic Measurement Technology*, 2023, 46(22): 177–185.
- [20] 王铖浩,骆忠强,漆梓渊. 基于改进YOLOv5的变压器漏油检测[J]. *国外电子测量技术*, 2023, 42(9): 169–176. Wang Chenghao, Luo Zhongqiang, Qi Ziyuan. Transformer oil leakage detection based on improved YOLOv5[J]. *Foreign Electronic Measurement Technology*, 2023, 42(9): 169–176.
- [21] 刘向举,刘洋,蒋社想. 基于SimAM注意力机制的DCN-YOLOv5水下目标检测[J/OL]. *重庆工商大学学报(自然科学版)*. <https://link.cnki.net/urlid/50.1155.N.20231020.1542.004>. Liu Xiangju, Liu Yang, Jiang Shexiang. DCN-YOLOv5 underwater target detection based on SimAM attention mechanism[J/OL]. *Journal of Chongqing Technology and Business University (Natural Science Edition)*. <https://link.cnki.net/urlid/50.1155.N.20231020.1542.004>.
- [22] 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*, 2023, 19(1): 404–413.
- [23] 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 Linsen, Zhu Wenzhong, Xie Kangkang, et al. Improved YOLOv5s-based image detection model for EL defects in photovoltaic cells[J]. *Foreign Electronic Measurement Technology*, 2023, 42(6): 93–102.

责任编辑:李翠薇