

DOI:10.19651/j.cnki.emt.2517869

改进 YOLOv10n 的光伏电池缺陷检测算法^{*}

王海群 武泽楷 于海峰

(华北理工大学电气工程学院 唐山 063000)

摘要: 针对光伏电池缺陷检测中,由于缺陷形态不规则、尺寸多变及缺陷种类繁多等因素导致的缺陷识别困难、漏检和误检率高的问题,提出一种改进 YOLOv10n 的光伏电池缺陷检测算法。首先,剔除原 C2f 的 Bottleneck 结构,设计 PMSFA_CSP 模块作为主干和颈部网络的部分特征提取模块,通过其部分多尺度特征提取及残差结构获取上下文信息的能力,增强网络对缺陷特征的融合能力。其次,利用不同膨胀率的共享卷积层及 SENetV2 聚合稠密层注意力机制,设计 FPSC_SENetV2 模块引入主干网络,减少局部信息丢失,增强网络对细节特征的捕捉能力。再次,融合 FreqFPN 与 PMSFA_CSP 模块,设计 FreqFP_FPN 模块并引入特征金字塔网络,降低类别不一致性,增强高频细节的缺陷信息;最后,构建 SESN 损失函数作为边界框回归损失函数,平衡不同尺度缺陷的检测,加速网络收敛,提高计算效率。实验结果表明:将改进的 YOLOv10n 在光伏电池缺陷数据集上进行实验,相较原算法 mAP@0.5 提高 3.0%;计算量降低 0.7 GFLOPs;参数量降低 0.08 M;综合性能满足光伏电池缺陷检测要求。

关键词: 光伏电池;缺陷检测;YOLOv10n;损失函数;SENetV2 注意力机制;共享卷积层;部分卷积

中图分类号: TP391.41;TN86.2 **文献标识码:** A **国家标准学科分类代码:** 510.80

Improved defect detection algorithm for YOLOv10n photovoltaic cells

Wang Haiqun Wu Zekai Yu Haifeng

(Faculty of Electrical Engineering, North China University of Science and Technology, Tangshan 063000, China)

Abstract: In order to solve the problems of difficulty in defect identification, high rate of missed detection and false detection rate caused by factors such as irregular defect shape, variable size and wide variety of defects in photovoltaic cell defect detection, an improved photovoltaic cell defect detection algorithm based on YOLOv10n was proposed. Firstly, the bottleneck structure of the original C2f is eliminated, and the PMSFA_CSP module is designed as a partial feature extraction module of the backbone and neck network, and the ability to obtain context information through its partial multi-scale feature extraction and residual structure is designed to enhance the network's ability to fuse defect features. Secondly, by using the shared convolutional layer with different expansion rates and the attention mechanism of SENetV2 aggregate dense layer, the FPSC_SENetV2 module is designed to introduce the backbone network to reduce local information loss and enhance the network's ability to capture detailed features. Thirdly, FreqFPN and PMSFA_CSP modules were fused, and the FreqFP_FPN modules were designed and feature pyramid networks were introduced to reduce category inconsistency and enhance the defect information of high-frequency details. Finally, the SESN loss function is constructed as the bounding box regression loss function to balance the detection of defects at different scales, accelerate the network convergence, and improve the computational efficiency. The experimental results show that compared with the original algorithm, the improved YOLOv10n is improved by 3.0%, the computational amount is reduced by 0.7 GFLOPs, and the parameter quantity is reduced by 0.08 M, which is compared with the original algorithm mAP@0.5, and the comprehensive performance meets the requirements of photovoltaic cell defect detection.

Keywords: photovoltaic cells; defect detection; YOLOv10n; loss function; SENetV2 attention mechanism; shared convolutional layers; partial convolution

0 引言

随着可再生能源需求的增长,光伏发电因其环保和可

持续性进而备受关注。光伏电池是光伏发电系统的核心,其质量直接影响发电效率和系统寿命。然而,在光伏电池的生产与使用中可能出现裂纹、黑芯、断栅等细微缺陷,若

收稿日期:2025-01-10

^{*} 基金项目:河北省自然科学基金(D2024209006)、河北省教育厅科学研究项目(QN2024147)资助

未能及时检测处理,会严重影响发电效率。因此,高效准确的缺陷检测对于保障光伏系统的长期稳定运行至关重要。

在分析缺陷图像时,目标检测技术负责从图像中精确识别和定位图像中的目标物体。基于深度学习的目标检测算法主要分为两大类:两阶段检测器和单阶段检测器。两阶段检测器以 R-CNN 系列为代表,典型算法包括 Faster R-CNN^[1] 和 Cascade R-CNN^[2] 等。单阶段检测器如 YOLO 系列(YOLOv5^[3]、YOLOv8、YOLOv9^[4])、(single shot multibox detector,SSD)等,该方法不需要额外生成候选区域,直接从输入图像中生成目标的类别和位置。

近年,光伏电池缺陷检测领域的研究日益深入。汪方斌等^[5]基于 U-Net 模型结合 MobileNet 中深度可分离卷积配合(efficient channel attention,ECA)注意力机制的轻量化思想,在降低参数数量的同时,对裂纹、黑斑等缺陷的检测精度有所提升;张冀等^[6]提出 RFCARep-YOLOv8n 缺陷检测算法,通过结合多尺度辅助检测头,提高了对小目标缺陷的检测能力;郭建等^[7]在 YOLOv5 颈部网络引入(bidirectional feature pyramid network,BiFPN)双向特征金字塔网络,减少光伏组件复杂背景的干扰,降低无关信息的特征;杨丽等^[8]结合广义高效层聚合网络 and 在线重参数化,提出 OREPANCSPPLAN4 模块,在提升模型精度的同时降低了参数数量,提高了对光伏电池表面缺陷的检测能力。

上述算法均在基础算法上进行改进,提高了模型的检测速度、精度,并降低了参数量。然而,在面对密集缺陷、复杂裂纹、重叠缺陷以及光伏电池自带的复杂背景时,仍会出现漏检和误检现象。

为解决上述问题,本文提出一种改进 YOLOv10n 的光伏电池缺陷检测算法。首先,通过部分卷积重构 C2f 模块并引入主干网络,增强网络特征融合能力;其次,引入不同膨胀率的共享卷积层及聚合稠密层注意力机制(squeeze-and-excitation networks V2,SENetV2)重构 SPPF 模块,减少局部细节信息丢失;再次,结合频率感知模块(freqfusion,FreqF)的思想设计 FreqFP_FPN,引入颈部网络,减少网络参数冗余;最后,采用 EMASlide loss 和归一化高斯损失(normalized wasserstein distance loss,NWD loss)的 SIoU 优化原损失函数,提升模型定位精度,加速网络收敛。

1 YOLOv10n 算法介绍

YOLOv10 由小到大包括 n、s、m、b、l 和 x 6 种型号,YOLOv10n 以其较少的参数量和计算量,在应用中展现出巨大潜力,主要由 3 个核心模块组成:主干网络(Backbone)、颈部网络(Neck)和输出网络(Head),具体结构如图 1 所示。

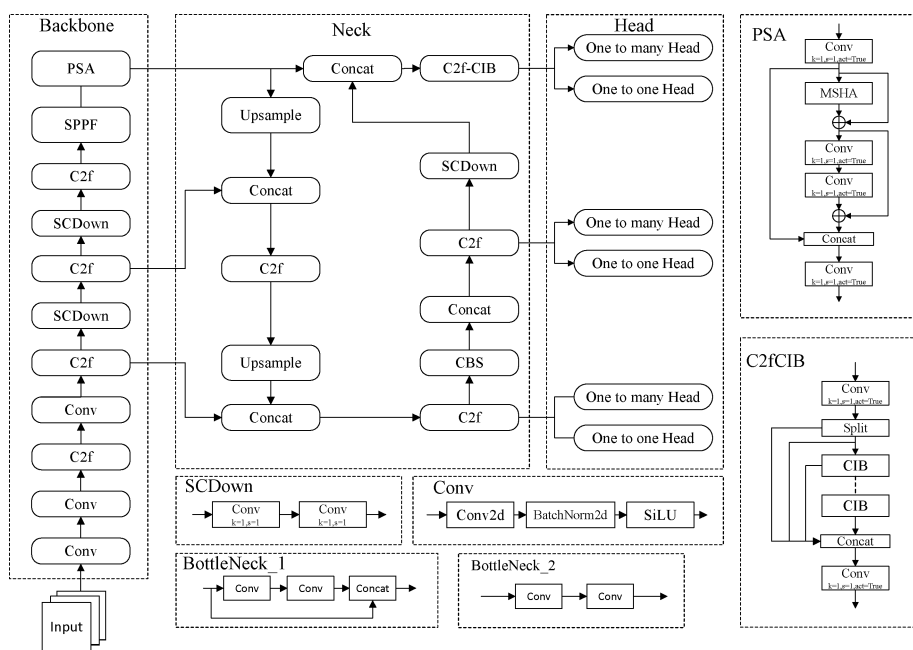


图 1 YOLOv10n 算法结构

Fig. 1 Structure of the YOLOv10n algorithm

YOLOv10n 的主干网络(Backbone)采用增强版的跨阶段部分网络 CSPNet,通过优化梯度流动和减少计算冗余,提高特征提取效率。主干网络负责提取多层次、多尺度的图像特征,为后续的目标检测提供基础。特征金字塔网络(Neck)结合金字塔网络(feature pyramid network,

FPN)+路径聚合网络(path aggregation network,PAN)结构,FPN 通过自顶向下的路径和横向连接实现特征融合,而 PAN 通过自底向上的路径完成多尺度特征聚合,两者协同作用,进一步融合主干网络提取的多层次特征。

输出网络(Head)采用解耦头结构,摒弃了传统锚框机

制,改用无锚框方案,并引入一对多头(one-to-many head)和一对一头(one-to-one head),一对多头在训练过程中为每个对象生成多个预测,提供丰富的监督信号并提高学习准确性;而一对一头在推理过程中为每个对象生成一个最佳预测,减少延迟并提高检测效率。

2 YOLOv10n 算法改进

针对 YOLOv10n 模型在光伏电池缺陷检测中存在目标识别困难、漏检和误检率高等问题,本文提出改进 YOLOv10n 的光伏电池缺陷检测算法。具体工作如下:

1)为更有效地处理光伏电池中的不规则缺陷和复杂形状,通过剔除原 C2f 的 Bottleneck 结构,引入高效的部分卷积^[9](partialconv, PConv)和残差链接,设计部分多尺度特征提取模块(partial multi-scale feature aggregation_CSP, PMSFA_CSP),提升模型的计算效率和特征融合

能力。

2)通过结合不同膨胀率的共享卷积层与聚合稠密层注意力机制 SENetV2,设计聚合金字塔共享模块(feature pyramid shared conv_senetV2, FPSC_SENetV2),利用多尺度特征提取和高效的通道变换,全面捕获局部细节和全局上下文信息,提高网络对关键缺陷特征的聚焦能力。

3)设计频率感知特征融合模块(freqfusion-pmsfa_FPN, FreqFP_FPN),利用 FreqFusion 的频率特性及 PMSFA_CSP 的残差链接,增强低层特征与高层特征融合的特征质量,减少网络参数冗余。

4)为提升模型在缺陷检测任务中的定位精度,设计 SESN(SIoU-emaslidenwd Loss)损失函数。将原 YOLOv10n 的损失函数 CIoU 优化为 Siou,并进一步引入 NWD loss 和 EMASlide Loss,规范模型定位。

改进的 YOLOv10n 算法结果如图 2 所示。

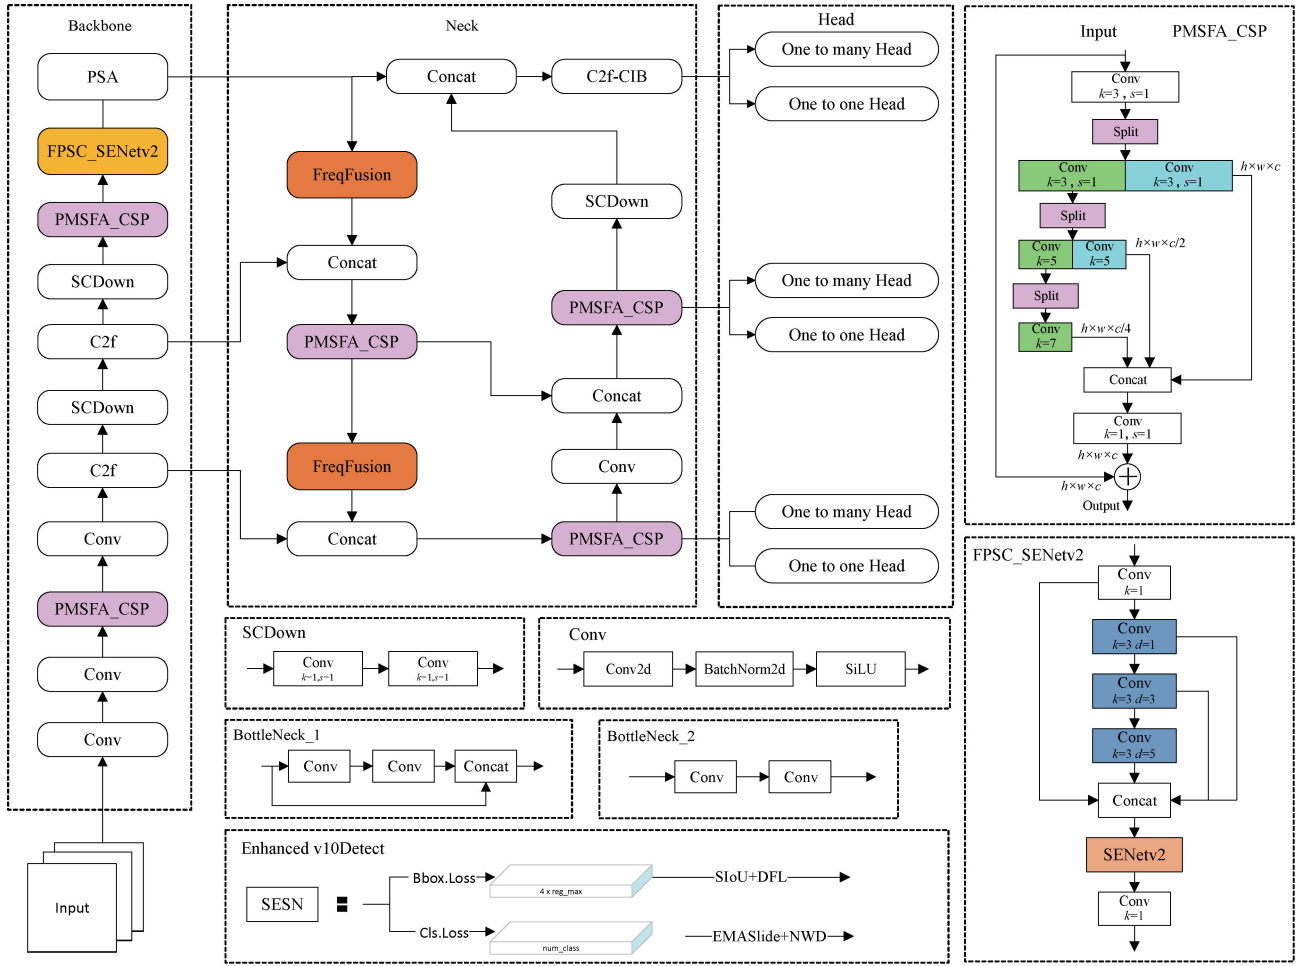


图 2 改进的 YOLOv10n 算法结构

Fig. 2 Structure of the improved YOLOv10n algorithm

2.1 部分多尺度特征提取模块 PMSFA_CSP

在 YOLOv10n 中,C2f 模块通过多个 Bottleneck 结构缓解网络中的梯度消失问题。尽管 Bottleneck 结构有助于

提升网络的深度和表达能力,但其内部的降维和升维操作会过滤掉重要的细节特征。为突破 Bottleneck 结构的局限性,通过剔除 Bottleneck 结构,在 C2f 模块中引入不同尺度

卷积核的部分卷积 PConv^[9]和残差链接,设计部分多尺度特征聚合模块 PMSFA_CSP。如图 2 所示,与传统方法相异,部分卷积不是在所有通道上进行多尺度特征提取,而是部分地进行,将不同尺度的特征同时传递到 Concat 进行融合,从而提高模型的计算效率。

普通卷积与部分卷积的存储访问量分别如式(1)、(2)所示。

$$h \times w \times 2c + k^2 \times c^2 \approx h \times w \times 2c \quad (1)$$

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

式中: k 为卷积核尺寸, h 为输入特征图的高度, w 为输入特征图的宽度, c 为普通卷积通道数, c_p 为部分卷积的通道数。在计算过程中普通卷积通道数 c 大于部分卷积的通道数 c_p ,通过下采样操作,部分卷积能够减少输入特征图的空间维度,从而缩小输出的特征图尺寸。为进一步增强模型的特征捕捉能力,在模块的最后引入一个 1×1 卷积层,用于融合不同尺度的缺陷特征。通过残差链接将输入特征与处理后的特征相加,在保留原始信息的同时,引入新的多尺度信息,提升模型对细节缺陷的识别能力以及对上下文信息的理解。

PMSFA_CSP 与 C2f 模块对比分别如图 3(a)C2f 模块和图 3(b)PMSFA_CSP 模块所示。PMSFA_CSP 通过剔除 Bottleneck 结构,并引入部分卷积和残差链接,解决了 Bottleneck 结构堆叠,导致加深网络深度的局限性。

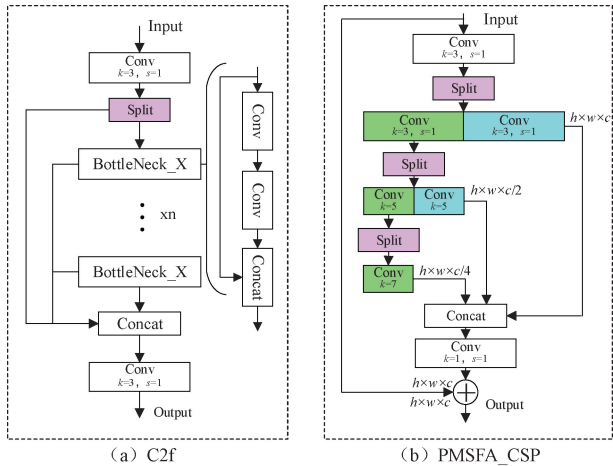


图 3 C2f 与 PMSFA_CSP 模块结构对比

Fig. 3 Comparison of C2f and PMSFA_CSP modules

2.2 聚合金字塔共享模块 FPSC_SENetV2

SPPF 模块利用空间金字塔池化技术,融合不同尺度的特征。由于光伏电池缺陷具有形状不规则、多样性以及细微特征等特点,传统 SPPF 模块的固定池化结构难以适应不同尺度缺陷的特征提取需求。本文通过重构 SPPF 模块,将不同膨胀率的特征金字塔共享卷积(feature pyramid shared conv, FPSC)与 SENetV2 进行融合,设计聚合特征金字塔共享卷积模块 FPSC_SENetV2,具体结构如图 2 所示。

挤压激励注意力机制 SENet^[10]通过全局信息对每个通道进行加权调整,增强重要通道特征的贡献。聚合稠密层注意力机制 SENetV2^[11]继承 SENet 的核心理念,引入多分支卷积结构,将多分支稠密层嵌入到 SENet 的残差模块中,构建新的聚合稠密层 SaE 模块,如图 4 所示。




图 4 SaE 模块工作机制

Fig. 4 Working mechanism of the SaE module

图 4 中 SaE 模块先对特征图通道维度进行压缩操作,将生成的全局信息输入到多分支的全连接(FC)层中进行激励操作,分割的输入在最终阶段被整合以恢复其原始形状。该结构能够使网络在学习输入数据多样化特征的同时,还能充分考虑到不同通道之间的相互依赖性,SENetV2 则通过通道重校准和激活全局特征,并结合多分支结构,进一步增强特征表达的细致程度和全局信息的整合能力。

FPSC_SENetV2 模块通过引入不同膨胀率的特征金字塔共享卷积层,使模型能够捕捉缺陷图像中不同尺度特征。

2.3 频率感知特征融合模块 FreqFP_FPN

YOLOv10 颈部采用 FPN+PAN 的特征融合结构在处理多尺度缺陷目标时,易导致高层特征图中的细节信息丢失,光伏电池的缺陷包含高频成分,其背景信息会干扰缺陷的识别。

为改善光伏电池缺陷检测中小目标检测精度低、高频特征丢失和多尺度特征不均衡等问题,本文在特征金字塔网络引入频率感知模块 FreqF,模块结构如图 5 所示。基于 FreqFusion 模块,设计频率感知特征融合模块,如图 6 所示。

FreqF^[12]模块通过两个主要阶段进行操作,即初始融合和最终融合。由图 5 可知,具体操作流程如下:在初始融合阶段,低级特征图 X_{ALPF}^l 和高级特征图 Y_{ALPF}^{l+1} 分别通过 ALPF 发生器和 AHPF 发生器进行处理,并通过 Pixel Unshuffle 操作将高级特征图 Y_{ALPF}^{l+1} 转换为与低级特征图 X_{ALPF}^l 相同尺度的特征图。然后,中间特征图通过逐元素相加与低级特征图 X_{ALPF}^l 进行融合生成 Z^l , Z^l 通过 ALPF 发生器与 Y^{l+1} 结合生成 Z_{ALPF}^{l+1} ,再通过 Pixel Unshuffle 操

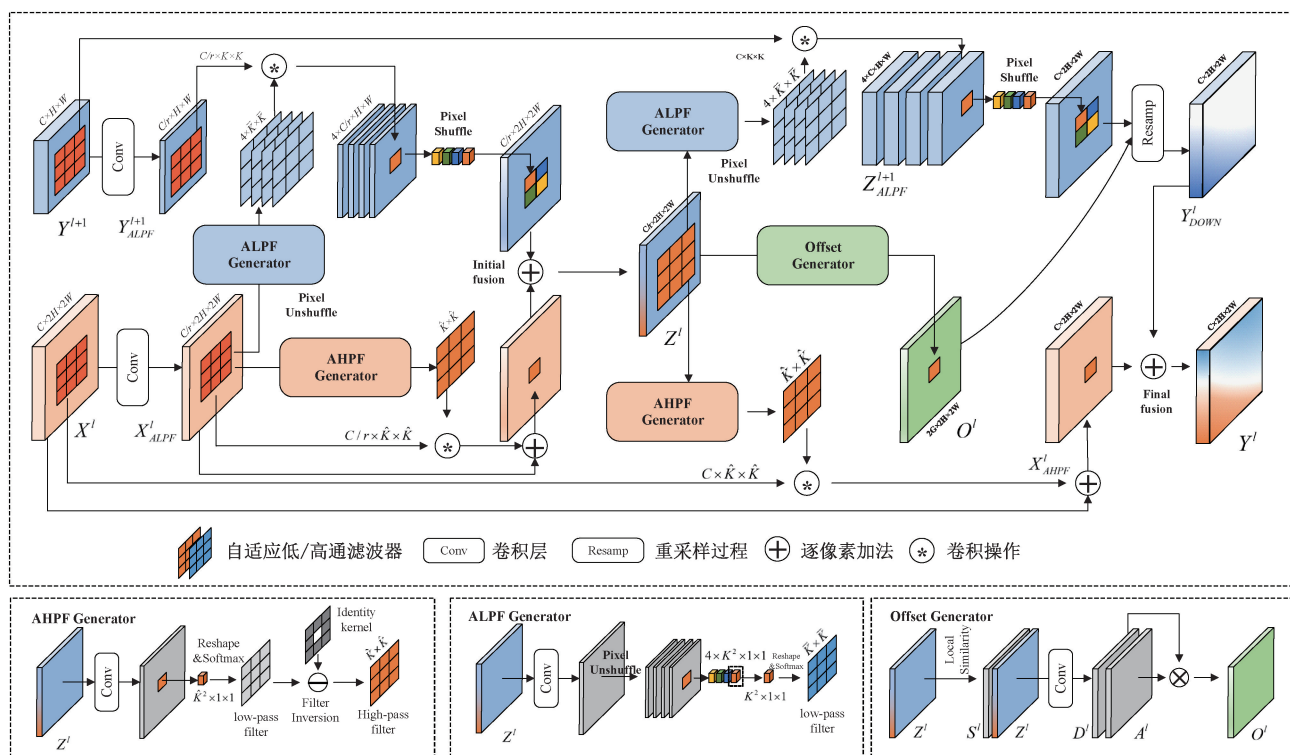


图 5 FreqFusion 模块工作原理

Fig. 5 The working principle of the FreqFusion module

作将尺度调整为与低级特征图相同的尺度并与偏移特征图 O^l 进行重采样操作进行尺度调整和通道压缩,生成 Y^l_{DOWN} , AHPF 发生器与 X^l 结合生成 X^l_{AHPF} 。最后,将压缩后的中间特征图 Y^l_{DOWN} 与低级特征图 X^l_{AHPF} 进行逐元素相加,生成输出特征图 Y^l 。

FreqFP_FPN 模块通过接收 3 个尺度的特征输入,对输入的特征进行融合和增强,聚焦不同尺度缺陷的高层和底层特征信息。

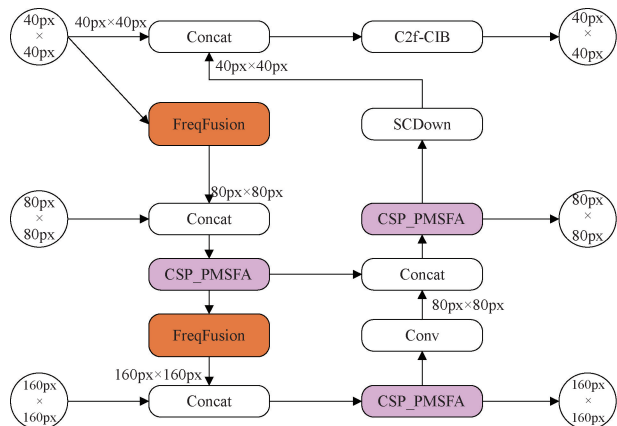


图 6 FreqFP_FPN 结构

Fig. 6 Structure of FreqFP_FPN

2.4 SESN 损失函数

YOLOv10n 原损失函数为 CIoU^[13],通过综合考虑边

界框之间的重叠面积、中心点距离以及长宽比差异,帮助模型准确定位缺陷。然而,CIoU 对中心点距离和长宽比差异的权重较大,当目标方向发生较大变化时,会导致不稳定的损失值。为解决上述问题,引入 SIoU^[14] 损失函数,通过优化边界框的对称性,避免了 CIoU 中复杂的中心点距离和长宽比差异的计算。考虑到 SIoU 在检测过程中仍受小目标位置及极端长宽比缺陷的影响,导致定位精度欠佳。为此,本文设计了 SESN 损失函数,通过引入 EMASlide loss 和 NWD loss,利用其平滑因子、自适应权重和归一化的 Wasserstein 距离,逐步调整训练过程中损失函数的权重,减少梯度的不稳定性,提供更稳定的梯度传递。SESN 损失函数由 SIoU、EMASlide loss 和 NWD loss 联合优化。

SIoU 损失函数主要由距离成本、形状成本和 IoU 成本 3 方面组成。

1) 角度成本

角度成本描述了中心点连接与 x - y 轴之间的最小角度,当中心点在 x 轴或 y 轴上对齐时, $\Delta=0$ 。当中心点连接到 x 轴 45° 时, $\Delta=1$,角度成本计算公式如式(3)所示。

$$\Delta = 1 - 2 \times \sin^2 \left(\arcsin(x) - \frac{\pi}{4} \right) \quad (3)$$

2) 距离成本

距离成本在角度成本基础上进行优化,使预测框在空间位置上紧贴真实框,距离成本计算公式如式(4)所示。

$$\Delta = \sum t = x, y(1 - e^{-\gamma p_i}) \quad (4)$$

3) IoU 成本

IoU 成本为普通的交集比并集值减 1, 代表预测边界框的非重叠部分, 真实框与预测框的交集比并集 IoU 损失如式(5)、(6)所示。

$$L_{IoU} = 1 - IoU \quad (5)$$

$$IoU = \frac{|B \cap B^{GT}|}{|B \cup B^{GT}|} \quad (6)$$

综上所述, SIoU 损失函数公式如式(7)所示。

$$L_{SIoU} = 1 - I_{IoU} + \frac{\Delta + \Omega}{2} \quad (7)$$

SIoU 损失函数在原 IoU 基础上引入角度成本和距离成本, 减弱几何因素对模型的过度惩罚, 提升对非矩形缺陷的检测能力。EMASlide loss 计算公式为:

$$L_{EMASlide}(y, \hat{y}) = (1 - \alpha) \times L_{BCE}(y, \hat{y}) + \alpha \times EMA(L_{BCE}(y, \hat{y})) \quad (8)$$

式中: L_{BCE} 为二元交叉熵损失函数, $EMA(L_{BCE}(y, \hat{y}))$ 是对 L_{BCE} 的指数移动平均, 计算公式分别为:

$$L_{BCE}(y, \hat{y}) = -y \log(\hat{y}) - (1 - y) \log(1 - \hat{y}) \quad (9)$$

$$EMA(L_{BCE}(y, \hat{y})) = \beta \times EMA_{t-1}(L_{BCE}(y, \hat{y})) + (1 - \beta) \times L_{BCE}(y, \hat{y}) \quad (10)$$

式中: α 为平滑因子, β 为 EMA 的衰减因子。通过引入动态权重和指数移动平均调整损失值, 使模型在训练过程中适应不同 IoU 值, 提高对不同缺陷形状和位置的适应性, NWD loss 计算公式如下:

$$L_{NWD} = 1 - \exp\left(-\frac{\sqrt{W_2^2(N_a, N_b)}}{c}\right) \quad (11)$$

$$W_2^2(N_a, N_b) = \left\| \left(\left[cx_a, cy_a, \frac{w_a}{2}, \frac{h_a}{2} \right] T, \left[cx_b, cy_b, \frac{w_b}{2}, \frac{h_b}{2} \right] T \right) \right\| F \quad (12)$$

式中: $W_2^2(N_a, N_b)$ 表示两个分布 N_a 和 N_b 之间的二阶 Wasserstein 距离, c 为封闭框的对角线长度, N_a 和 N_b 分别为预测框和真实框的高斯建模分布。本文将 SIoU、EMASlide loss 和 NWD loss 联合优化, 作为光伏电池缺陷检测边界框的新损失函数 SESN, 计算公式为:

$$L_{SESN} = \lambda L_{SIoU} + (1 - \lambda) L_{NWD} + \gamma L_{EMASlide} \quad (13)$$

经实验表明, 当 λ 为 0.5, γ 为 1 时模型检测效果最佳。

3 实验结果与参数分析

3.1 参数配置

所有实验环境均在 Ubuntu 20.04, 深度学习框架为 Pytorch 1.11.0, Python 版本为 3.8, CUDA 版本为 11.3, 训练 CPU 为 NVIDIA Geforce RTX 4090 的数据上进行, 实验的训练关键参数如表 1 所示。

表 1 模型训练关键参数

Table 1 Key parameters for model training

函数	设置值
优化器	SGD
输入图像大小	640×640
学习率	0.001
epochs	150
批处理大小	16

经实验表明, 当输入图像大小为 640×640 时, 优化器选用 SGD, 学习率为 0.001, 训练轮次为 150, 批处理大小为 16 时, 模型训练最稳定。

3.2 数据集

本文通过收集 PVEL-AD^[15] 开源数据集, 构建光伏电池缺陷检测数据集。该数据集涵盖星状裂纹(SC)、线状裂纹(LC)、断栅(FG)、黑芯(BC)、粗线(TL)、水平错位(HD)、印刷错误(PE)、短路(SC)8 种不同类型的缺陷, 图像共 4 449 张。输入图像的分辨率统一为 1 024×1 024 像素, 并按照为 8:2 的比例将缺陷图像随机划分为训练集和验证集, 其中训练集缺陷图像为 3 560 张, 验证集缺陷图像为 889 张, 部分缺陷效果如图 7(a)~(d)所示。




图 7 部分缺陷效果图

Fig. 7 Renderings of some defects

3.3 评价指标

本文采用准确率 Precision、召回率 Recall、平均精度均值 mAP、浮点运算次数 GFLOPs 来评估模型性能。准确率, 召回率、平均精度均值的公式如式(14)~(16)所示。

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

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

式中:准确率衡量所有被预测为正类的样本中,实际为正类的比例。 TP 指预测为正类且真实情况也是正类的样本数; FP 指预测为正类,但实际为负类的样本数。召回率衡量在所有实际为正类的样本中,被正确识别为正类的比例, FN 指预测为负类,但实际为正类的样本数。平均精度均值 mAP 是所有类别平均精度的平均值。 AP_i 表示第 i 类的平均精度值, k 为所有类别总数。

3.4 空间金字塔池化模块对比实验

为探究剔除 SPPF 的最大池化层,引入不同膨胀率的共享卷积层以及不同注意力机制的效果,采用几种性能优异的注意力机制(如 ECA^[16]、CBAM^[17]、LSKA^[18])分别引入到 SPPF 和 FPSC 模块中,并将其与在 SPPF 和 FPSC 模块相同位置引入的 SENetV2 对比,实验结果如表 2 所示。

表 2 空间金字塔池化模块对比实验

Table 2 Comparative experiments of spatial pyramid pooling modules

算法	mAP50	FLOPs/G	Para/M
SPPF	0.899	6.5	2.27
SPPF_ECA	0.900	6.5	2.27
SPPF_CBAM	0.908	6.5	2.30
SPPF_LSKA	0.910	6.8	2.54
SPPF_SENetV2	0.913	6.5	2.33
FPSC	0.915	6.5	2.40
FPSC_ECA	0.904	6.5	2.41
FPSC_CBAM	0.919	6.5	2.45
FPSC_LSKA	0.913	6.8	2.68
Ours	0.920	6.5	2.41

由表 2 可知,在 SPPF 模块相同位置引入不同类型的注意力机制(如 ECA、CBAM、LSKA 和 SENetV2)普遍提高了模型的性能。其中,引入 SENetV2 相较引入其他注意力机制表现最佳,mAP50 提高了 1.4%,参数量仅增加 0.06 M,展示了聚合稠密层在整合不同尺度缺陷信息方面的优势。相比之下,在引入 ECA 注意力机制后参数量没有变化,但其 mAP50 仅提升 0.1%,整体性能明显逊色于 SENetV2。而引入 LSKA 虽然在 mAP50 方面较 SENetV2 低 0.3%,两者检测精度接近,但其计算量和参数量的增加,导致整体性能较差。

FPSC 模块通过去除 SPPF 中的最大池化层,并引入不同膨胀率的共享卷积层,对 SPPF 模块进行重构。实验结果表明,FPSC 的 mAP50 在所有测试中均优于引入 ECA、CBAM、LSKA 和 SENetV2 的 SPPF 模块,较基线提升 1.6%,展示了不同膨胀率卷积层在捕捉缺陷图像中不同尺度特征方面的优势。其次,将 ECA、CBAM、LSKA 和 SENetV2 注意力机制引入 FPSC 模块较在 SPPF 模块引

入时,检测精度均有提升,其中 FPSC 与 SENetV2 结合后整体性能最优,mAP50 较基线提高 2.1%,参数量较 FPSC 仅提高 0.01 M,验证了本文设计 FPSC_SENetV2 模块提高光伏电池多尺度缺陷检测能力的有效性。

3.5 损失函数对比实验

为评估损失函数对模型性能的影响,通过对比几种性能优异的损失函数(CIoU、WIoU^[19]、EIoU^[20]、ShapeIoU^[21]、SIoU)应用于模型训练中,对比不同损失函数在光伏电池缺陷检测任务中的表现,实验结果如表 3 所示。

表 3 损失函数对比实验

Table 3 Comparative experiments on loss functions

算法	P	R	mAP50
CIoU	0.865	0.856	0.899
WIoU	0.843	0.873	0.908
EIoU	0.883	0.852	0.912
ShapeIoU	0.875	0.875	0.917
ShapeESN	0.862	0.886	0.920
SIoU	0.871	0.869	0.918
Ours	0.875	0.876	0.922

根据表 3 数据显示,引入不同损失函数(CIoU、WIoU、EIoU、ShapeIoU 和 SIoU)后,模型检测精度较原始损失函数均有提升。其中,SIoU 表现最佳,其 mAP50 较基线提升了 1.9%,并在精确率和召回率指标上均优于其他损失函数,展示其处理多尺度缺陷的优势,有效弥补了 CIoU 因目标方向变化影响损失值的不足。

SESN 损失函数基于 SIoU 设计,进一步引入了 EMASlide-Loss 和 NWD-Loss,优化模型的整体性能。为验证 SIoU 在定位精度方面的优势,选择 ShapeIoU 为对比损失函数。实验数据显示,ShapeIoU 的 mAP50 仅较 SIoU 低 0.1%,表明其在性能上与 SIoU 接近。然而,将 EMASlide-Loss 和 NWD-Loss 引入 ShapeIoU 后,尽管 ShapeESN 的 mAP50 提升了 0.3%,但其精确率、召回率以及 mAP50 均低于 SESN。因此,在 SIoU 的基础上引入 EMASlide-Loss 和 NWD-Loss 为最佳选择。实验证实,SESN 较 SIoU 的 mAP50 提升 0.4%,较基线的精确率和召回分别提高 1.0%和 2.0%。

SESN 通过精准定位缺陷位置以及减少漏检、误检率,展示了其针对小目标方向任意变化和极端长宽比缺陷检测的改善能力。

3.6 消融实验

为深度地分析各模块对 YOLOv10n 性能的影响,本文在光伏电池缺陷检测数据集上进行消融实验。通过设计 11 组实验,验证所提改进策略的有效性,实验结果如表 4 所示。

表 4 消融实验
Table 4 Ablation experiments

组别	PMSFA_CSP	FPSC_SENetV2	FreqFP_FPN	SESN	P	R	mAP50	FLOPs/G	Params/M
1	×	×	×	×	0.865	0.856	0.899	6.5	2.27
2	√	×	×	×	0.865	0.873	0.921	6.1	2.06
3	×	√	×	×	0.868	0.852	0.920	6.5	2.41
4	×	×	√	×	0.896	0.852	0.914	6.0	2.19
5	×	×	×	√	0.864	0.876	0.922	6.5	2.27
6	√	√	×	×	0.904	0.858	0.923	6.2	2.34
7	√	×	√	×	0.879	0.866	0.923	5.8	1.95
8	√	×	×	√	0.894	0.870	0.923	6.1	2.06
9	√	√	√	×	0.880	0.890	0.926	5.8	2.19
10	√	×	√	√	0.905	0.853	0.926	5.8	1.95
11	√	√	√	√	0.880	0.899	0.929	5.8	2.19

根据表 4 数据显示,本文提出的各模块均提高了模型性能。第 2 组实验中,通过将 PMSFA_CSP 引入到主干和颈部网络,计算量和参数量较基线分别降低 0.4 GFLOPs 和 0.21 M, mAP50 提高了 2.2%,验证了本文剔除 Bottleneck 结构、引入不同尺度卷积核的 PConv 和残差链接以重构 C2f 的有效性;第 3 组实验引入 FPSC_SENetV2, mAP50 较基线提升 2.1%, P 提高 0.3%;第 4 组引入 FreqFP_FPN, mAP50 较基线提升 1.5%,计算量和参数量分别降低 0.5 GFLOPs 和 0.08 M,证明其减少参数冗余,防止梯度消失的优势;第 5 组实验引入 SESN 损失函数后, mAP50 较基线提高 2.3%,有效规范模型对多尺度缺陷的准确定位,减少了漏检和误检现象。

第 6~8 组是在结合 PMSFA_CSP 基础上引入各改进模块;相较第 2 和第 3 组实验,同时引入 PMSFA_CSP 和 FPSC_SENetV2, mAP50 分别提高了 0.2% 和 0.3%;第 7 组实验引入 FreqFP_FPN,较基线 mAP50 提升 2.4%,参数量和计算量分别降低 0.32 M 和 0.7 GFLOPs;第 8 组实验引入 SESN 损失函数, mAP50 较基线提升 2.4%,计算量和参数量分别降低 0.21 M 和 0.4 GFLOPs, P 和 R 分别提高 2.9% 和 1.4%,展示两者结合后存在协同效应,提升模型的整体性能。相较第 6 和第 7 组实验,在引入 PMSFA_CSP 的基础上,同时引入 FPSC_SENetV2 和 FreqFP_FPN, mAP50 均提高 0.3%,计算量降低 0.7 GFLOPs;同时引入 FreqFP_FPN 和 SESN 损失函数后, mAP50 较基线提升 2.7%,分别验证了三者模块结合的优势;最终改进模型较基线 P、R 和 mAP50 分别提升 1.5%、4.3% 和 3.0%,计算量和参数量分别减少 0.7 GFLOPs 和 0.08 M,验证了本文所有改进模块的有效性。

3.7 主流算法对比实验

为更全面验证改进算法的优越性,将改进后的算法在光伏电池缺陷检测数据集上进行实验验证,并与主流双阶

段(Faster_RCNN、Mask_RCNN 和 Cascade_RCNN)、单阶段 (TOOD^[22]、YOLOv3、YOLOv5n、YOLOX、YOLOv7-tiny、YOLOv8n 和 YOLOv9-tiny)算法进行对比分析,实验结果如表 5 所示。

表 5 主流算法对比实验
Table 5 Comparative experiments of mainstream algorithms

算法	mAP50	Para/M	GFLOPs
Faster_RCNN	0.742	41.16	206.7
Mask_RCNN	0.813	44.17	260.1
Cascade_RCNN	0.837	68.95	234.5
TOOD	0.858	30.81	180.9
YOLOv3	0.877	103.70	282.2
YOLOv5n	0.878	7.01	7.1
YOLOX	0.873	5.03	18.9
YOLOv7-tiny	0.754	6.01	13.1
YOLOv8n	0.893	3.01	8.1
YOLOv9-tiny	0.898	1.97	10.7
YOLOv10n	0.899	2.27	6.5
文献[6]	0.876	3.23	8.2
BCS-YOLOv8 ^[23]	0.932	12.30	20.5
Ours	0.929	2.19	5.8

实验数据表明,双阶段算法如 Faster_RCNN、Mask_RCNN 和 Cascade_RCNN 在检测精度方面表现出优势,但在参数量和计算量方面仍有改进空间。相比之下,单阶段算法 TOOD 在 mAP50 上分别比 Faster_RCNN、Mask_RCNN 和 Cascade_RCNN 高 11.6%、4.5% 和 2.1%,且参数量和计算量均低于上述 3 种算法;YOLOv3 作为 TOOD 后的新兴单阶段算法,其 mAP50 较 TOOD 高 1.9%,较 YOLOv5n 低 0.1%,较 YOLOX 高 0.5%。然而,

YOLOv3 参数量和计算量较大,训练时间长,难以满足资源受限的环境;YOLOv7-tiny 为 YOLOv7 中最小的版本,其参数量较 YOLOv5n 低 1 M,但 mAP50 表现一般,且计算量较高;YOLOv8n 在轻量化方面有所改进,其 mAP50 较 YOLOv5n 高 1.5%,参数量低 4 M;YOLOv9-tiny 进一步优化了参数量,较 YOLOv8n 低 1.04 M;尽管 YOLOv10n 相较 YOLOv9-tiny 参数量高 0.3 M,但其计算量低 4.2 GFLOPs,综合性能优于 YOLOv9-tiny,本文所选用的 YOLOv10n 算法在检测精度、计算量与参数量方面均表现最优,模型参数量仅有 2.27 M,检测精度达到 89.9%。

RFCARep-YOLOv8n、BCS-YOLOv8 与本文算法在 PVEL-AD 光伏电池缺陷数据集上的实验结果表明,RFCARep-YOLOv8n 虽参数量较低为 3.23 M,但其 mAP50 仅为 0.876,计算量为 8.2 GFLOPs,与本文算法相比性能表现有限;BCS-YOLOv8 的 mAP50 较高为 0.932,

仅比本文算法高 0.3%,但其计算量却达到 20.5 GFLOPs,且参数量高达 12.30 M,模型复杂度显著增加,相比之下,本文所改进的 YOLOv10n 算法,不仅检测精度与速度均优于 RFCARep-YOLOv8n,同时在模型轻量化上显著优于 BCS-YOLOv8,较基线算法检测精度提高了 3.0%,参数量减少了 0.08 M,计算量降低了 0.7 GFLOPs,综合性能指标满足光伏电池缺陷检测的需求。

本文改进的 YOLOv10n 算法较基线算法 mAP50 提高了 3.0%,参数量减少了 0.08 M,计算量降低 0.7 GFLOPs,验证了本文改进算法的有效性。

3.8 实验结果与可视化分析

为直观地分析改进算法的效果,实验展示了部分检测对比结果和可视化分析,如图 8(a)~(e)所示。图中从上至下各行分别展示星状裂纹缺陷、多类密集缺陷小目标、大目标类别缺陷、线状裂纹缺陷以及多尺度类别缺陷的检测对比效果。




图 8 改进模块检测对比效果

Fig. 8 Improved module detection and comparison effect

本文针对主干网络、颈部网络和损失函数进行优化。设计了 PMSFA_CSP、FPSC_SENetV2 和 FreqFP_FPN 模块,并引入 SESN 损失函数。实验数据表明,改进后的算法在漏检和误检以及检测精度方面均优于 YOLOv8n、YOLOv9-tiny 和 YOLOv10n。在星状裂纹、多类密集小目标和大目标类别缺陷检测方面,YOLOv8n 和 YOLOv9-tiny 表现出检测精度不足问题,且 YOLOv8n 将一处星状裂纹缺陷误检为线状裂纹缺陷;在线状裂纹重叠和多尺度类别缺陷检测中,YOLOv8n、YOLOv9-tiny 和 YOLOv10n 均存在不同程度的漏检。相比之下,本文改进后的算法成功检测了所有相关缺陷,且精度优于前 3 种算法。

由图 8 可视化分析数据显示,改进后的算法在第 1、2、3 行缺陷图像中,所有的类型均被成功检测,且检测精度优于 YOLOv8n、YOLOv9-tiny 和 YOLOv10n;在第 4 行中,改进算法有效弥补了 YOLOv10n 对线状裂纹缺陷检测的漏检和误检;在第 5 行中,改进算法对水平错位的检测精度较前三者均有提升,且误检率也有所改善。

相比原算法和其他先进算法,本文改进后的算法在星状裂纹、多类别小目标和线状重叠缺陷检测方面表现优异,有效减少了密集目标和小目标的误检和漏检现象,整体检测效果提升明显。

4 结 论

本文针对光伏电池缺陷检测中目标识别困难、漏检和误检率高的问题,提出了一种改进的 YOLOv10n 缺陷检测算法。设计 PMSFA_CSP 模块作为主干和颈部网络的部分特征提取模块,有效提升了网络的特征融合能力;设计 FPSC_SENetV2 模块,减少了局部信息丢失,增强网络对关键缺陷特征的捕捉能力;结合频率融合和多尺度特征聚合,设计 FreqFP_FPN 模块,进一步提升特征质量,减少了网络参数冗余;最后,构建 SESN 损失函数,优化模型的定位精度和收敛速度。实验结果表明,改进后的算法在光伏电池缺陷数据集上的 mAP@0.5 提高了 3.0%,计算量降低了 0.7 GFLOPs,参数量减少了 0.08 M,提高了缺陷检测精度。尽管如此,该模型在参数量方面仍有改进空间,未来的研究将进一步优化模型参数,以实现更高的检测精度和更低的计算复杂度。

参考文献

- [1] MAITY M, BANERJEE S, CHAUDHARI S S. Faster R-CNN and yolo based vehicle detection: A survey [C]. 2021 5th International Conference on Computing Methodologies and Communication (ICCMC). IEEE, 2021: 1442-1447.
- [2] CAI ZH W, VASCONCELOS N. Cascade R-CNN: High quality object detection and instance segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43 (5): 1483-1498.
- [3] QIAO S Y, CHEN L C, YUILLE A. Detectors: Detecting objects with recursive feature pyramid and switchable atrous convolution [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10213-10224.
- [4] WANG CH Y, YE H I, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]. European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2024: 1-21.
- [5] 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. EL image defect detection of photovoltaic cells based on improved lightweight U-Net model [J]. Electronic Measurement Technology, 2024, 47(5):102-111.
- [6] 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. Defect detection algorithm for photovoltaic cells based on RFCARep-YOLOv8n [J]. Computer Engineering and Applications, 2025, 61(3):131-143.
- [7] 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.
GUO J, HUANG Y J. Defect detection of photovoltaic solar cells based on improved YOLOv5 [J]. Combined Machine Tools and Automated Machining Technology, 2024(11):104-109.
- [8] 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. Photovoltaic cell defect detection algorithm based on reparameterization [J]. Electronic Measurement Technology, 2025, 48 (5): 184-192.
- [9] LIU G L, DUNDAR A, SHIH K J, et al. Partial convolution for padding, inpainting, and image synthesis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(5): 6096-6110.
- [10] HU J, LI SH, GANG S. Squeeze-and-excitation networks [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [11] NARAYANAN M. SENetV2: Aggregated dense layer for channelwise and global representations [J]. ArXiv preprint arXiv:2311.10807, 2023.

- [12] CHEN L W, FU Y, GU L, et al. Frequency-aware feature fusion for dense image prediction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 10763-10780.
- [13] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [14] GEVORGYAN Z. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv:2205.12740, 2022.
- [15] 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.
- [16] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [17] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision(ECCV), 2018: 3-19.
- [18] LAU K W, PO L M, REHMAN Y A U. Large separable kernel attention: Rethinking the large kernel attention design in cnn [J]. Expert Systems with Applications, 2024, 236: 121352.
- [19] 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.
- [20] YANG Z, WANG X, LI J. EIou: An improved vehicle detection algorithm based on vehiclenet neural network[J]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1924(1): 012001.
- [21] HAO ZH, ZHANG SH J. Shape-IoU: More accurate metric considering bounding box shape and scale[J]. ArXiv preprint arXiv:2312.17663, 2023.
- [22] FENG C, ZHONG Y, GAO Y, et al. Toood: Task-aligned one-stage object detection [C]. 2021 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE Computer Society, 2021: 3490-3499.
- [23] 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 defect detection algorithm of photovoltaic cells with YOLOv8 [J]. Electronic Measurement Technology, 2025, 48(1): 92-99.

作者简介

王海群, 副教授, 硕士, 主要研究方向为智能控制与应用、深度学习。

E-mail: wanghq0604@163.com

武泽锴(通信作者), 硕士研究生, 主要研究方向为图像处理、目标检测。

E-mail: 1270518284@qq.com

于海峰, 博士, 主要研究方向为深度学习、图像处理。