

# 基于深度学习的太阳能电池板表面缺陷检测及分类

涂俊博, 曾佳林, 唐越新, 吴晨曦, 刘晓宇\*

四川大学机械工程学院, 四川 成都 610065

**摘要** 针对目前太阳能电池板缺陷检测中对小目标缺陷检测精度不高、分类不准的问题, 提出一种适用于小目标检测的改进轻量型 YOLOv5s 太阳能电池板缺陷检测模型。首先用 SiLU 激活函数替换原激活函数, 优化模型收敛速度, 增强其泛化性能; 其次使用 C3TR 模块和卷积块注意力模块重新优化主干特征采样结构, 提高模型对不同类型缺陷尤其是小目标缺陷的识别能力; 接着将内容感知特征重组引入到特征提取网络, 在不增加模型权重的同时提高检测精度和检测速率; 最后加入动态非单调损失函数 WIoUv3 来动态匹配预测框和真实框, 增强小目标数据集和噪声的鲁棒性。实验结果显示, 改进模型的平均精度均值(mAP@0.5)为 95.9%, 对大面积裂缝、星形缺陷的分类精度达到 98.0%, 检测速度达到 75.133 frame/s, 模型轻量化且检测快捷, 满足工业生产的需要。

**关键词** 深度学习; 太阳能电池; 内容感知特征重组; 注意力机制; C3TR

中图分类号 TM914.4; TP391.4

文献标志码 A

DOI: 10.3788/LOP241100

## Detection and Classification of Surface Defects on Solar Cell Panels Based on Deep Learning

Tu Junbo, Zeng Jialin, Tang Yuexin, Wu Chenxi, Liu Xiaoyu\*

School of Mechanical Engineering, Sichuan University, Chengdu 610065, Sichuan, China

**Abstract** To solve the problems of the low-accuracy detection or inaccurate classification of small target defects in solar cell panel defect detection, an improved lightweight YOLOv5s solar cell panel defect detection model suitable for small target detection is proposed in this study. First, an SiLU activation function is used to replace the original activation function to optimize the convergence speed and enhance the generalization ability of the model. Second, the C3TR and convolution block attention modules are used to re-optimize the backbone feature sampling structure to improve the recognition ability for different defect types, especially small target defects. Third, the content-aware re-assembly of features is realized in the feature extraction network to improve the detection accuracy and detection speed without increasing the model weight. Finally, a dynamic nonmonotonic loss function WIoUv3 is added to the dynamic matching prediction box and real frame to enhance the robustness of small target datasets and noise. Experimental results show that the mean average precision (mAP@0.5) of the proposed model is 95.9% and that its classification accuracies for large-area cracks and star-shaped scratches reach 98.0% and detection speed reaches 75.133 frame/s, demonstrating its lightweight nature and rapidness that meet the requirements of industrial production.

**Key words** deep learning, solar cell; content-aware reassembly of features; attention mechanism; C3TR

## 1 引言

2024 年《政府工作报告》指出:要积极稳妥推进碳达峰碳中和,加快建设新型能源体系,加强大型风电光伏基地和外送通道建设,促进绿电使用和国际互认<sup>[1]</sup>。在此背景下,“新三样”产品——电动汽车、锂电池、光

伏产品的出口总额首次突破万亿元大关。光伏产业已成为我国在全球最具竞争力和话语权的战略性新兴产业,其市场份额占全球总量的 70% 以上,成为我国高端制造的一面旗帜<sup>[2]</sup>。作为光伏产业的重要组成部分,太阳能电池的质量与生产效率受到广泛关注。然而,在生产、运输、安装及使用过程中,多种原因可能导

收稿日期: 2024-04-15; 修回日期: 2024-04-30; 录用日期: 2024-06-06; 网络首发日期: 2024-06-11

基金项目: 2024 年国家级大学生创新创业训练计划(202410610101)

通信作者: liuxiaoyu@scu.edu.cn

致太阳能电池板存在诸多缺陷,这些缺陷在影响电池板外观的同时,还会降低其光电转换效率和使用寿命<sup>[3]</sup>。因此,实现快速且准确的太阳能电池表面缺陷检测已成为当前研究的重点<sup>[4-7]</sup>。

杨瑞珍等<sup>[8]</sup>建立数字化电磁热成像检测系统,运用独立成分分析(ICA)、傅里叶变换和主成分分析(PCA)等方法对采集的热像图序列进行处理,实现对晶体硅光伏电池中大面积缺陷的可视化检测。但这种方法的准确率不高,且检测时间较长。

Acharya 等<sup>[9]</sup>对电致发光(EL)图像进行预处理,去除图中的噪声和畸变,并利用 Deep Siamese 卷积神经网络(CNN)对太阳能电池中存在的缺陷进行分类。然而,传统 CNN 在面对复杂的图像环境和多种缺陷时,其分类准确率较低,且时间成本高。周得永等<sup>[10]</sup>使用 YOLOv3 目标检测模型对采用 EL 得到的太阳能电池板图像进行缺陷检测,并对 YOLOv3 中的特征金字塔网络(FPN)进行替换,实现特征上下语义的多尺度融合,有效提升网络性能,但该操作会增加网络模型参数,降低模型的检测速率。

Huang 等<sup>[11]</sup>通过加权双向特征金字塔来分配不同的权重,从而平衡像素差异过大的特征信息,改进目标检测模型中的长期上下文注意力(LCA)机制,提高检测精度,但该方法对小目标的检测效果较差,且容易出现漏检和错检现象。Yang 等<sup>[12]</sup>提出一种基于图像预处理和改进 VGG-19 网络的轻量级太阳能电池板故障诊断系统,引入卷积块注意力模块(CBAM)来提高系统对太阳能电池板缺陷检测的精度,但该系统只能检测特定背景与特定缺陷,对环境适应性不强。彭雪玲等<sup>[13]</sup>提出 Transformer 网络(CoT),可为小目标检测器提供特征前后文语义,并在检测头(Head)部分引入 CBAM 来提高模型的性能和鲁棒性,但算法的检测精度仍较低,且无法对多种缺陷进行准确分类。

基于上述问题,本文设计一种可同时检测多种小目标缺陷并实现精准分类、高精度、快速检测的太阳能电池板表面缺陷检测算法。该算法对目标检测算法模型再次进行优化与测试,大幅度提升检测精度,实现检测目标,可满足工业检测要求,为太阳能电池的生产质量控制提供新的解决方案。

## 2 YOLOv5s 目标检测模型

目前常用的目标检测算法包括一阶段和二阶段的检测算法。二阶段的检测算法是预先给出一些候选的目标检测框,再对候选框进行筛选处理获得最后的目标框,RCNN(Region-CNN)系列的算法属于二阶段的目标检测算法。一阶段的检测算法则不需要目标候选阶段,它直接产生目标位置的坐标及其类别和概率,其中代表算法是 YOLO 系列算法。经过连续优化,YOLOv5 已成为工业领域采用最广泛的先进算法<sup>[14]</sup>。如图 1 所示,YOLOv5s 网络包括 5 大核心部分:输入

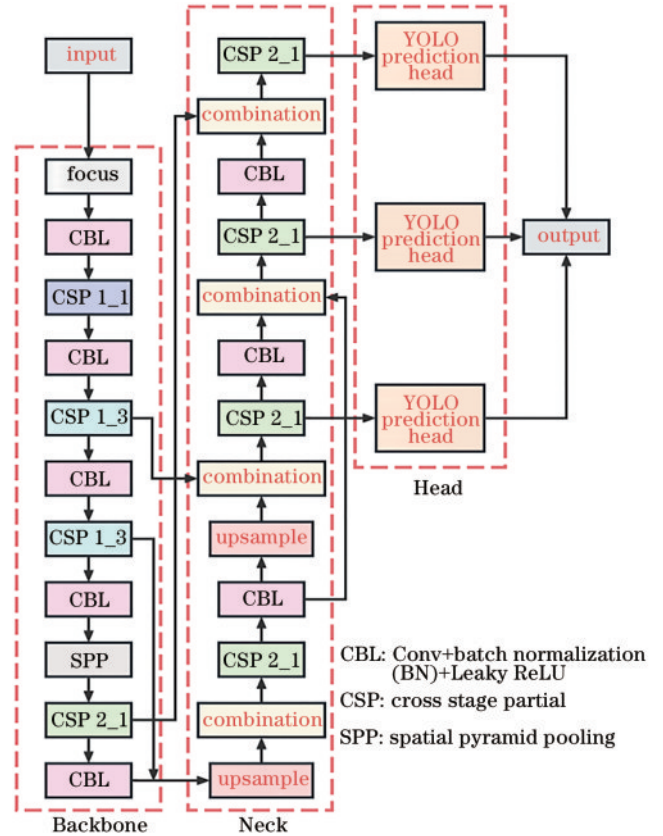


图 1 YOLOv5s 网络结构

Fig. 1 Structure of YOLOv5s network

端、主干特征提取网络(Backbone)、增强特征融合网络(Neck)、Head 和输出端。

YOLOv5s 采用 3 种数据增强技术进行设计,包括缩放、色彩空间调整和数据集增强。在数据集增强技术中,系统随机抽取 4 张图像,以自适应缩放、编辑、分布等方式增强小目标特征表达,提升算法对小目标的检测效果。为提高模型的性能,在 YOLOv5s 结构中引入两个 CSP 结构,CSP 1\_X 结构排列在 Backbone 部分,Neck 部分应用 CSP 2\_X 结构,进一步增强特征的融合能力。

## 3 改进的 YOLOv5s 目标检测模型

在通用目标检测中,所有目标的权重均相同。但在太阳能电池板的检测中,各种缺陷之间存在重要性差异,且缺陷之间具有关联性,往往一张图像可能出现多个类型的缺陷<sup>[15]</sup>。因此,为实现对太阳能电池板的小目标、多种类缺陷的高精度、轻量化检测与分类,对现有模型算法进行改进和优化,改进后的网络结构如图 2 所示。

### 3.1 激活函数

传统 YOLOv5s 网络一般使用 Leaky ReLU 作为激活函数。作为 ReLU 的迭代函数,Leaky ReLU 在输入信息特征小于 0 时仍可输出一个有限小量,而不是直接输出 0。这种函数可减少神经元学习中的部分特

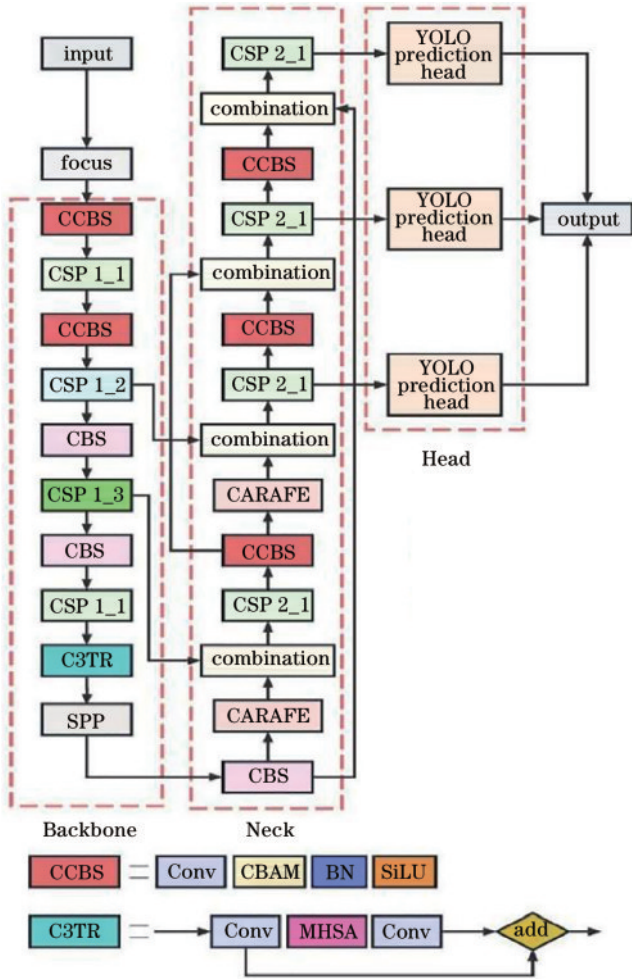


图 2 改进后的网络结构

Fig. 2 Structure of improved network

征缺失,提高模型的适应性。Leaky ReLU 激活函数的表达式为

$$f(x) = \begin{cases} x, & x \geq 0 \\ \lambda x, & x < 0 \end{cases} \quad (1)$$

式中  $\lambda \in (0, 1)$  为斜率参数,通常取值为 0.01 或 0.05。

但 Leaky ReLU 在用于太阳能电池板缺陷检测时,由于梯度消失和梯度爆炸问题,模型的训练速度较慢,检测精度不高<sup>[16]</sup>。因此选择 SiLU 激活函数<sup>[17]</sup>替换 Leaky ReLU 激活函数,在零点附近, SiLU 激活函数具有更均匀的性质和可导性,对梯度计算和更新、加速模型的收敛非常有帮助。此外, SiLU 还引入许多非线性属性从而进一步提高模型的泛化性能,这对提升缺陷检测模型准确度非常有帮助。SiLU 激活函数的表达式为

$$f(x) = \frac{x}{(1 + e^{-x})} \quad (2)$$

### 3.2 主干特征上采样网络

在 YOLOv5s 的特征网络中运用最近邻插值进行上采样。但最近邻插值依赖像素点的空间位置来确定采样点,只关注亚像素级别的相邻像素,未能充分利用特征图的神经元信息,且忽视密集检测场景中至关重要的语义信息(密集检测场景指场景中大量微小物体目标或大量无效信息干扰)。这一过程经常导致图像灰度值不连续和图像质量下降,从而影响网络对微小物体目标的检测能力<sup>[18]</sup>。

轻量级内容感知特征重组 (CARAFE)<sup>[19]</sup> 结构如图 3 所示,其中  $H$  和  $W$  为输入特征垂直和水平方向的维度,  $C$  为通道数,  $C_m$  为压缩后的通道数,  $X$  为输入特征图,  $N(x_1, k_{up})$  表示以位置  $x_1$  为中心的  $k_{up} \times k_{up}$  采样子区域,  $\varphi$  为上采样率,  $X'$  为输出特征图,  $w_1$  为预测上采样核。首先根据每个表达特征来确定目标位置,采用内容感知算法感知目标内容预测一个重组核,之后将

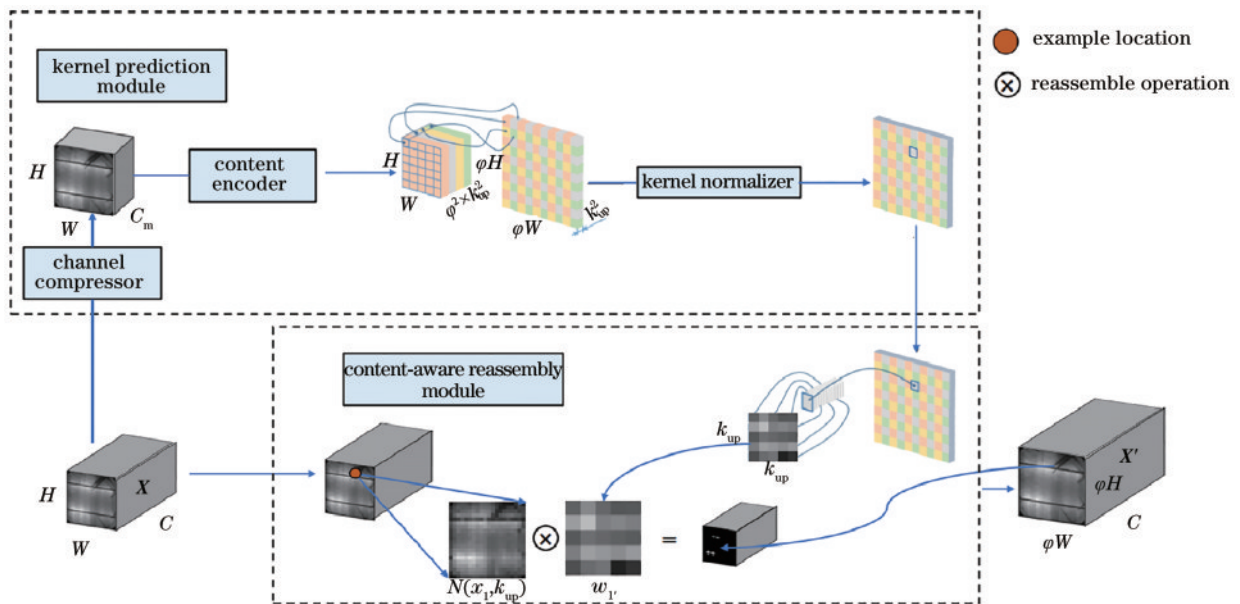


图 3 CARAFE 结构

Fig. 3 Structure of CARAFE

预测的核进行特征重组,并将生成的重组对象利用加权组合聚合成更大的空间区域。将该区域视为由多个特征点组成的空间簇,这种重组可将多个特征点的信息汇聚到一起,从而提供更多的目标信息,可提高模型对地图中微小目标的检测能力。由于空间簇提供了更多的信息,算法可更准确地定位和描述目标的位置和形状,从而优化对亚像素级目标的检测。在分层对象架构中,CARAFE可便捷地以2倍的频率对对象地图进行采样,具有最小的冗余、强大的对象集成能力和高效的运行机制,可轻松集成到现有结构中取代近邻插值,无需额外改动。CARAFE结构可提高目标检测的精确度和召回率,特别是对于小目标或低分辨率的图像。因此,将CARAFE结构运用到太阳能电池板缺陷检测算法中可使模型轻量化并提高模型检测准确性。

### 3.3 主体网络 C3TR 模块

在原始的YOLOv5s模型中,C3模块在结构上具有至关重要的作用,Backbone和Neck部分均采用CSP架构。尽管两部分的CSP架构在修正单元的选择上存在差异,但其核心构成均包含3个标准卷积层,其数量由配置文件yaml中的*n*和depth\_multiple参数共同决定。这一模块是学习和提取残差特征的关键组成部分,其结构一分为二,一支由多个指定的Bottleneck堆叠而成,另一支则仅通过一个基础卷积模块进行处理。最终,对这两支路径的输出进行Concat操作,以融合不同路径的特征信息。

为进一步提升模型的特征表达能力和检测精度,引入Bottleneck Transformer模块来替换Backbone网络中原有的C3模块,从而形成C3TR<sup>[20]</sup>模块,结构如图4所示。作为C3模块的变体,C3TR模块在保持原有结构的基础上,引入Transformer Block来替换原有的Bottleneck结构。

C3TR模块的关键结构组件包括:包含多个卷积层

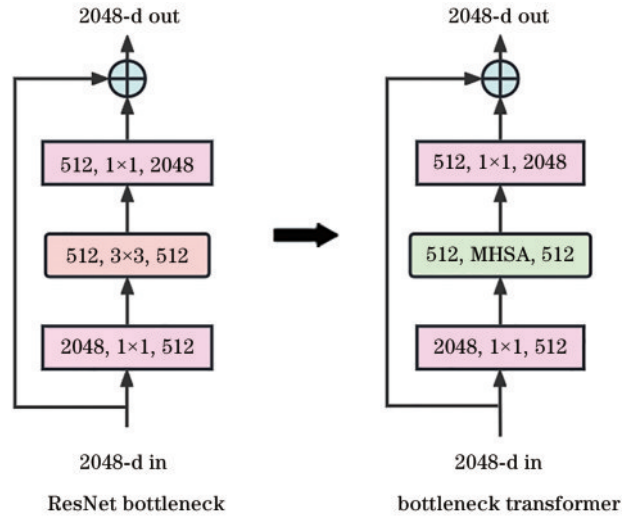


图4 C3TR改进模块结构

Fig. 4 Structure of C3TR improved module

的卷积块,用于从输入数据中提取关键特征信息;CSP连接将前一层特征图的部分信息与当前层的特征图进行相加,从而增强模型的特征表达能力;SPP在不同的空间尺度上提取特征信息,进一步增强模型的特征检测能力;Concatenation层将来自不同路径和尺度的特征信息进行拼接,以生成包含更丰富信息的最终特征图。通过引入C3TR模块,太阳能电池板缺陷检测模型的特征读取能力和检测精度得到显著提升。

### 3.4 注意力机制

在处理多特征目标和复杂场景时,由于通用目标检测对所有目标的权重相同,可加入注意力机制来增强模型对特征的重要性识别能力。结合CBAM<sup>[21]</sup>的CNN在工业生产中具有较高的准确率和较好的性能,将CBAM(图5)添加到Backbone和Head之中,使模型能更好地表达图像中重要的特征信息,提高检测的准确性。




图5 CBAM结构

Fig. 5 Structure of CBAM

CBAM将通道注意力(图6)与空间注意力(图7)相结合,可对特征图的通道进行加权调整并改变特征的空间位置,从而生成较合理的权重分布。使用CBAM检测太阳能电池缺陷具有明显优势,CBAM的

聚焦机制可对关键特征进行重复表达,同时抑制背景信息等中间因素的影响。其中:通道注意力机制通过测量不同通道之间的特征来提高模型对不同通道独特特征的理解度;空间注意力机制通过对不同空间位置




图 6 通道注意力原理

Fig. 6 Principle of channel attention




图 7 空间注意力原理

Fig. 7 Principle of spatial attention

的特征进行加权运算来提高模型对不同空间位置的识别能力。

通道注意力、空间注意力机制的计算公式为

$$\text{Channel Attention}(\mathbf{X}) = \sigma \left[ \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W F_{i,j}(\mathbf{X}) \right] \quad (3)$$

$$\text{Spatial Attention}(\mathbf{X}) = \sigma \left[ F_{\text{avg}}(\mathbf{X}) F_{\text{max}}(\mathbf{X}) \right] \quad (4)$$

式中： $\sigma$ 为激活函数； $F_{i,j}(\mathbf{X})$ 为输入特征结构位置的特征； $F_{\text{avg}}(\mathbf{X})$ 为输入特征图 $\mathbf{X}$ 经过全局平均池化的结果； $F_{\text{max}}(\mathbf{X})$ 为最大池化结果。

这种注意力机制可捕捉缺陷的上下文语义信息，使模型聚焦关键特征区域，从而提高模型对不同类型缺陷尤其是微小目标的识别能力。CBAM能更好地挖掘出图像中重要的特征信息，减少冗余信息的干扰，从而带来更优秀的性能。因此，该模块将提高模型的故障检测率，减少误检和漏检，从而为光伏电池的生产、运输和使用提供更强的质量控制和维护辅助。

### 3.5 损失函数

边界框损失函数是目标检测的重要组成部分，其良好的定义将提升目标检测模型的性能。利用交并比(IoU)来评估预测值与真实值之间的距离，经过多次迭代产生多个变种IoU，如广义交并比(GIoU)、距离交并比(DIoU)、完全交并比(CIoU)。YOLOv5s中采用GIoU作为边界框的损失函数，可计算预测框和真实框之间的交叉面积：

$$R_{\text{IoU}} = \frac{|\mathbf{A} \cap \mathbf{B}|}{|\mathbf{A} \cup \mathbf{B}|} \quad (5)$$

$$R_{\text{GIoU}} = R_{\text{IoU}} - \frac{|A_c - U|}{|A_c|} \quad (6)$$

式中： $\mathbf{A}$ 为预测框； $\mathbf{B}$ 为真实框； $A_c$ 为能同时包含预测框和真实框的最小矩形框的面积； $U$ 为预测框和真实框的并集。DIoU和CIoU的计算公式分别为

$$R_{\text{DIoU}} = 1 - R_{\text{IoU}} + \frac{\rho^2(\mathbf{b}, \mathbf{b}_{\text{gt}})}{c^2} \quad (7)$$

$$R_{\text{CIoU}} = 1 - R_{\text{IoU}} + \frac{\rho^2(\mathbf{b}, \mathbf{b}_{\text{gt}})}{c^2} + \alpha v \quad (8)$$

$$v = \frac{4}{\pi^2} \left( \arctan \frac{w_{\text{gt}}}{h_{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (9)$$

式中： $\mathbf{b}$ 为预测框的几何中心位置； $\mathbf{b}_{\text{gt}}$ 为标注框的几何中心位置； $\rho$ 为两个点之间的空间距离； $c$ 为最小矩形(能够同时包含预测框和标注框)的对角线距离； $\alpha$ 为特征权重函数； $v$ 为宽高比一致性参数； $w$ 、 $h$ 分别为预测框的宽、高； $w_{\text{gt}}$ 、 $h_{\text{gt}}$ 分别为真实框的宽、高。

为获得更准确的边界框回归(BBR)和目标检测，增强小目标数据集和噪声的鲁棒性，研究选择动态非单调聚焦机制，将Wise-IoUv3(WIoUv3)<sup>[22]</sup>引入网络中，结果表明该模块的引入可大幅度提高模型的检测精度。动态非单调聚焦机制使用“离群度”来评估预测框的质量，并采用可自动优化的梯度分配策略，除了能减少高质量锚架的竞争外，还能减少与低质量锚架相

关的低等级梯度,这使得 WIoUv3 能专注于常见目标的锚架,并提高检测器的检测效率。第一代 WIoU 的损失函数计算公式为

$$L_{\text{WIoUv1}} = R_{\text{WIoU}} L_{\text{IoU}} \quad (10)$$

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

式中: $x, y$ 分别为预测框中心点的坐标值; $x_{\text{gt}}$ 和 $y_{\text{gt}}$ 分别为真实框中心点的坐标值; $W_g$ 和 $H_g$ 分别为两框最小外接矩形框的宽、高;\*为将 $W_g$ 和 $H_g$ 从计算图中分离出来的操作过程; $R_{\text{WIoU}} \in [1, e]$ 用来显著放大普通质量锚框的 $L_{\text{IoU}}$ ; $L_{\text{WIoUv1}} \in [0, 1]$ 用来显著放大普通质量锚框的 $L_{\text{IoU}}$ ,降低高质量锚框的 $R_{\text{WIoU}}$ ,并且当锚框与目标框重合良好时,它更注重中心点之间的距离。

锚框的离群度用单调聚焦系数( $L_{\text{IoU}}^*$ )与 $L_{\text{IoU}}$ 的滑动平均值( $\overline{L_{\text{IoU}}}$ )的比值表示:

$$\beta = \frac{L_{\text{IoU}}^*}{\overline{L_{\text{IoU}}}} \quad (12)$$

式中: $\beta \in [0, +\infty)$ 。锚框的质量可通过其离群度的大小进行衡量,离群度较小通常意味着锚框的质量较高。为提升训练效果,对高质量的锚框分配较小的梯度增益,使 BBR 更关注质量一般的锚框。当锚框的离群度达到预设常数时,将接收到最大的梯度增益。动态的分配机制使 WIoUv3 能动态计算最适合当前情境的梯度增益分配策略<sup>[23]</sup>。WIoUv3 通过优化对低质量和高

质量锚框的调整力度,运用动态非单调焦点机制来降低低质量样本的影响,从而更好地保留多尺度特征信息<sup>[24]</sup>。

## 4 实验结果与分析

### 4.1 实验配置

为确保实验数据的准确性,所有实验的环境配置如表 1 所示。

表 1 实验环境配置

Table 1 Experimental environment configuration

Parameter	Configuration
Operating system	Windows 11
GPU	NVIDIA GeForce RTX 4060
Memory	8 GB
Python	3.8.19
Deep learning framework	PyTorch 2.2

### 4.2 数据集准备与预处理

对于深度学习而言,数据集的质量往往决定着检测精度的上限,因此制作太阳能电池板数据集是实验开始前最重要的步骤。实验采用的数据集为实验室通过拍摄处理得到的太阳能电池板缺陷图片,初始图片数量为 1440 张,主要针对裂缝缺陷和边缘上的微小目标缺陷进行识别与分类。如图 8 所示,数据集中共包含 5 类缺陷,分别是星形缺陷(578 张)、边缘星形缺陷




图 8 裂缝缺陷分类。(a)边缘细微缺陷;(b)大面积裂缝缺陷;(c)边缘斜角缺陷;(d)星形缺陷;(e)边缘星形缺陷

Fig. 8 Classification of crack defects. (a) Edge fine defect; (b) large area crack defect; (c) edge bevel defect; (d) star-shaped defect; (e) edge star-shaped defect

(150 张)、边缘斜角缺陷(244 张)、大面积裂缝缺陷(216 张)、边缘细微缺陷(252 张)。其中微小目标缺陷占比为 84%，经过亮度调节、图片旋转、切割等方法按 1:1.5 扩充共得到 2160 张图片，按照训练集、验证集、测试集的数量比为 8:1:1 进行随机分配，用 Labelimg 标注工具进行标注。使用精确度( $P$ )、召回率( $R$ )、平均精度均值( $mAP@0.5$ )、检测速度(FPS)、模型权重数量(Params)作为评估指标。

### 4.3 实验结果

在完成太阳能电池板数据集制作后，选择 YOLOv5s 模型作为目标基准检测模型。图 9 为对 YOLOv5s 模型检测结果的各项指标进行评估的结果，图 10 为对太阳能电池部分数据集的检测结果。由图 9 可知，在训练次数超过 300 后各项指标(损失值、 $mAP@0.5$ 、精确率、召回率)趋于稳定。因此，将所有模型的训练次数统一为 300。

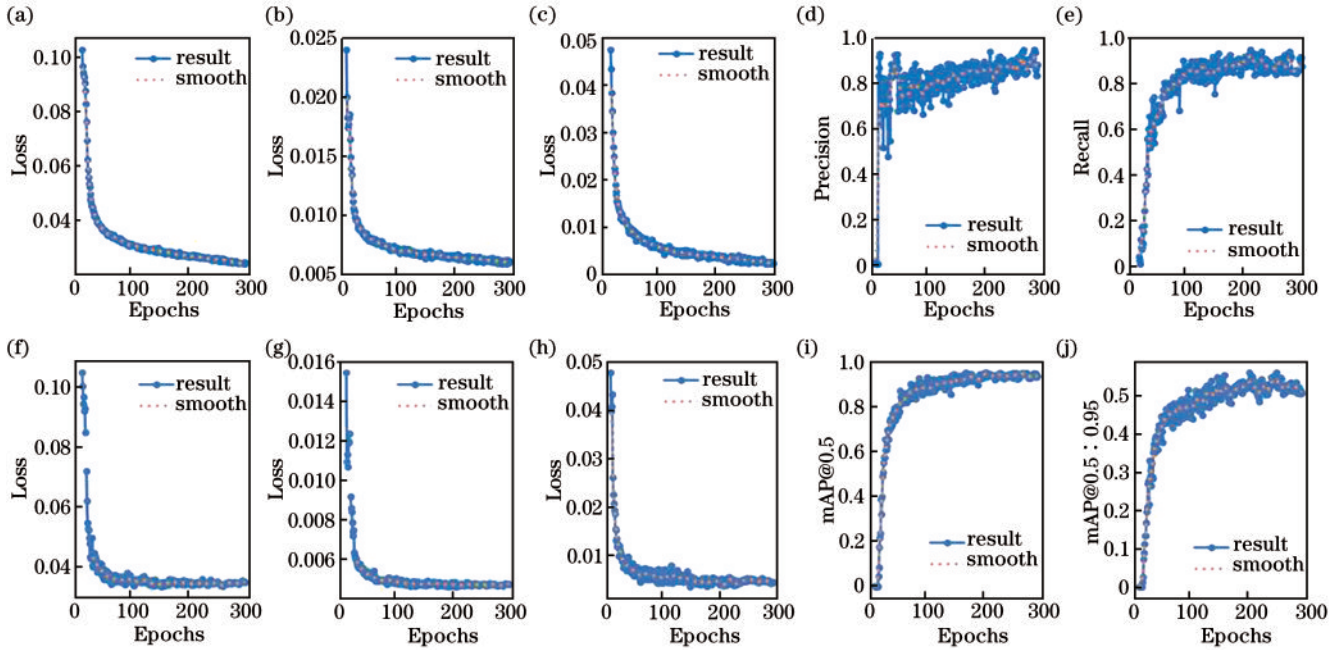


图 9 YOLOv5s 模型用于太阳能电池数据集的训练结果。(a) 训练集中边界框损失；(b) 训练集中置信度损失；(c) 训练集中分类损失；(d) 精确度；(e) 召回率；(f) 验证集中边界框损失；(g) 验证集中置信度损失；(h) 验证集中分类损失；(i)  $mAP@0.5$ ；(j)  $mAP@0.5:0.95$

Fig. 9 Training results of YOLOv5s model for solar cell dataset. (a) Boundary box loss in training set; (b) confidence loss in training set; (c) classification loss in training set; (d) precision; (e) recall; (f) boundary box loss in validation set; (g) confidence loss in validation set; (h) classification loss in validation set; (i)  $mAP@0.5$ ; (j)  $mAP@0.5:0.95$

YOLOv5s 在经过 300 次训练后，检测缺陷的  $mAP@0.5$  达到 89.1%，但精确度(84.6%)和召回率(94.0%)相对较低。

### 4.4 消融实验

为验证所提模型的各环节改进效果，设计如表 2 所示的消融实验。序号 1 表示原 YOLOv5s 模型，序号 2

表示采用 SiLU 激活函数，序号 3 表示在序号 2 的基础上增加 CBAM，序号 4 表示在序号 3 的改进上将主干网络的 C3 模块替换为改进后的 C3TR 模块，序号 5 表示在序号 4 的改进上将主干特征上采样网络改为 CARAFE 轻量采样算子，序号 6 表示在序号 5 的改进上引入 WIoUv3 损失函数生成最后的改进模型。由表 3

表 2 消融实验设计  
Table 2 Ablation experimental design

Serial number	YOLOv5s	SiLU	CBAM	C3TR	CARAFE	WIoUv3
1	✓					
2	✓	✓				
3	✓	✓	✓			
4	✓	✓	✓	✓		
5	✓	✓	✓	✓	✓	
6	✓	✓	✓	✓	✓	✓

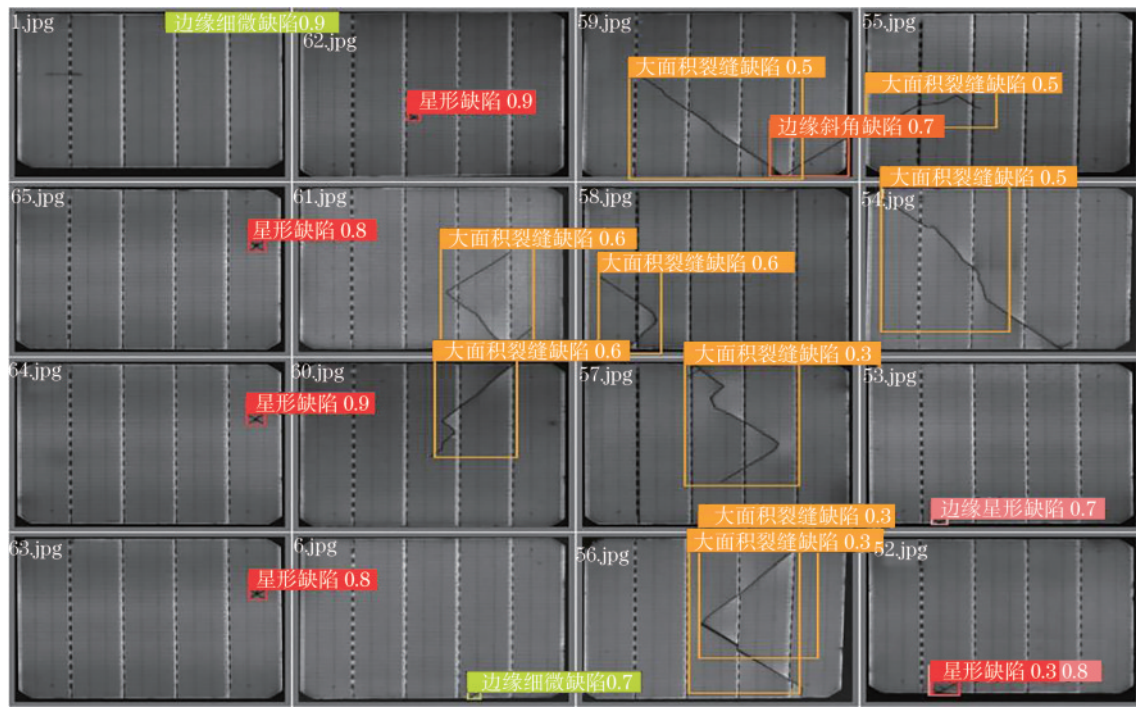


图 10 YOLOv5s 模型用于太阳能电池数据集的检测结果  
 Fig. 10 Detection results of YOLOv5s model for solar cell dataset

表 3 消融实验结果  
 Table 3 Results of ablation experiments

Serial number	$P / \%$	$R / \%$	mAP@0.5 / %	FPS / (frame · s <sup>-1</sup> )	Params / 10 <sup>6</sup>
1	84.6	94.0	89.1	114.746	6.97
2	86.8	95.0	90.0	120.645	7.02
3	81.4	98.0	93.8	97.171	7.26
4	86.1	97.0	94.9	89.044	8.11
5	84.5	97.0	95.7	75.412	8.25
6	89.7	98.0	95.9	75.133	8.25

可知,序号 6 即所提模型(简称 YOLOv5s-CW)的精确度、召回率和 mAP@0.5 达到最大,且检测速度相较于基准模型大幅度降低。

#### 4.5 算法性能对比实验

使用相同的数据集和环境配置,将所提模型与当

前主流的太阳能电池板缺陷检测模型 YOLOv5s、YOLOv5n、YOLOv8s、YOLOv8m+GAMAttention、YOLOv5s+CBAM+CTR3+WIOUv3+Decoupled\_Detect(简称 YOLOv5s-cc)进行对比实验,实验结果如表 4 所示。

表 4 不同模型的实验结果对比  
 Table 4 Comparison of experimental results for different models

Model	$P / \%$	$R / \%$	mAP@0.5 / %	FPS / (frame · s <sup>-1</sup> )	Params / 10 <sup>6</sup>
YOLOv5n	89.6	95.0	87.2	80.330	1.76
YOLOv8s	87.9	98.0	88.9	78.125	11.12
YOLOv8m+GAMAttention	83.9	95.0	93.0	36.630	29.94
YOLOv5s	84.6	94.0	89.1	114.746	6.97
YOLOv9	76.7	74.5	85.0	42.880	15.51
YOLOv5s-cc	85.3	95.0	92.1	64.065	13.69
YOLOv5s-CW	89.7	98.0	95.9	75.133	8.25



从对比实验结果可以看出:所提模型的 mAP@0.5 比原 YOLOv5s 模型提高 6.8 个百分点,比目前效果最好的 YOLOv8m+GAMAttention 提高 2.9 个百分点,达到 95.9%;在保证检测速度的同时,所提模型较轻量化。所提模型对各类小目标缺陷检测的精度均较高,星形缺陷检测精度为 99.5%、边缘星形缺陷检测精度为 99.5%、边缘斜角缺陷检测精度为 97.3%、大面积裂缝缺陷检测精度为 98.2%、边缘细微缺陷检测精度为 85.0%,实验证明了改进模型对小目标缺陷检测的有效性。

## 5 结 论

提出一种适用于小目标检测的改进轻量化 YOLOv5s 的太阳能电池板缺陷检测模型。首先使用 SiLU 激活函数替换 Backbone 中的激活函数,从而加速模型的收敛,提高模型的泛化能力;其次使用 C3TR 模块和 CBAM 重新优化主干特征采样结构,提高模型对图像中重要特征信息的显性表达,可将更多的神经元用于关键特征识别,从而提高模型对不同类型缺陷尤其是小目标缺陷的识别能力,因此,该模块有助于提高缺陷的识别率和减少错检漏检;接着将轻量采样算子 CARAFE 引入特征提取网络,在不增加模型权重的同时提高检测精度和检测速率;最后改进损失函数,损失函数是模型分类与定位的关键,动态非单调损失函数 WIoUv3 可自适应动态匹配预测框和真实框,动态优化预测框的位置,从而提高缺陷检测的精度和鲁棒性。通过多个对比消融实验,改进模型的 mAP@0.5 为 95.9%,相比原 YOLOv5s 模型提高 6.8 个百分点,改进效果显著。改进模型对大面积裂缝、星形缺陷的检测精度超过 98%,检测速度达到 75.133 frame/s,整体而言模型轻量且快捷,满足工业生产的需要,可为太阳能电池板生产、运输、使用过程中的质量控制和维修提供更有力的帮助。

## 参 考 文 献

- [1] 李贝贝, 何一华. 向阳生长·逐光而行[N]. 华夏时报, 2024-03-25(14).  
Li B B, He Y H. Growing towards the sun, chasing the light[N]. China Times, 2024-03-25(14).
- [2] 白宇. 光伏产业已成为我国高端制造的一面旗帜[N]. 中国电力报, 2024-03-11(2).  
Bai Y. Photovoltaic industry has become a banner of high end manufacturing in China[N]. China Electric Power News, 2024-03-11(2).
- [3] 周得永. 基于电致发光太阳能电池板缺陷检测系统设计[D]. 扬州: 扬州大学, 2022.  
Zhou D Y. Design of defect detection system based on electroluminescent solar panel[D]. Yangzhou: Yangzhou University, 2022.
- [4] Song X Y, Yang L, Xia X H, et al. Defect detection method for solar cells based on human visual characteristics[C]//2020 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE), December 25-27, 2020, Harbin, China. New York: IEEE Press, 2020: 515-518.
- [5] Fu Y Z, Ma X L, Zhou H. Automatic detection of multi-crossing crack defects in multi-crystalline solar cells based on machine vision[J]. Machine Vision and Applications, 2021, 32(3): 60.
- [6] El-Rashidy M A. An efficient and portable solar cell defect detection system[J]. Neural Computing and Applications, 2022, 34(21): 18497-18509.
- [7] Zhang P Y, Hou W, Wu D, et al. Real-time detection of small targets for video surveillance based on MS-YOLOv5[C]//2023 6th International Conference on Artificial Intelligence and Big Data (ICAIBD), May 26-29, 2023, Chengdu, China. New York: IEEE Press, 2023: 690-694.
- [8] 杨瑞珍, 杜博伦, 何赞泽, 等. 晶体硅光伏电池电磁感应激励红外热辐射缺陷检测与成像技术[J]. 电工技术学报. 2018, 33(s2): 321-330.  
Yang R Z, Du B, He Y Z, et al. Infrared radiation defect detection and imaging technique under active electromagnetic induction excitation for crystalline silicon photovoltaic cells[J]. Transactions of China Electrotechnical Society, 2018, 33(s2): 321-330.
- [9] Acharya A K, Sahu P K, Jena S R. Deep neural network based approach for detection of defective solar cell[J]. Materials Today: Proceedings, 2021, 39: 2009-2014.
- [10] 周得永, 高龙琴. 基于 YOLOv3 的太阳能电池板缺陷检测[J]. 南方农机, 2022, 53(4): 142-144.  
Zhou D Y, Gao L Q. Solar panel defect detection based on YOLOv3[J]. China Southern Agricultural Machinery, 2022, 53(4): 142-144.
- [11] Huang J, Zeng K Y, Zhang Z J, et al. Solar panel defect detection design based on YOLO v5 algorithm[J]. Heliyon, 2023, 9(8): e18826.
- [12] Yang X Y, Zhang Q, Wang S Y, et al. Detection of solar panel defects based on separable convolution and convolutional block attention module[J]. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, 2023, 45(3): 7136-7149.
- [13] 彭雪玲, 林珊玲, 林志贤, 等. 改进的 YOLOv5s 太阳能电池片缺陷检测算法[J]. 液晶与显示, 2024, 39(2): 237-247.  
Peng X L, Lin S L, Lin Z X, et al. Defect detection algorithm of improved YOLOv5s solar cell[J]. Chinese Journal of Liquid Crystals and Displays, 2024, 39(2): 237-247.
- [14] 李婷, 孙渊. 基于改进轻量化 YOLOv5 的太阳能电池板缺陷检测[J]. 组合机床与自动化加工技术, 2023(11): 95-99, 106.  
Li T, Sun Y. Defect detection of solar panels based on improved lightweight YOLOv5[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2023(11): 95-99, 106.
- [15] 王新宇, 蒋三新. 芯片缺陷检测综述[J]. 现代制造技术与装备, 2022, 58(5): 94-98.  
Wang X Y, Jiang S X. Overview of chip defect detection [J]. Modern Manufacturing Technology and Equipment,

- 2022, 58(5): 94-98.
- [16] 王淑青, 张鹏飞, 要若天, 等. 基于改进 YOLOv5 的太阳能电池片表面缺陷检测[J]. 仪表技术与传感器, 2022(5): 111-116.  
Wang S Q, Zhang P F, Yao R T, et al. Surface defect detection of solar cell based on improved YOLOv5[J]. Instrument Technique and Sensor, 2022(5): 111-116.
- [17] 张光华, 李聪发, 李钢硬, 等. 基于改进 YOLOv7-tiny 的无人机航拍图像小目标检测算法[J/OL]. 工程科学与技术: 1-14[2024-04-10]. <https://doi.org/10.15961/j.jsuese.202300593>.  
Zhang G H, Li C F, Li G Y, et al. Small target detection algorithm for UAV aerial images based on improved YOLOv7-tiny[J/OL]. Engineering Science and Technology: 1-14[2024-04-10]. <https://doi.org/10.15961/j.jsuese.202300593>.
- [18] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 3-19.
- [19] Zhang L H, Xiong N, Gao W Y, et al. Improved detection method for micro-targets in remote sensing images[J]. Information, 2024, 15(2): 108.
- [20] 刘思远. 基于改进 YOLOv5s 的太阳能电池缺陷检测算法[D]. 大庆: 东北石油大学, 2023.  
Liu S Y. Solar cell defect detection algorithm based on improved YOLOv5s[D]. Daqing: Northeast Petroleum University, 2023.
- [21] Wang J Q, Chen K, Xu R, et al. CARAFE: content-aware ReAssembly of FEatures[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Republic of Korea. New York: IEEE Press, 2019: 3007-3016.
- [22] Tong Z J, Chen Y H, Xu Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[EB/OL]. (2023-01-24)[2024-04-10]. <https://arxiv.org/abs/2301.10051>.
- [23] 石洋宇, 左景, 谢承杰, 等. 多尺度融合与FMB改进的YOLOv8异常行为检测方法[J]. 计算机工程与应用, 2024, 60(9): 101-110.  
Shi Y Y, Zuo J, Xie C J, et al. Improved YOLOv8 method for anomaly behavior detection with multi-scale fusion and FMB[J]. Computer Engineering and Application, 2024, 60(9): 101-110.
- [24] 许永华, 唐鹤卿, 肖伸平. 基于改进 YOLOv5s 的输电线路异物检测[J]. 电工技术, 2023(21): 54-57, 62.  
Xu Y H, Tang H Q, Xiao S P. Improved YOLOv5s-based detection of foreign objects in transmission lines[J]. Electric Engineering, 2023(21): 54-57, 62.