

# 光电工程

## Opto-Electronic Engineering

中文核心期刊 中国科技核心期刊  
Scopus CSCD

### 基于YOLOv8优化改进的太阳能电池片缺陷检测模型

彭自然, 王思远, 肖伸平

#### 引用本文:

彭自然, 王思远, 肖伸平. 基于YOLOv8优化改进的太阳能电池片缺陷检测模型[J]. 光电工程, 2024, 51(11): 240220.

Peng Z R, Wang S Y, Xiao S P. A solar cell defect detection model optimized and improved based on YOLOv8[J]. *Opto-Electron Eng*, 2024, 51(11): 240220.

<https://doi.org/10.12086/oe.2024.240220>

收稿日期: 2024-09-16; 修改日期: 2024-11-04; 录用日期: 2024-11-04

### 相关论文

#### 局部和全局特征融合的太阳能电池片表面缺陷检测

陶志勇, 何燕, 林森, 易廷军, 张尧晟

光电工程 2024, 51(1): 230292 doi: 10.12086/oe.2024.230292

#### 无人机视角下的道路损伤检测算法MAS-YOLOv8n

王晓燕, 王禧钰, 李杰, 梁文辉, 牟建宏, 毕楚然

光电工程 2024, 51(10): 240170 doi: 10.12086/oe.2024.240170

#### 改进GBS-YOLOv7t的钢材表面缺陷检测

梁礼明, 龙鹏威, 卢宝贺, 李仁杰

光电工程 2024, 51(5): 240044 doi: 10.12086/oe.2024.240044

#### 基于改进YOLOv5s网络的斜拉桥拉索表面缺陷检测

王鹏峰, 李运堂, 黄永勇, 朱文凯, 林婕, 王斌锐

光电工程 2024, 51(5): 240028 doi: 10.12086/oe.2024.240028

更多相关论文见光电期刊集群网站 

 | 光电工程  
Opto-Electronic Engineering

<http://cn.ojournal.org/oe>



 OE\_Journal



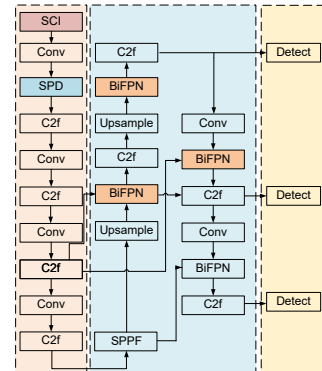
Website

# 基于 YOLOv8 优化改进的 太阳能电池片缺陷检测模型

彭自然<sup>1,2\*</sup>, 王思远<sup>1,2</sup>, 肖伸平<sup>1,2</sup>

<sup>1</sup>湖南工业大学电气与信息工程学院, 湖南 株洲 412007;

<sup>2</sup>湖南省电传动控制与智能装备重点实验室, 湖南 株洲 412007



**摘要:** 针对太阳能电池片缺陷检测中存在检测精度低、误检和漏检率高的问题, 本文在深度学习模型 YOLOv8 的基础上进行优化与改进, 提出了一种太阳能电池片电致成像 (electroluminescent, EL) 缺陷检测模型。首先, 采用自校准光照学习 (self-calibrated illumination, SCI) 方法对低光照图像进行预处理, 以增强太阳能电池片缺陷的有效特征信息。然后, 引入一个空间到深度的注意力模块 (space-to-depth, SPD), 替换主干网络的第二个跨步卷积层, 避免跨步卷积导致的信息丢失, 扩大感受野, 减少计算量, 从而在特征提取时保留更多特征信息。其次, 构建了空间双向要素金字塔网络 (spatial-BiFPN, S-BFPN), 通过多尺度特征融合, 解决因太阳能电池片缺陷形状多样性而造成缺陷识别率不稳定的问题。最后, 本文改进了损失函数, 使用 MPDIoU 作为损失函数, 解决了原有的 CIoU 损失函数中惩罚项失效的问题。实验结果显示, 改进后的 YOLOv8 模型的 mAP 达到了 96.9%, 比原始 YOLOv8 提升了 2.2%, 计算量减少了 0.2 GFlops, 检测速度最高达 155 f/s, 实现了高精度与高实时性, 更适合工业部署。

**关键词:** 深度学习; 太阳能电池片; 缺陷检测; YOLOv8

**中图分类号:** TP391

**文献标志码:** A

彭自然, 王思远, 肖伸平. 基于 YOLOv8 优化改进的太阳能电池片缺陷检测模型 [J]. 光电工程, 2024, 51(11): 240220

Peng Z R, Wang S Y, Xiao S P. A solar cell defect detection model optimized and improved based on YOLOv8[J]. *Opto-Electron Eng*, 2024, 51(11): 240220

## A solar cell defect detection model optimized and improved based on YOLOv8

Peng Ziran<sup>1,2\*</sup>, Wang Siyuan<sup>1,2</sup>, Xiao Shenping<sup>1,2</sup>

<sup>1</sup>School of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou, Hunan 412007, China;

<sup>2</sup>Hunan Key Laboratory of Electric Drive Control and Intelligent Equipment, Zhuzhou, Hunan 412007, China

**Abstract:** To address issues of low detection accuracy and high false-positive and false-negative rates in solar cell defect detection, this paper proposes an optimized solar cell electroluminescent (EL) defect detection model based on the YOLOv8 deep learning framework. First, a self-calibrated illumination (SCI) method is applied to preprocess low-light images, enhancing effective feature information for solar cell defects. Then, a space-to-depth (SPD)

收稿日期: 2024-09-16; 修回日期: 2024-11-04; 录用日期: 2024-11-04

基金项目: 国家重点研发计划基金资助项目 (2019YFE0122600); 湖南省教育厅重点科研项目 (22A0423); 湖南省自然科学基金项目 (2023JJ60267, 2022JJ50073)

\*通信作者: 彭自然, pengziran@hut.edu.cn。

版权所有©2024 中国科学院光电技术研究所

attention module is introduced, replacing the second stride convolution layer in the backbone network. This substitution avoids information loss caused by stride convolution, expands the receptive field, and reduces computational load, preserving more feature information during extraction. Next, a spatial-BiFPN (S-BFPN) network is constructed to perform multi-scale feature fusion, stabilizing defect recognition rates by addressing the shape variability of solar cell defects. Lastly, the loss function is improved by adopting MPDIoU, which resolves the issue of ineffective penalties in the original CIoU loss function. The experimental results show that the improved YOLOv8 model achieved an mAP of 96.9%, a 2.2% increase compared to the original YOLOv8. The computational load was reduced by 0.2 GFlops, and the detection speed reached a maximum of 155 f/s, demonstrating high accuracy and real-time performance, making it more suitable for industrial deployment.

**Keywords:** deep learning; solar cells; defect detection; YOLOv8

## 1 引言

太阳能电池片的效能与性能评估是光伏发电管理的重要环节, 准确识别检测太阳能电池片表面缺陷变得愈发关键<sup>[1-2]</sup>。电致发光 (electroluminescent, EL) 成像<sup>[3]</sup> 作为一种广泛应用的非接触式检测技术, 被广泛用于评估太阳能电池片的质量和性能。手动分析太阳能电池片 EL 图片依赖专业人士的经验, 容易受到主观因素的影响, 检测精度难以保证, 而且耗时耗力, 人工成本高<sup>[4]</sup>。因此, 利用目标识别算法快速地对太阳能电池片 EL 图片进行自动缺陷检测成为研究热点<sup>[5]</sup>。

目标识别算法主要分为三类: 第一类是传统的机器视觉算法; 第二类是基于候选框的两阶段深度学习目标检测算法<sup>[6]</sup>; 第三类是基于回归的单阶段深度学习目标检测算法<sup>[7]</sup>。钱晓亮等人<sup>[8]</sup> 从人眼仿生学角度出发, 提出了一种结合视觉显著性和超像素分割的算法来定位太阳能电池片的缺陷区域。该算法模仿人眼视觉系统, 能够有效捕捉视觉上突出的缺陷, 但过于依赖视觉显著性, 会导致一些微小或隐藏的缺陷未被检测到。Tsai 等人<sup>[9]</sup> 采用傅里叶图像重建技术检测多晶太阳能电池的缺陷, 能够识别微裂纹、断裂和断指等目标缺陷, 具有较强的普适性, 但傅里叶图像重建技术往往需要较高的计算资源, 会降低方法的实时性。刘磊等人<sup>[10]</sup> 提出了一种自动数据分析流水线方法对 EL 图像进行预处理, 并引入机器学习算法对缺陷特征进行分类。该方法提高了效率, 特别是在大批量数据处理中表现较优, 但依赖于高质量的标注数据, 若标注不精确或样本量不足, 模型性能会显著下降。Wei 等人<sup>[11]</sup> 基于 Faster R-CNN 算法, 利用太阳能电池板红外图像进行训练, 实现对太阳能电池板缺陷的识别。尽管该方法提高了检测精度, 但 Faster R-

CNN 的计算量和复杂网络结构使其在处理大量数据时效率较低。张文彪等人<sup>[12]</sup> 通过参数不共享的双分支结构和 Cosine 学习率改进了 Faster R-CNN, 提升了对复杂缺陷的检测能力, 但也增加了计算复杂度和推理时间, 可能不适用于实时检测任务。如上述方法所示, 尽管传统的机器视觉算法和两阶段深度学习目标检测算法在特定缺陷检测上取得了一定进展, 但它们普遍存在计算复杂度高、实时性差和泛化能力不足的问题, 这使其不适用于 EL 图像的高效自动检测和工业化部署。

近年来, 随着深度学习的快速发展, YOLO 系列作为一阶段检测模型在目标检测的精度和速度上取得了显著进展。Lu 等人<sup>[13]</sup> 基于 YOLOv5 模型引入 CA 注意力机制, 并采用解耦头替换原有检测头, 从而提高了定位和目标识别的准确性。该方法有效捕捉了空间和通道间的特征, 适合复杂场景的目标检测, 但引入的复杂结构也增加了计算量, 导致推理速度下降, 影响实时性应用。周启宸等人<sup>[14]</sup> 在 YOLOv7 的基础上引入 Transformer 模型, 增强特征提取能力。虽然 Transformer 在捕捉长距离依赖特征方面表现出色, 但该方法的检测精度提升不足, 并且 Transformer 的计算开销降低了 YOLOv7 的轻量化优势, 推理速度较慢。Fu 等人<sup>[15]</sup> 通过引入高效远程卷积网络 (ELCN) 模块, 提升了 YOLOv7 的缺陷检测能力, 检测精度达到了 91.93%, 但 ELCN 的引入也增加了模型的复杂性, 推理速度未能满足实时检测的要求。张焯等人<sup>[16]</sup> 将 YOLOv8 中的多分支结构转化为单分支结构, 通过渐进式特征融合提高了检测小目标的能力。尽管在小目标检测方面取得了一定进展, 但在处理复杂背景和微小缺陷时, 单分支结构的特征表达能力仍显不足。上述改进 YOLO 模型的方法大多通过直接嵌入

注意力机制或其他模块来提升精度和特征提取能力。然而, 这些改进往往引入了更复杂的结构, 导致计算量增加, 推理速度下降, 从而削弱了 YOLO 在高实时性方面的性能。此外, 这些模型大多是为自然场景图像设计的, 通常在明亮环境下进行识别, 难以有效应对像 EL 图像这样的低光环境。再者, 改进的模型普遍缺乏针对微小且多样化目标的强化机制, 容易在检测 EL 图像中的缺陷目标时出现漏检问题。为了解决这些挑战, 本文选择了轻量化且具备较高精度的 YOLOv8<sup>[17]</sup> 进行优化, 提出了一种改进后的太阳能电池片缺陷检测模型 EL-YOLO。该模型区别于其他 YOLO 系列的改进方案, 不仅能够满足工业部署对高实时性和准确性的要求, 还解决了 YOLO 系列模型在低光环境下检测精度不足的缺陷。主要工作如下:

1) 将自校准照明 (self-calibrated illumination, SCI) 学习框架与 YOLOv8 框架相结合, 增强图像特征, 提高 EL 图像缺陷检测的准确率。

2) 引入了空间到深度的注意力模块 (space-to-depth, SPD-Conv) 用来替换主干网络的第二个跨步卷积, 使得网络在进行特征提取时能够保留更多的特征信息, 降低缺陷检测时的环境噪声。

3) 本文构建了空间双向要素金字塔网络 (spatial-BiFPN, S-BFPN), 通过多尺度的特征融合, 提高多形态缺陷检测的准确率。

4) 改进了损失函数, 选用了 MPDIoU 替换 CIoU

损失函数, 解决现有损失函数出现的惩罚项失效的问题, 以获得更快的收敛速度和更准确的回归结果, 提升模型的分类和检测性能。

## 2 相关工作

### 2.1 YOLOv8 网络结构

在过去的几年中, YOLO 系列模型凭借其在计算成本和检测性能之间的卓越平衡, 已经成为实时目标检测领域的主流。YOLOv8 按照模型宽度和深度不同分为 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x 五个版本。由于 EL 图像的缺陷检测任务通常包含大量小目标和细微特征, 轻量化模型能够减少推理延迟并确保高效的检测速度。结合模型体积与精度的平衡, 本文选择了精度较高且体积最小的 YOLOv8n 模型进行改进, 既能够满足工业应用中的实时性要求, 又能够保持较高的检测精度, 适用于实际生产环境的需求。YOLOv8n 网络主要由 Backbone、Neck 和 Head 部分组成, 如图 1 所示。

### 2.2 自校准光照学习模型结构

针对 EL 成像环境偏暗、图像对比度清晰度有限的问题, 本文采用了自校准光照学习 (SCI) 方法实现图像增强, 其结构如图 2 所示。SCI 是一个利用学习过程来加速弱光图像增强算法的深度网络模型<sup>[18]</sup>。

如图 2 所示, 整个结构分为两部分: 自校正模




图 1 YOLOv8n 网络结构图  
Fig. 1 YOLOv8n network structure

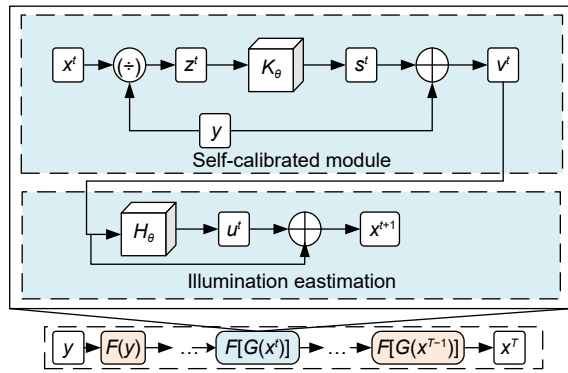


图 2 SCI 的结构  
Fig. 2 Structure of SCI

块 (self-calibrated module) 和照明估计模块 (illumination eastimation)。自校正模块可以表示为

$$G(x^t): \begin{cases} z^t = y(\div)x^t \\ s^t = K_\theta(z^t) \\ v^t = y + s^t \end{cases} \quad (1)$$

式中:  $y$  为低照度图像;  $z$  为目标图像;  $s$  为自校正映射;  $K_\theta$  为参数化操作符,  $\theta$  参数可学习;  $v^t$  为校准后用于下一阶段的输入;  $(\div)$  为按元素除法;  $t \geq 1$ 。式 (1) 中自校准模块通过引入一个自校准映射  $s$  来实现,  $s$  通过  $K_\theta$  这个参数化的操作符, 将当前阶段的输

入  $z$  调整为与初始输入更加一致的  $x^t$ , 最终目的是通过校准每个阶段的输出, 使其与初始低光图像更加一致, 能有效地调整图像, 使其具备一致的光照特征。照明估计模块可以表示为式 (2):

$$F(x^t): \begin{cases} u^t = H_\theta(v^t) \\ x^{t+1} = v^t + u^t \end{cases} \quad (2)$$

式中:  $u^t$  为第  $t$  阶段的残差;  $H_\theta$  为光照估计网络且网络均保持结构与参数共享状态。式 (2) 中通过神经网络模块  $H_\theta$  实现了对校准后的照明图进行更新的作用。

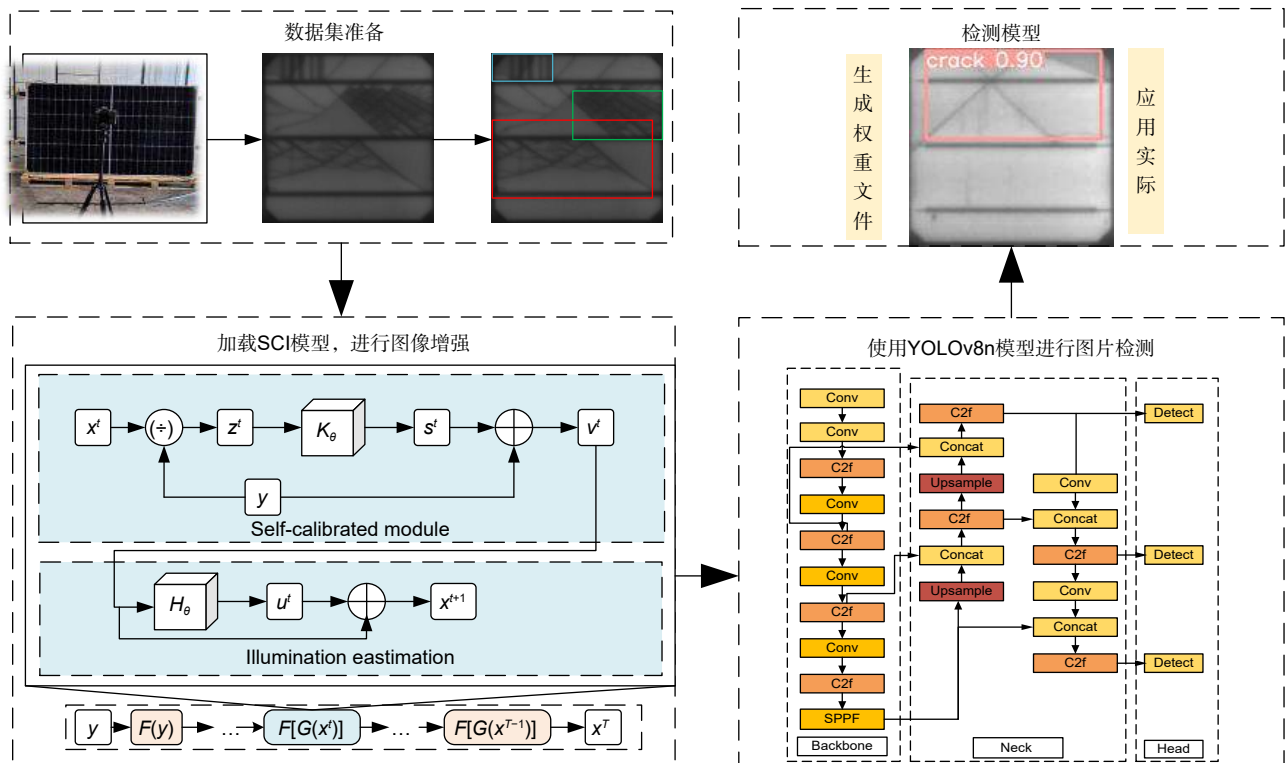
### 2.3 YOLOv8n 结合 SCI

本文使用 YOLOv8n 结合 SCI, 能够有效缓解由于光照不足导致的图像噪声和细节丢失问题, 具体流程如图 3 所示。

## 3 YOLOv8n 的改进与优化

### 3.1 Backbone 部分的改进

在 EL 图像的缺陷检测中, 背景的灰暗和缺陷的复杂性可能容易使 YOLOv8n 检测时受到干扰, 从而导致细小缺陷的丢失。为了解决这一问题, 本文对



注: 本文算法写成端对端的方法, 只需要输入低照度图像就可以产生增强后并绘制了检测框的图片。

图 3 具体算法实现流程  
Fig. 3 Specific algorithm implementation flow

YOLOv8n 模型的 Backbone 进行了改进, 引入了空间到深度的注意力模块 (space-to-depth, SPD), 以进一步增强其对 EL 图像中细小缺陷的特征提取能力。SPD 模块包括空间深度转换层和一个  $1 \times 1$  的非跨步卷积层, 它们分别负责特征图的分割融合和通道数的控制。这个结构允许 SPD 模块在进行特征下采样时保留所有通道维度中的信息, 从而避免了信息的丢失。SPD 模块将输入的任何大小为  $S \times S \times C_1$  的特征图划分为多个子特征图, 具体过程如式 (3) 所示。

$$\begin{cases} f_{0,0} = X[0 : S : scale, 0 : S : scale] \\ f_{1,0} = X[1 : S : scale, 0 : S : scale] \\ \dots \\ f_{scale-1,0} = X[scale-1 : S : scale, 0 : S : scale] \\ \dots \\ f_{scale-1, scale-1} = X[scale-1 : S : scale, scale-1 : S : scale] \end{cases} \quad (3)$$

式中:  $scale$  为图像比例;  $f_{1,0}, f_{1,1}, f_{scale-1, scale-1}$  为子特征图;  $S$  为特征图大小;  $C_1$  为图像深度。

为便于理解, 本文给出了  $scale=2$  时的划分过程如图 4 所示, SPD 层通过划分得到 4 个子特征图沿着通道维数进行拼接获得中间特征图, 在通过非跨步卷积层减少信息的无差别损失, 尽可能保留所有的判别

特征信息, 最后转化为最终特征图。

然而, 传统的在网络中嵌入注意力机制通常会增加模型的复杂度和训练难度, 同时也可能增加过拟合的风险。通过分析发现, YOLOv8n 网络在主干部分使用了大量的步长为 2 的跨步卷积模块 (Conv), 其在卷积核滑动过程中可能会错过一些有用的特征, 影响模型性能。特别是在细粒度信息提取方面, 这种结构可能导致小目标检测性能的下降。因此, 本文考虑使用 SPD 模块替换部分 Conv 模块, 以进一步提高特征提取能力。为了验证这一替换对模型性能的实际影响, 本文进行了多个位置的对比实验。如图 5 所示, 数字代表了各个 Conv 模块的位置。

表 1 实验数据表明, 将 SPD 模块加入 YOLOv8n 模型后, 大多数配置均实现了轻量化, 并提升了精度。第二组数据中, 虽然完全替换 Conv 模块使模型的权重、参数量和计算量最小, 但 mAP 仅为 95.1%, 准确性偏低。而在最后一组数据中, 仅替换第二个 Conv 模块时, 虽然模型略重, 但 mAP 达 96%, 精度最高。因此, 基于精度优先的原则, 本文最终选择在第二个 Conv 模块进行替换, 达成了高精度的轻量化改进。

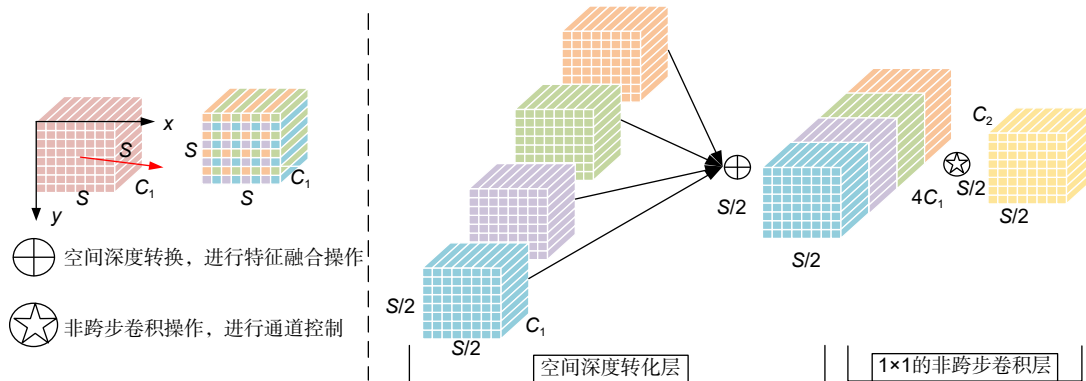


图 4  $scale$  为 2 的 SPD 示意图  
Fig. 4 Schematic diagram of SPD with  $scale=2$




图 5 Backbone 部分不同位置的 Conv 模块  
Fig. 5 Conv modules in different positions of the Backbone part

表 1 多个位置添加注意力机制对比实验结果

Table 1 Comparative experimental results of adding attention mechanisms at multiple locations				
替换位置	权重/MB	参数量/( $10^6$ )	GFlops	mAP/%
YOLOv8n	6.3	3.006	8.1	94.7
2, 3, 4, 5	<b>5.7</b>	<b>2.818</b>	<b>7.4</b>	95.1
2, 5	5.8	2.890	7.8	95.3
5	5.8	2.894	8.0	95
4	6.2	3.066	8.0	94.5
3	6.3	3.109	8.0	94.7
<b>2 (本文)</b>	<b>6.2</b>	3.002	<b>7.9</b>	<b>96.0</b>

### 3.2 Neck 部分的改进

YOLOv8n 采用基于 FPN 改进的 PAN 结构进行特征融合, 通过双路径实现了浅层和深层特征的高效传递, 但 PANet 仍存在特征丢失和效率低的问题。为此, 本文引入并改进了加权双向特征金字塔网络 (BiFPN), 最终构建出简化的空间双向特征金字塔网络 (S-BFPN), 其结构如图 6(d) 所示。S-BFPN 具有以下优点: 1) 删除了对网络贡献较小的 P3 和 P7 中间节点; 2) 增加跳跃连接, 实现更好的多尺度特征融合; 3) 将双向特征融合路径作为基础层重复使用, 达到更深层次的特征融合; 4) 考虑到 BiFPN 包含 5 个特征层输入, 而本文仅对 P3、P4、P5 层进行特征提取, 为减少计算量和噪声干扰, 删除了 P7 和 P6 层的输出。改进后的 S-BFPN 能够更好地融合特征, 同时保持模型的参数量不变, 具备高精度和高效率的优势。

为了便于理解, 本文举出 YOLOv8n 使用的 PAN 网络第 4 层的特征融合过程如式 (4)~(5) 所示:

$$P_4^{id} = Conv(P_4^{in} + US(P_5^{id})), \quad (4)$$

$$P_4^{out} = Conv(P_4^{id} + DS(P_3^{out})). \quad (5)$$

改进后的 S-BFPN 网络第 4 层的特征融合过程如式 (6)~(7) 所示:

$$P_4^{id} = Conv\left(\frac{\omega_4^0 \cdot P_4^{in} + \omega_5^1 \cdot US(P_5^{in})}{\omega_4^0 + \omega_5^1 + \delta}\right), \quad (6)$$

$$P_4^{out} = Conv\left(\frac{\omega_4^1 \cdot P_4^{id} + \omega_4^2 \cdot P_4^{id} + \omega_3^3 \cdot DS(P_3^{out})}{\omega_4^1 + \omega_4^2 + \omega_3^3 + \delta}\right), \quad (7)$$

式中:  $P^{id}$  为中间层;  $P^{in}$  为第一层输入;  $P^{out}$  为第三层输出;  $Conv$  为执行卷积;  $US$  为上采样;  $DS$  为下采样;  $\omega$  为相应路径的可学习权重;  $\delta$  为远小于 1 的数值, 用于保持稳定。

如式 (4)~(5) 所示, PAN 网络结构主要通过自顶向下和自底向上的路径来融合特征, 只进行了简单的上下层语义融合。而本文构建的 S-BiFPN 网络在每个融合步骤中引入了可学习的权重, 如式 (6)~(7) 所示。这样使得网络能够根据不同层次特征图的重要性自适应地调整融合权重, 从而提升特征融合的效果。相比于 PAN 结构的上下层特征融合, S-BiFPN 网络通过融合多个层次的特征图, 能够更好地捕捉目标的不同尺度和细节信息, 提高模型的泛化能力。

### 3.3 损失函数的改进

YOLOv8n 使用 CIoU 作为边界框损失函数, 其 CIoU 计算公式如式 (8) 所示。

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(B_{gt}, B_{prd})}{c^2} + v \cdot \alpha, \quad (8)$$

$$IoU = \frac{B_{gt} \cap B_{prd}}{B_{gt} \cup B_{prd}}, \quad (9)$$

$$v = \frac{4}{\pi^2} \left( \arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w^{prd}}{h^{prd}} \right)^2, \quad (10)$$

$$\alpha = \frac{v}{1 - IoU + v}. \quad (11)$$

式中:  $B_{gt}$  为真实边界框;  $B_{prd}$  为预测边界框;  $IoU$  为交并比;  $\rho$  为目标框与预测框中心点之间的距离;  $c$  为目标框与预测框最小包围矩形的对角线长度;  $v$  为目标框与预测框宽高比的相似度;  $\alpha$  为  $v$  的影响因子。

从式 (10) 中可以看出, 当  $\frac{w^{gt}}{h^{gt}}$  与  $\frac{w^{prd}}{h^{prd}}$  长宽比相同时, 作为 CIoU 损失函数的惩罚项  $v$  取 0, 这将导致 CIoU 的收敛速度变慢且效率较低, 最终可能会产生一个更差的训练模型。为了解决这个问题且针对光伏电池板 EL 图像的特征与特点, 本文引入了一种新的




图 6 四种特征融合结构示意图

Fig. 6 Schematic diagram of four features of fusion structure

损失函数 MPDIoU。MPDIoU 由三部分组成：图像的高度与宽度、预测框与真实框的对角点、重叠面积。MPDIoU 损失函数的计算如图 7 所示。




图 7 MPDIoU 损失函数的计算  
Fig. 7 Calculation of MPDIoU loss function

通过将真实框与预测框的左上点和右下点顶点加入损失函数的计算中，使预测框在训练过程中不断靠近真实框，以解决原有损失函数在预测框损失计算中存在的问题。修改后的损失函数 MPDIoU 如式 (15) 所示。

$$d_1^2 = (x_1^{\text{prd}} - x_1^{\text{gt}})^2 + (y_1^{\text{prd}} - y_1^{\text{gt}})^2, \quad (12)$$

$$d_2^2 = (x_2^{\text{prd}} - x_2^{\text{gt}})^2 + (y_2^{\text{prd}} - y_2^{\text{gt}})^2, \quad (13)$$

$$MPDIoU = IoU - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2}, \quad (14)$$

$$L_{MPDIoU} = 1 - IoU + \frac{d_1^2}{w^2 + h^2} + \frac{d_2^2}{w^2 + h^2}, \quad (15)$$

式中： $(x_1^{\text{gt}}, y_1^{\text{gt}}), (x_2^{\text{gt}}, y_2^{\text{gt}})$  分别为  $B_{\text{gt}}$  的左上和右下点坐标； $(x_1^{\text{prd}}, y_1^{\text{prd}}), (x_2^{\text{prd}}, y_2^{\text{prd}})$  分别为  $B_{\text{prd}}$  的左上和右下点坐标； $w$  为输入图像的宽度； $h$  为输入图像的高度； $d_1, d_2$  分别为预测框和真实框的两个顶点的距离。

### 3.4 YOLOv8 改进后的网络结构

通过上述改进后，得到本文提出的 EL-YOLO 模型，网络结构如图 8 所示。

改进 YOLO 模型的主要难点在于：为提高精度往往引入复杂结构，导致计算量增加，牺牲了工业部署的实时性<sup>[19]</sup>。此外，YOLO 模型多应用于自然场景，未针对低光环境（如 EL 图像）优化设计<sup>[20]</sup>，且在小目标检测中易漏检或误检<sup>[21]</sup>。针对这些问题，本文提出 EL-YOLO 模型，其具备以下优势：1) 轻量化设计：结合 SPD-Conv 注意力机制与 YOLOv8n 主干网络，提升检测能力的同时保持高实时性，适用于工业实时应用；2) 低光优化：引入自校准照明 (SCI)，提高低

光环境下的检测效果；3) 小目标检测提升：采用 S-BFPN，增强多尺度特征融合，提高小目标检测精度；4) 损失函数优化：使用 MPDIoU 替代 CIoU，提高检测精度和收敛速度。

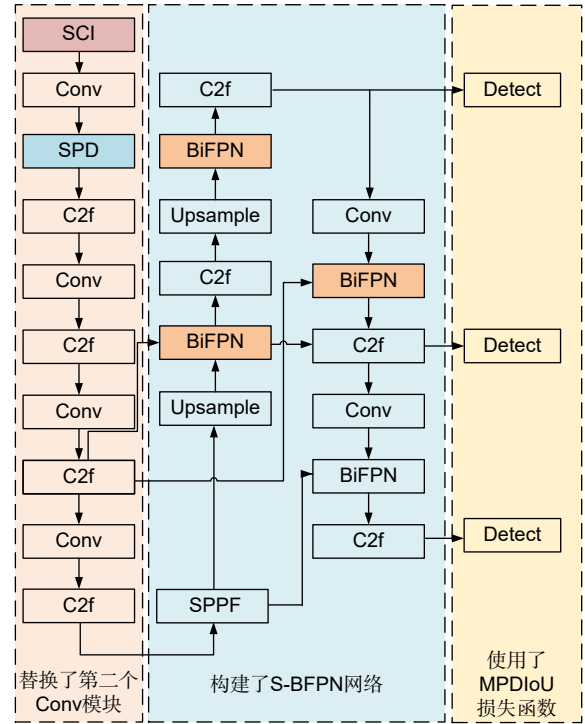


图 8 改进后的 EL-YOLO 模型  
Fig. 8 Improved EL-YOLO model

通过这些改进，EL-YOLO 模型在满足工业实时性需求的同时，显著提升了低光环境下的缺陷检测能力，弥补了现有 YOLO 改进方案的不足。

## 4 实验

### 4.1 实验条件

本文在训练阶段采用单张 GPU (NVIDIA GeForce RTX 3050 Laptop GPU, 4096 MB)，图片的输入规格为 300 pixel×300 pixel，初始学习率设置为 0.01，使用余弦退火的策略调整学习率，Batchsize 设置为 8，选择 SGD 优化器，训练轮数设置为 300。除特别说明外，本文所有实验均采用以上设置。

### 4.2 电致发光 (EL) 成像数据集

本研究采用生产现场采集的 2257 张太阳能电池片电致发光 (EL) 图像，尺寸为 300 pixel×300 pixel。为增强缺陷检测模型的性能和泛化能力，本文对图像进行数据增广，包括：1) 图像翻转；2) 对比度增强；

3) 添加噪声。处理后, 数据集扩展到 6468 张 EL 图像。如图 9 所示, EL 图像分析可检测出电池片的裂纹、残缺和脏污等缺陷。然而, EL 成像需在低光下进行, 图像较暗, 增加了识别难度。

### 4.3 使用 SCI 算法进行数据增强

为了进一步说明不同增强算法对模型性能的改善作用, 本文分别采用自适应伽马变换 (AGT)、零参考深度曲线估计 (ZERO-DCE)、自校准光照学习 (SCI) 算法对原生数据集 (RAW) 进行图像增强, 效果对比如图 10 所示。

自适应伽马变换 (AGT) 虽然能够有效提升 EL 图像的亮度, 但容易引入大量噪点; 零参考深度曲线估计 (ZERO-DCE) 则由于 EL 图像的过度曝光, 可能导致部分有效信息无法稳定表达。而自校准光照学习算法 (SCI) 通过自校准机制和光照估计, 能够自动适应并校正不同光照条件, 显著提升了 EL 图像处理的鲁棒性和准确性。本文采用 AGT、ZERO-DCE 和 SCI 三种算法对原始数据集 (RAW) 进行图像增强, 生成三个新数据集, 分别命名为 AGT、ZERO 和 SCI。随后, 使用这三个增强数据集以及未经增强的原始数据集分别训练 YOLOv8n 基础检测模型, 得到结果如表 2 所示。




图 9 三种主要缺陷种类图  
Fig. 9 Diagram of three major defect types

从表 2 的实验结果可以看出, SCI 算法相比于其他两种增强算法, 在精确率、召回率以及平均精确率上均有显著提升。使用本文提出的图像增强方法, 在检测太阳能电池片 EL 图像时, 准确率 ( $P$ ) 从 93.1% 提升至 96.5%, 提高了 3.4%; 召回率 ( $R$ ) 提升了 0.1%; 平均精度从 91.0% 提升至 94.7%, 提高了 3.6%。

### 4.4 检测效果对比

本文按照 7:3 的比例将数据集划分为训练集和验证集, 并将其输入到 EL-YOLO 模型中进行实验。检测效果与原始模型 YOLOv8n 进行对比, 如图 11。

通过图 11(a) 的误检组可以看出, YOLOv8n 将复杂的裂纹误检成脏污 (dirt)。图 11(b) 漏检组中的 YOLOv8n 模型出现了小目标的漏检, 忽略掉了细小的裂纹 (crack)。图 11(c) 检测框重叠组中可以发现 EL-YOLO 模型预测框的置信度有较大提升, 没有出现重叠框的现象。图 11(d) 检测精度不足组可知, YOLOv8n 与 EL-YOLO 对比可知, 优化改进后的 EL-YOLO 模型提取到了更加丰富的特征信息, 检测精度更高, 表现出了更好的性能。

### 4.5 评价指标

本文实验采用均值平均精度 (mAP)、权重大小、

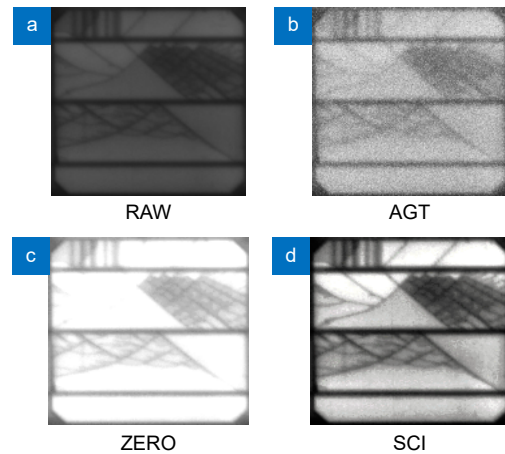


图 10 不同增强方法的视觉对比  
Fig. 10 Visual comparison of different enhancement methods

表 2 增强算法对比实验

算法	准确率/%	召回率/%	平均精度/%
RAW	93.1	91.0	91.0
AGT	93.5	90.4	91.8
ZERO-DCE	95.6	90.7	93.2
SCI (本文)	96.5	91.1	94.7




图 11 本文算法与 YOLOv8n 检测效果对比

Fig. 11 Comparison of detection effect between the proposed algorithm and YOLOv8n

参数量、计算量 (GFlops) 与检测速度 (FPS) 等几项指标评判算法模型的性能。其中均值平均精度 mAP 以 IoU 阈值为 0.5 来计算, 且需要参考准确率 (P)、召回率 (R)。mAP 作为评价模型的关键指标, 如式 (19) 所示。

$$P = \frac{T_p}{T_p + F_p}, \quad (16)$$

$$R = \frac{T_p}{T_p + F_N}, \quad (17)$$

$$AP = \int_0^1 P(R)dR, \quad (18)$$

$$mAP = \frac{1}{N} \sum_{c=1}^N AP_c, \quad (19)$$

式中:  $T_p$  为正样本预测出正样本的数量;  $F_p$  为负样本预测出正样本的数量;  $F_N$  为正样本预测出负样本的数量;  $N$  为本文检测目标的类别数,  $AP_c$  为第  $c$  个类别的平均精度。

图 12(a1, b1) 展示了准确率 (Precision) 曲线, 图 12(a2, b2) 展示了召回率 (Recall) 曲线, 图 12(a3, b3) 展示了 PR 曲线。当分类器的准确率和召回率都较高时, PR 曲线接近右上角, 表明模型的平均精度更高。实验表明, 裂纹缺陷检测难度最大, 主要因其特征不明显、背景干扰多。裂纹在 EL 图像中通常呈细小、不规则线条, 对比度低, 易被噪声和复杂背景混淆, 增加误检和漏检风险。改进后的 EL-YOLO 通过引入 SPD 模块和 S-BFPN, 有效增强了对小目标和复杂背

景的检测能力, 特别在裂纹检测上较 YOLOv8n 提升明显, 验证了改进方法在 EL 缺陷检测中的有效性。

#### 4.6 损失函数对比

本文将改进后的 EL-YOLO 的损失函数与 YOLOv8n 的损失函数进行了对比, 如图 13 所示。可以看出, 本文模型损失值衰减速率明显较快, 边界框损失函数整体收敛加快。因此, 本文模型中 MPDIoU 损失函数, 对网络模型的性能提升有着重要意义。

#### 4.7 消融实验

本文对 YOLOv8n 的主要改进分为 3 个部分: 1) Backbone 部分改进, 嵌入 SPD 模块; 2) Neck 部分改进, 构建了 S-BFPN 网络; 3) 损失函数改进, 使用 MPDIoU 代替 CIoU 损失函数; 将上面的改进分别简称为 S (SPD)、SB (S-BFPN)、M (MPDIoU)。为了验证上述改进方法的有效性, 本文设计消融实验。实验结果如表 3 所示, 表中“√”表示在训练时加入了此改进方法。

由表 3 可知, 第 2 组实验中在 YOLOv8n 模型主干网络中使用 SPD 模块替换掉第二个卷积网络, 扩大感受野, 增强模型的小目标特征提取能力, 使得模型检测平均精度较原始模型 YOLOv8n 提升了 1.3%, 降低了 0.1 MB 的权重大小, 减少了 0.2 GFlops 计算量大小并提升了 2 FPS 的检测速度, 在提升了精确度的前提下还将模型轻量化; 第 3 组实验中在 YOLOv8n

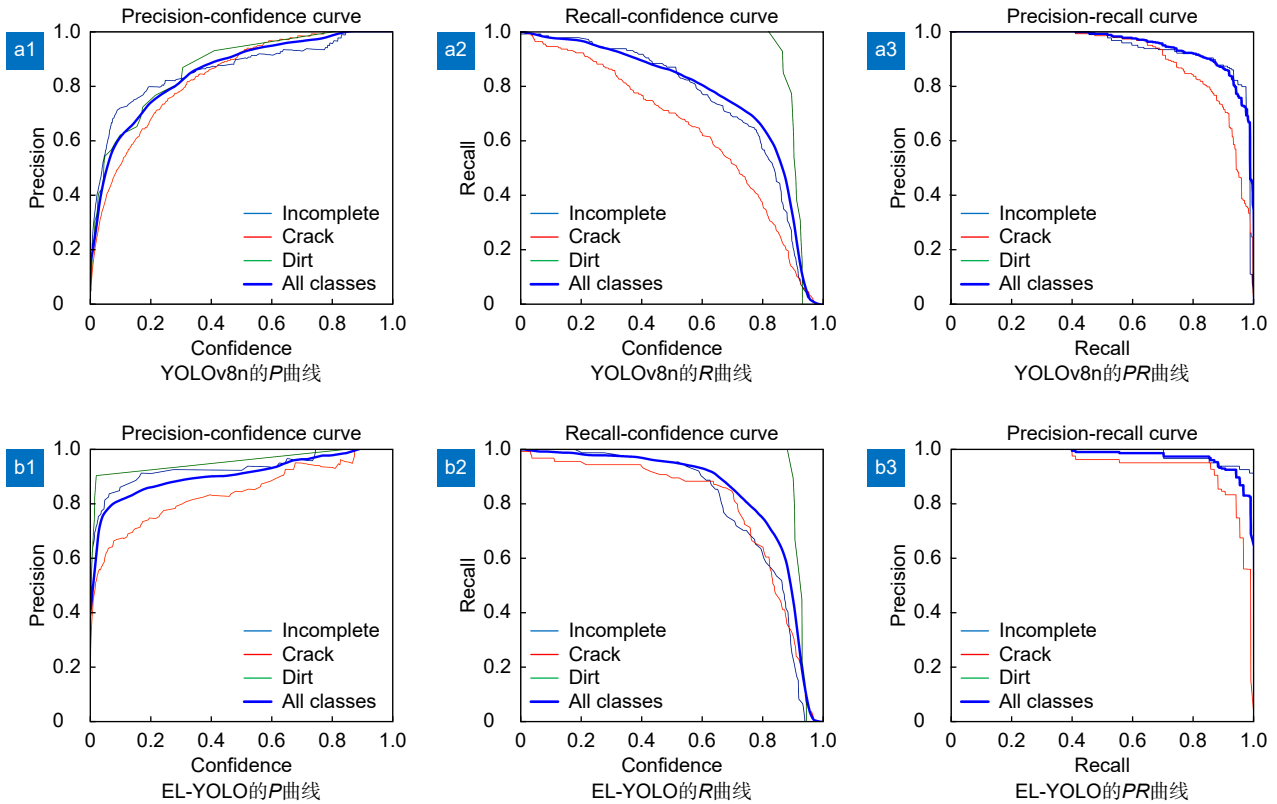


图 12 本文算法与 YOLOv8n 的 P、R、PR 曲线对比

Fig. 12 Comparison of P, R, and PR curves between the algorithm in this paper and YOLOv8n

表 3 消融实验结果

Table 3 Results of the ablation experiment

算法模型	S	SB	M	权重/MB	参数量/ $10^6$	计算量/GFlops	FPS	mAP@(0.5)/%
YOLOv8n				6.3	3.006	8.1	153	94.7
YOLOv8n-S	√			6.2	3.002	7.9	155	96.0
YOLOv8n-SB		√		6.3	3.006	8.1	147	95.4
YOLOv8n-M			√	6.3	3.006	8.1	154	95.5
YOLOv8n-S+SB	√	√		6.2	3.002	7.9	148	96.2
YOLOv8n-S+M	√		√	6.2	3.002	7.9	158	96.4
YOLOv8n-SB+M		√	√	6.3	3.006	8.1	150	96.0
EL-YOLO (本文)	√	√	√	6.2	3.002	7.9	155	96.9

模型颈部引入 S-BiFPN 网络, 在牺牲少量检测速度的前提下, 实现了多尺度特征的快速捕捉与融合, 使得模型平均检测精度均值提升了 0.7%; 第 4 组实验采用 MPDIoU 代替 CIoU 损失函数, 以提升检测框定位精度和模型收敛速度, 使得模型平均检测精度均值提升了 0.8%。几组实验相比最终 EL-YOLO 模型, 消除任意改进方法都会降低模型的检测精度, 其中消除 SPD 的改进, 对于本文最终模型影响最大, 不仅检测精度降低了 1.3%, 增加了权重大小和计算量, 还降低了模型检测速度。为了探究 EL-YOLO 的改进效果, 本文对模型的各项改进进行了热力图可视化分析, 以展示 EL-YOLO 的性能提升。如图 14 所示, 其中

蓝色部分表示置信度较低的区域, 红色则表示置信度较高的区域。可以发现, YOLOv8n 的主要关注区域包含错误的裂纹部分, 并且还关注了一些无关信息。最终检测结果 (结合表 3 与图 14) 表明, 对于缺陷检测, 本文提出的 EL-YOLO 算法其关注到需要检测的地方相比 YOLOv8n 更加精确, 检测精度更高。

#### 4.8 多种算法对比

为了进一步证明本文所提模型的优越性和有效性, 使用本文所提模型与主流目标检测模型、轻量化检测模型进行对比实验, 实验结果如表 4 所示。

本文对当前流行的太阳能电池片缺陷检测算法进

行了综合比较, 包括一阶段检测网络如 SSD、YOLO 及 RT-DETR<sup>[22]</sup>, 以及二阶段检测网络如 Faster-R-CNN。尽管 Faster-R-CNN 的检测精度较高, 但其模型较大, 作为两阶段算法, 检测速度较慢, FPS 仅为 8, 不利于 EL 缺陷的工业实时检测。SSD 虽速度较快, 但其检测精度较低, 特别是在小目标检测方面表现不足。百度飞桨团队研发的 RT-DETR 是基于 Transformer 架构的单阶段目标检测算法, 虽然模型比 Faster-R-CNN 和 SSD 小, 但仍大于 YOLO 系列, 其 FPS 值为 47, 同样不适合工业实时检测。

相比之下, YOLO 系列模型在精度和权重大小上均表现优越。本文进一步比较了工业检测领域常用的 YOLOv5s、YOLOv7、YOLOv8、YOLOv10<sup>[23]</sup> 和

Gold-YOLO<sup>[24]</sup> 模型。虽然 YOLOv5s 和 YOLOv7 的检测效果尚可, 但与 YOLOv8 相比仍存在差距。YOLOv10 和 Gold-YOLO 在 YOLOv8 的基础上进行了改进, 尽管其检测精度高于 YOLOv8 系列, 但因增加了多个模块导致模型复杂化, 检测速度下降, FPS 值低于 YOLOv8n。同样, 虽然在不同体量的模型中, 只有 YOLOv8s 的检测精度高于 YOLOv8n, 但其模型体积较大, 导致 FPS 降低了 49。因此, 本文未考虑在 YOLOv8s 基础上进行改进, 以避免在提升少量检测精度的同时牺牲实时性。

在此背景下, 本文提出的 EL-YOLO 算法在太阳能电池片 EL 成像缺陷检测中表现尤为出色。EL-YOLO 不仅在检测精度上超过了 YOLOv10 和 Gold-

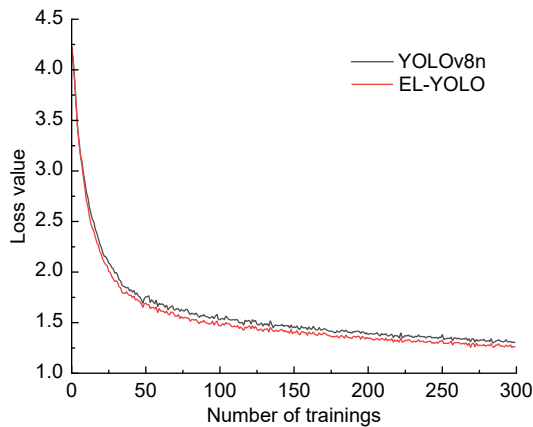


图 13 损失函数对比

Fig. 13 Comparison of loss functions

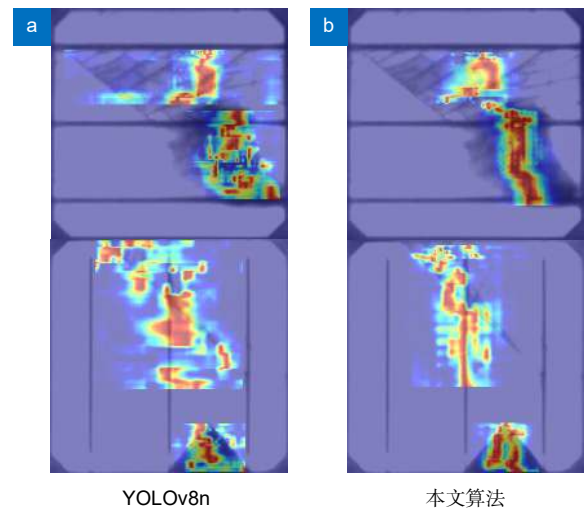


图 14 热力图效果对比

Fig. 14 Comparison of thermal map effects

表 4 多种检测算法结果对比

Table 4 Comparison of results of multiple detection algorithms

算法模型	权重/MB	参数量/ $10^6$	计算量/GFlops	FPS	mAP@(0.5)/%
YOLOv5s	14.5	7.018	15.8	118	89.8
YOLOv7	74.8	37.194	105.1	71	84.6
YOLOv8n	6.3	3.006	8.1	153	94.7
YOLOv8s	22.5	11.137	28.8	104	95.3
YOLOv8m	52.0	25.902	79.3	73	93.6
YOLOv10s	31.4	7.2	21.6	119	96.2
RT-DETR	63.1	32.8	108.2	46	96.0
Gold-YOLO	43.1	21.5	46.0	82	96.4
Faster-R-CNN	112.7	41.325	24.2	8	94.6
SSD	99.1	35.873	12.7	44	81.3
EL-YOLO(本文)	6.2	3.019	7.9	155	96.9

YOLO, 还保持了 YOLOv8n 的轻量化优势, 检测速度达到了最高的 155 f/s, 同时实现了 96.9% 的最高检测精度。与基线 YOLOv8 模型相比, EL-YOLO 的精度提高了 2.2%, 并在权重和计算量上有少量降低, 模型更加轻量化。

综上所述, EL-YOLO 模型在轻量化设计、参数效率、计算量、推理速度和检测精度等方面均表现优秀, 充分满足了工业实时应用的需求, 展现了良好的应用前景。

## 5 结论

本文提出了一种基于 YOLOv8n 优化改进的深度神经网络 EL-YOLO, 旨在解决太阳能电池片 EL 成像缺陷自动检测中的技术瓶颈。通过引入图像增强技术, 处理低照度条件下的图像, 显著强化了目标特征信息, 提升了检测准确率。同时, 对 YOLOv8n 模型进行了优化, 引入了注意力模块和多尺度 S-BFPN 网络, 以增强特征提取能力, 并采用 MPDIoU 损失函数, 提高了模型的检测精度和收敛速度。实验结果表明, EL-YOLO 在检测精度和速度上均取得了显著进展, 最高精度达到 96.9%, 检测速度为 155 f/s。这证明了 EL-YOLO 能够满足工业应用中对实时性和准确性的高要求, 且具备轻量化特性。本文的研究为低光环境下的目标检测提供了新的解决方案, 展示了 YOLO 系列模型在特定应用中的优化潜力。

**利益冲突:** 所有作者声明无利益冲突

## 参考文献

- [1] Peng Z R, Xu H S, Xiao S P. A CatBoost optimization-based fault diagnosis model for photovoltaic arrays[J]. *Acta Electron Sin*, 2024, 52(7): 2418–2428.  
彭自然, 许怀顺, 肖伸平. 一种基于 CatBoost 优化的光伏阵列故障诊断模型[J]. *电子学报*, 2024, 52(7): 2418–2428.
- [2] Shi Y T, Dai F, Yang C M. Defect detection of solar photovoltaic cell[J]. *J Electron Meas Instrum*, 2020, 34(4): 157–164.  
时亚涛, 戴芳, 杨畅民. 太阳能光伏电池缺陷检测[J]. *电子测量与仪器学报*, 2020, 34(4): 157–164.
- [3] Bedrich K, Bokalić M, Bliss M, et al. Electroluminescence imaging of PV devices: advanced vignetting calibration[J]. *IEEE J Photovoltaics*, 2018, 8(5): 1297–1304.
- [4] Chen X, Karin T, Jain A. Automated defect identification in electroluminescence images of solar modules[J]. *Solar Energy*, 2022, 242: 20–29.
- [5] Peng Z R, Zhang Y Q, Xiao S P. Research on surface defect detection of solar cell with improved YOLOv5 algorithm[J]. *Acta Energ Sol Sin*, 2024, 45(6): 368–375.

- [6] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, 39(6): 1137–1149.
- [7] Pei S T, Zhang H Y, Hu C L, et al. The defect detection method for cross-environment power transmission line based on ER-YOLO algorithm[J]. *Trans China Electrotech Soc*, 2024, 39(9): 2825–2840.  
裴少通, 张行远, 胡晨龙, 等. 基于 ER-YOLO 算法的跨环境输电线路缺陷识别方法[J]. *电工技术学报*, 2024, 39(9): 2825–2840.
- [8] Qian X L, Zhang H Q, Zhang H L, et al. Solar cell surface defect detection based on visual saliency[J]. *Chin J Sci Instrum*, 2017, 38(7): 1570–1578.  
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.
- [9] Tsai D M, Wu S C, Li W C. Defect detection of solar cells in electroluminescence images using Fourier image reconstruction[J]. *Solar Energy Mater Solar Cells*, 2012, 99: 250–262.
- [10] Liu L, Wang C, Zhao S W, et al. Research on solar cells defect detection technology based on machine vision[J]. *J Electron Meas Instrum*, 2018, 32(10): 47–52.  
刘磊, 王冲, 赵树旺, 等. 基于机器视觉的太阳能电池片缺陷检测技术的研究[J]. *电子测量与仪器学报*, 2018, 32(10): 47–52.
- [11] Wei S Q, Li X X, Ding S H, et al. Hotspots infrared detection of photovoltaic modules based on Hough line transformation and Faster-RCNN approach[C]//*Proceedings of the 2019 6th international conference on control, decision and information technologies*, Paris, 2019: 1266–1271.  
<https://doi.org/10.1109/CoDIT.2019.8820333>.
- [12] Zhang W B, Ma Y H, Bai X J, et al. Defect identification of solar panels using improved Faster R-CNN[J]. *Power Syst Technol*, 2022, 46(7): 2593–2600.  
张文彪, 马永华, 白晓静, 等. 基于改进 Faster R-CNN 的太阳能电池缺陷识别[J]. *电网技术*, 2022, 46(7): 2593–2600.
- [13] Lu S, Wu K X, Chen J X. Solar cell surface defect detection based on optimized YOLOv5[J]. *IEEE Access*, 2023, 11: 71026–71036.
- [14] Zhou Q C, Wang B C. Solar cell surface defect detection based on improved YOLOv7[J]. *J Comput Appl*, 2023, 43(S2): 223–228.  
周启宸, 王伯超. 基于改进 YOLOv7 的太阳能电池片表面缺陷检测[J]. *计算机应用*, 2023, 43(S2): 223–228.
- [15] Fu H, Cheng G Q. Convolutional neural network based efficient detector for multicrystalline photovoltaic cells defect detection[J]. *Energy Sources Part A Recovery Util Environ Eff*, 2023, 45(3): 8686–8702.
- [16] Zhang Y, Li B T, Shang J H, et al. Defect detection of transmission line damper based on multi-scale convolutional attention mechanism[J]. *Trans China Electrotech Soc*, 2024, 39(11): 3522–3537.  
张烨, 李博涛, 尚景浩, 等. 基于多尺度卷积注意力机制的输电线路防振锤缺陷检测[J]. *电工技术学报*, 2024, 39(11): 3522–3537.
- [17] Wang Z, Hua Z X, Wen Y C, et al. E-YOLO: recognition of estrus cow based on improved YOLOv8n model[J]. *Expert Syst Appl*, 2024, 238: 122212.
- [18] Ma L, Ma T Y, Liu R S, et al. Toward fast, flexible, and robust low-light image enhancement[C]//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, New Orleans, 2022: 5627–5636.

<https://doi.org/10.1109/CVPR52688.2022.00555>.

- [19] Liu H J, Liu L S, Zhang M C. An improved infrared object detection algorithm based on YOLOv5[J]. *Laser Technol*, 2024, 48(4): 534–541.  
刘皓皎, 刘力双, 张明淳. 基于 YOLOv5 改进的红外目标检测算法[J]. *激光技术*, 2024, 48(4): 534–541.
- [20] Zhang R M, Xiao Y F, Jia Z N, et al. Improved YOLOv7 algorithm for target detection in complex environments from UAV perspective[J]. *Opto-Electron Eng*, 2024, 51(5): 240051.  
张润梅, 肖钰霏, 贾振楠, 等. 改进 YOLOv7 的无人机视角下复杂环境目标检测算法[J]. *光电工程*, 2024, 51(5): 240051.
- [21] Wang P F, Li Y T, Huang Y Y, et al. Defects detection for cable surface of cable-stayed bridge based on improved YOLOv5s network[J]. *Opto-Electron Eng*, 2024, 51(5): 240028.

王鹏峰, 李运堂, 黄永勇, 等. 基于改进 YOLOv5s 网络的斜拉桥拉索表面缺陷检测[J]. *光电工程*, 2024, 51(5): 240028.

- [22] Zhao Y A, Lv W Y, Xu S L, et al. DETRs beat YOLOs on real-time object detection[C]//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, 2024: 16965–16974.  
<https://doi.org/10.1109/CVPR52733.2024.01605>.
- [23] Wang A, Chen H, Liu L H, et al. YOLOv10: real-time end-to-end object detection[Z]. arXiv: 2405.14458, 2024.  
<https://doi.org/10.48550/arXiv.2405.14458>.
- [24] Wang C C, He W, Nie Y, et al. Gold-YOLO: efficient object detector via gather-and-distribute mechanism[C]//*Proceedings of the 37th Conference on Neural Information Processing Systems*, New Orleans, 2023: 36.

## 作者简介



【通信作者】彭自然 (1969-), 男, 副教授, 研究方向为人工智能、信号处理、智能检测仪表、智能移动终端等。

E-mail: [pengziran@hut.edu.cn](mailto:pengziran@hut.edu.cn)



王思远 (2000-), 男, 硕士研究生, 研究方向为人工智能、太阳能发电等。

E-mail: [1184808260@qq.com](mailto:1184808260@qq.com)



肖仲平 (1965-), 男, 教授, 博士生导师, 研究方向为时滞系统鲁棒控制理论及应用、电力时滞系统稳定性分析、工业网络控制、智能控制、过程控制等。

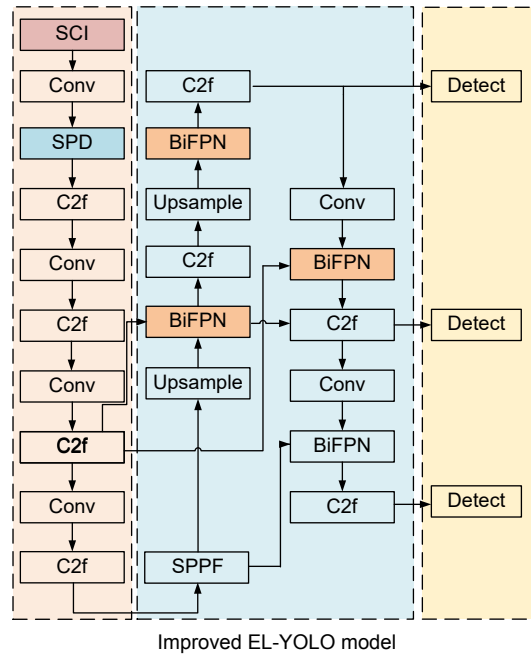
E-mail: [xsp@hut.edu.cn](mailto:xsp@hut.edu.cn)



扫描二维码, 获取PDF全文

# A solar cell defect detection model optimized and improved based on YOLOv8

Peng Ziran<sup>1,2\*</sup>, Wang Siyuan<sup>1,2</sup>, Xiao Shenping<sup>1,2</sup>



**Overview:** As the global demand for renewable energy grows, solar power has become an essential source of clean energy. However, solar cells often develop defects, such as microcracks, hotspots, and black spots, during production, which significantly impact their conversion efficiency and lifespan. Traditional manual inspection methods are inefficient and limited by lighting conditions, resulting in low detection accuracy with high false-positive and false-negative rates. To meet the need for efficient and precise automated inspection in industrial production, this study aims to develop a high-accuracy, real-time solar cell defect detection model suitable for practical industrial environments. In response, this paper proposes an optimized solar cell electroluminescent (EL) defect detection model based on the YOLOv8 deep learning framework. First, a self-calibrated illumination (SCI) method is applied to preprocess low-light images, enhancing the effective feature information for detecting solar cell defects. Next, a space-to-depth (SPD) attention module is introduced, replacing the second stride convolution layer in the backbone network to prevent information loss caused by stride convolution, expand the receptive field, and reduce computational load, ensuring more comprehensive feature retention. Additionally, a spatial-BiFPN (S-BFPN) network is constructed to perform multi-scale feature fusion, stabilizing recognition rates even when defect shapes vary. Finally, the loss function is improved with the adoption of MPDIoU, addressing the inadequate penalty issues in the original CIoU loss function. Experimental results show that the improved YOLOv8 model achieves an mAP of 96.9%, marking a 2.2% increase over the original YOLOv8, while reducing computational load by 0.2 GFlops. The detection speed reaches a maximum of 155 FPS, demonstrating high accuracy and real-time performance, making it more suitable for industrial applications.

Peng Z R, Wang S Y, Xiao S P. A solar cell defect detection model optimized and improved based on YOLOv8[J]. *Opto-Electron Eng*, 2024, 51(11): 240220; DOI: 10.12086/oe.2024.240220

Foundation item: Project supported by National Key Research and Development Program of China (2019YFE0122600), Key Scientific Research Project of the Hunan Provincial Department of Education (22A0423), and Hunan Provincial Natural Science Foundation of China (2023JJ60267, 2022JJ50073)

<sup>1</sup>School of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou, Hunan 412007, China; <sup>2</sup>Hunan Key Laboratory of Electric Drive Control and Intelligent Equipment, Zhuzhou, Hunan 412007, China

\* E-mail: pengziran@hut.edu.cn