

## 基于改进 YOLOv5 的光伏组件缺陷检测

郭岚<sup>1,2,3</sup>, 刘正新<sup>1,2,3\*</sup><sup>1</sup>中国科学院上海微系统与信息技术研究所, 上海 200050;<sup>2</sup>上海科技大学物质科学与技术学院, 上海 201210;<sup>3</sup>中国科学院大学材料与光电研究中心, 北京 100049

**摘要** 电致发光(EL)检测技术作为太阳能电池和组件缺陷检测的重要手段被广泛运用,但是EL检查中的缺陷筛查仍然需要持续完善。为了克服以往研究中可识别缺陷的种类少、无法对缺陷进行定位、模型参数多体积大及检测速度慢的局限性,使用改进的YOLOv5网络对电致发光图片中常见的隐裂、断栅、裂片和黑斑4类主要缺陷进行检测和分类。使用Ghost模块代替YOLOv5骨干提取网络中的普通卷积模块,减少网络模型的参数量;为了保证良好的检测性能,在骨干网络尾端加入Squeeze-and-Excitation(SE)注意力模块,提升算法的目标检测能力;在特征融合网络中引入双向特征金字塔网络(BiFPN)结构,进一步加强网络的特征融合能力。结果表明,所提模型成功地识别和定位了4类常见的缺陷,与YOLOv5算法相比,模型体积减小了21%,在没有GPU加速的情况下,单张图片的检测速度提升了17.4%。

**关键词** 缺陷检测; 电致发光; YOLOv5; Ghost模块; 注意力机制; 特征融合

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP223155

## Improved YOLOv5-Based Defect Detection in Photovoltaic Modules

Guo Lan<sup>1,2,3</sup>, Liu Zhengxin<sup>1,2,3\*</sup>

<sup>1</sup>Shanghai Institute of Microsystem and Information Technology, Chinese Academy of Sciences, Shanghai 200050, China;

<sup>2</sup>School of Physical Science and Technology, ShanghaiTech University, Shanghai 201210, China;

<sup>3</sup>Research Center for Materials and Optoelectronics, University of Chinese Academy of Sciences, Beijing 100049, China

**Abstract** Electroluminescence (EL) inspection technology is widely used as an important means for solar cell and module defect detection. However, defect screening in EL inspection is still a major challenge. Herein, to overcome the limitations in previous studies, such as few types of defects to be identified, the inability to locate defects, the large size of model parameters, and slow detection speed, the upgraded YOLOv5 network is used to detect and classify the four types of defects that are commonly found in electroluminescent images, including crack, finger interruption, break, and black zone. This shows that the improved Ghost module extracts ordinary convolutional modules in the network to reduce number of network model parameters compared with the YOLOv5 backbone. Additionally, to ensure good detection performance, the Squeeze-and-Excitation (SE) attention module is added to the tail of the backbone network to improve the algorithm's target detection ability. In the neck part, the bidirectional feature pyramid network (BiFPN) structure is used to further strengthens the feature fusion capability of the network. Experimental results show that the proposed model successfully identifies and locates the four common defects, has a reduced volume by 21% compared with the YOLOv5 algorithm and achieves an improved single image detection speed by 17.4% without GPU acceleration.

**Key words** defect detection; electroluminescence; YOLOv5; Ghost module; attention mechanism; feature fusion

## 1 引言

在碳达峰-碳中和背景下,我国的光伏发电(PV)

技术发展迅猛。据统计,我国光伏装机量在2020年达150 GW,预计在2030年达到350 GW<sup>[1]</sup>。光伏组件是将太阳能转换为电能的核心器件,在组件的制造、运输

收稿日期: 2022-11-24; 修回日期: 2022-12-18; 录用日期: 2022-12-22; 网络首发日期: 2023-01-05

基金项目: 临近空间科学实验系统(鸿鹄专项)-临近空间用高效可靠能源系统(XDA17020403)

通信作者: \*z.x.liu@mail.sim.ac.cn

及使用过程中会产生各类缺陷,这些缺陷会不同程度地降低组件的光电转换效率和可靠性<sup>[2-4]</sup>。因此,为了获得最大收益,光伏组件的维护和检查至关重要。

电致发光(EL)成像是一种有效的组件缺陷检测手段<sup>[5-6]</sup>。通过施加正向偏置电压,向组件中注入大量非平衡载流子,非平衡载流子复合后释放能量产生光子,形成 700~1200 nm 光谱,CCD 相机能捕获这种光谱并形成 EL 图像。EL 图像的亮度与少数载流子扩散长度成正相关,缺陷区域的少数载流子扩散程度较低,EL 图像颜色较暗,因此 EL 成像可检测电池和组件中的缺陷。EL 图像中常见的缺陷有隐裂、断栅、黑斑、裂片等<sup>[7]</sup>。

随着智能技术的普及,使用计算机视觉技术辅助组件缺陷检测成为研究的热点<sup>[8-11]</sup>。但是传统的图像处理技术只能识别特定类型的缺陷,泛化能力弱。近年来,现代卷积神经网络(CNN)模型提高了计算机视觉系统的性能。2018 年 Bartler 等<sup>[12]</sup>首次验证了 CNN 实现 EL 图像缺陷检测的可行性。随后,VGG19 模型也被用于预测 EL 图像中存在缺陷的概率<sup>[13]</sup>。此外,VGG16、ResNet50 和 BAF-CNN 等模型<sup>[14-15]</sup>也被用于 EL 图像缺陷检测和分类,虽然分类精度不断提升,但是依然存在可识别缺陷种类少、无法对缺陷进行定位、模型参数量大和检测速度慢等问题。YOLOv5 是第五代单阶段(one-stage)目标检测算法<sup>[16]</sup>,该算法的模型体积小但性能优越,在诸多应用场景下实现了检测精度和速度的最佳平衡。据报道<sup>[17]</sup>,YOLOv5 算法

可对人群口罩佩戴情况进行检测,准确率达 97% 以上。在光伏领域,YOLOv5 已被用于可见光图像的分割和红外图像的故障定位<sup>[18]</sup>。在布匹的瑕疵检测应用中,注意力机制模块的运用能有效提升 YOLOv5 的检测精度<sup>[19]</sup>。研究发现,YOLOv5 算法中的普通卷积替换成 Ghost 卷积之后,对工业插件的 DR 图像进行缺陷检测时,模型体积显著减小了 31%<sup>[20]</sup>。此外,文献<sup>[21]</sup>证明了 Ghost 卷积和双向特征金字塔网络(BiFPN)的联合运用能显著优化 YOLOv5 网络的结论。

基于此,本文以 YOLOv5 模型为基础框架,引入 Ghost 模块<sup>[22]</sup>代替普通卷积,以减少网络参数量,提升模型的推理速度;融合 Squeeze-and-Excitation(SE)注意力结构<sup>[23]</sup>,通过对各通道的依赖性进行建模以提高对缺陷特征的代表能力;同时采用 BiFPN 结构<sup>[24]</sup>进行多尺度特征融合,增强特征提取能力,提升缺陷检测精度。

## 2 研究方法

### 2.1 EL 图像中的缺陷类型

文献<sup>[25]</sup>表明,晶体硅组件中的裂纹类缺陷出现概率约为 5%,对于单个组件而言,出现裂纹类缺陷的电池单元数  $k$  与组件中电池单元总数  $n$  呈泊松分布。裂纹类缺陷出现概率大且对组件的性能危害性高,因此针对隐裂、裂片、断栅和黑斑 4 类裂纹类缺陷展开研究,各类缺陷形态如图 1 所示。




图 1 组件中不同的缺陷类型。(a) 多晶中的隐裂;(b) 单晶中的隐裂;(c) 断栅;(d) 裂片和黑斑

Fig. 1 Different forms of defects in PV modules. (a) Micro-crack in polycrystalline silicon; (b) micro-crack in monocrystalline silicon; (c) finger-interruption; (d) break and black-zone

### 2.2 数据集

本研究所使用的数据集由公开数据集和私有数据集两部分组成。公开数据集由 Deitsch 等<sup>[13,26]</sup>创建并授权公开使用。作者对 44 张组件 EL 图像按照电池单元进行裁剪,形成 2624 张子图像。在公开数据集中选择 398 张含 4 类缺陷的 EL 图片作为训练样本,其中多晶图片 231 张,单晶图片 167 张。私有数据集采集自本实验室,包括 4 张单晶组件 EL 图片和 4 张多晶组件 EL 图片。利用文献<sup>[26]</sup>中的图像分割算法对组件 EL 图片按电池单元进行分割,得到 576 张 EL 子图像。分割效果如图 2 所示。图 2(a)是一张完整的组件 EL 图片,包含冗余的黑色背景信息,图 2(b)是经过正畸和裁剪

之后第 1 行第 5 列电池单元的 EL 子图像。公开数据集用于模型训练,私有数据集用于验证所提算法的检测性能。

利用 LabelImg 软件对 EL 图片中的缺陷进行标注,被矩形框标注的缺陷即为所提算法的检测目标。采用翻转、镜像、亮度调节、高斯扰动、平移 5 种图像增广技术对图像进行随机变化,生成相似的训练样本,将图片数量扩充至原始数据量的 6 倍。扩充数据集中隐裂的目标数为 12228 个,断栅的目标数为 786 个,将扩充后的训练数据划分成训练集和验证集,其中训练集图片 1910 张,验证集图片 478 张。各类数据标注数量细节如表 1 所示。




图 2 EL 图片分割实验结果。(a)组件EL图像;(b)第1行第5列EL子图像

Fig. 2 Experimental results of EL image segmentation. (a) EL image of a PV module; (b) EL subimage in row 1 and column 5

### 2.3 改进的YOLOv5缺陷检测算法

为了得到更快的推理速度且保持较高的识别精

度,提出了一种改进的YOLOv5缺陷检测算法。首先利用GhostNet结构对骨干网络进行轻量化处理,然后融合SE注意力机制和BiFPN结构提升算法的特征表达能力,提升算法的分类精度。所提网络模型的总体结构如图3所示。

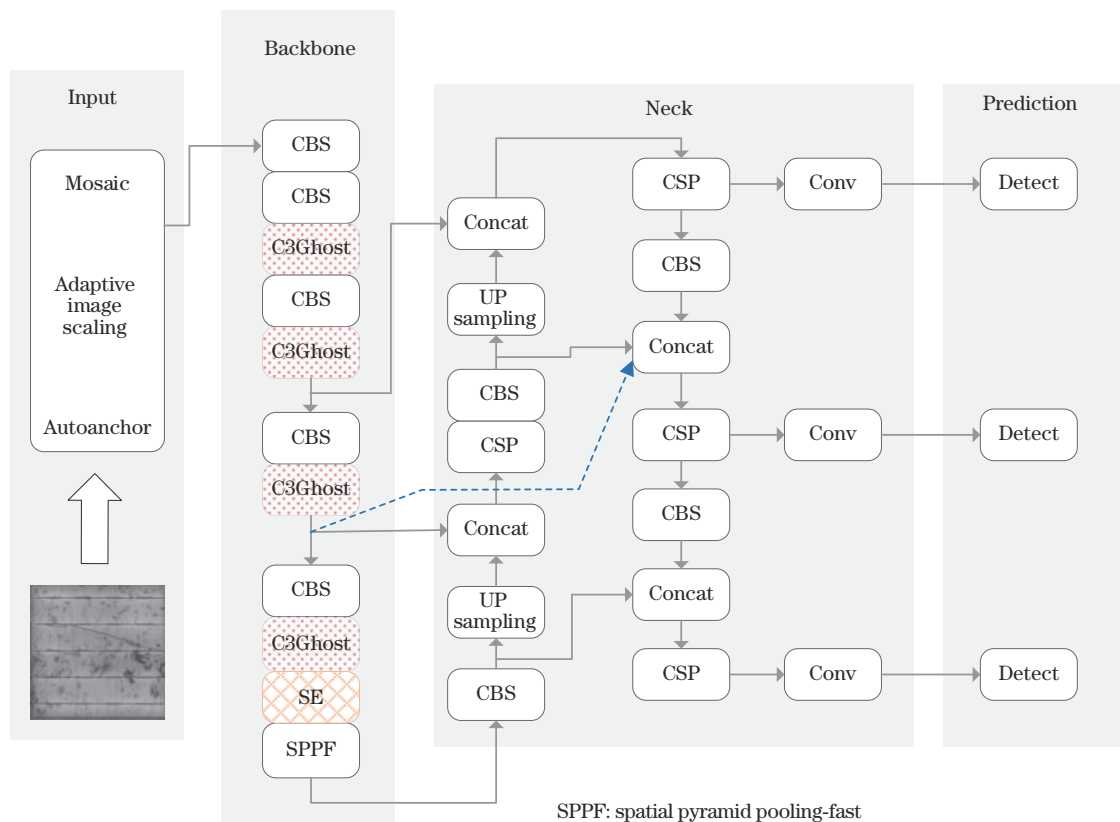
YOLOv5算法将目标检测问题视作回归问题。输入YOLOv5网络的图片首先被划分成 $s \times s$ 个网格,每一次算法迭代后在每个网格内会生成 $B$ 个目标框和分别标记为 $C$ 类不同目标的置信度。因此,网络输出的目标信息被表示成 $s \times s \times [B \times (4 + 1 + C)]$ 大小的三维张量,其中 $4 + 1$ 指表征目标框的5个参数,分别是目标框的4个顶点的坐标 $b_x, b_y, b_w, b_h$ 及置信度 $p_c$ 。

如图3所示,YOLOv5算法的网络结构可以划分为输入(Input)、特征提取骨干网络(Backbone)、多尺度特征融合网络(Neck)和输出预测(Prediction)4部分。根据网络深度,可以将网络划分为s、m、l和x等版

表 1 数据集各类别缺陷标注细节

Table 1 Details of defect labelling in the dataset

Dataset type	Data category	Number of pictures	Number of bounding boxes			
			Black zone	Crack	Inactive	Finger interruption
Public dataset	Augmented dataset for training	1910	1290	12228	2736	786
	Augmented dataset for validation	478				
Private dataset	Dataset for test	576	Unlabelled			



SPPF: spatial pyramid pooling-fast

图 3 改进的YOLOv5算法的网络结构

Fig. 3 Network structure of the improved YOLOv5 algorithm



本, 本文的研究对象为 YOLOv5s。在 Input 端, 使用 Mosaic 数据增强技术, 通过随机缩放、裁剪和排列 4 幅图像生成一张新图片, 以此丰富数据集, 提高网络的鲁棒性; 使用 Autoanchor 自适应锚框技术, 聚类生成符合数据集特征的锚框。Backbone 是基于 CSPDarknet53 的卷积神经网络, 通过多次卷积和池化从输入图像中提取不同大小的特征图。Backbone 部分包括 4 个 C3 模块, 共生成了 4 个不同尺度的特征图。Neck 网络由路径聚合网络 (PANet) 组成, 与特征金字塔网络 (FPN) 相比, 它增加了自底向上的特征融合层, 以此提高特征提取能力。Prediction 部分包括目标框回归和非极大值抑制两个过程。YOLOv5 采用完全交并比 (CIoU) Loss 作为回归运算的目标函数, 反向更新和优化网络参数; 采取非极大值抑制 (NMS) 方

法在众多目标框中筛选最优目标框。

为了减少卷积运算形成的特征图冗余, 将 Backbone 中的 C3 模块替换成 C3Ghost 模块。C3Ghost 模块源于 GhostNet 算法中的 Ghost bottleneck 结构, 它的核心是两个级联的 Ghost 卷积模块。Ghost 卷积模块的结构如图 4 所示。Ghost 卷积首先对输入特征图进行特征提取, 得到下一级的关键特征图, 然后对关键特征图进行简单的线性操作, 得到 Ghost 特征图, 最后, 将关键特征图和 Ghost 特征图堆叠形成完整的下一级特征图。Ghost 卷积利用网络特征映射通道之间的相似性, 在不同输出通道之间引入线性变换来取代原有的传统卷积运算, 以减少网络参数量和计算负载, 同时保持原有的特征映射通道数量。

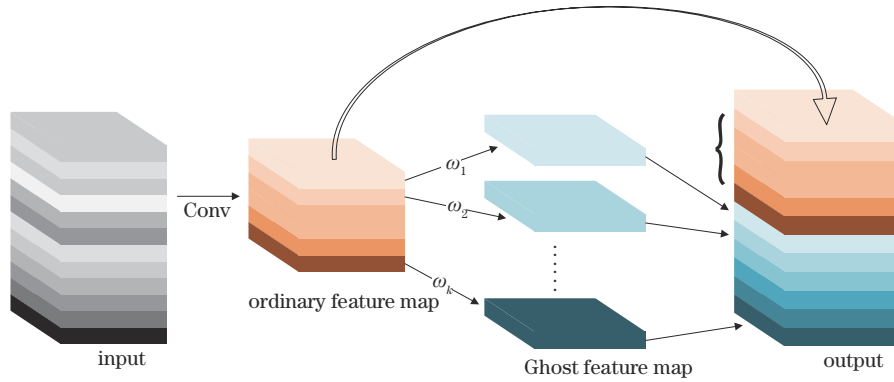


图 4 Ghost 卷积模块结构

Fig. 4 Schematic of Ghost convolution module

为了提升算法网络的特征提取能力, 在 Backbone 骨干网尾部引入 SE 注意力机制模块。SE 注意力机制的网络结构如图 5 所示。首先通过  $F_{sq}$  操作对特征通道进行全局平均池化, 得到一个  $1 \times 1 \times c_2$  大小的特

征图; 然后通过  $F_{ex}$  和  $F_{scale}$  操作对标量的每个元素乘以对应通道的归一化权重, 得到新的特征图。在模型中添加注意力机制, 神经网络可以自动获取每个特征通道的权重, 并通过权重过滤出关键特征。




图 5 SE 注意力模块结构

Fig. 5 Schematic of the SE attention convolution module

为了提升算法网络对不同尺度的特征图的融合能力, 将 YOLOv5s 的 Neck 网络中的 PANet 特征融合网络替换成 BiFPN 结构。BiFPN 的结构如图 6 所示。骨干网络对输入所提算法网络的 EL 图片进行特征提取后, 产生了  $40 \text{ pixel} \times 40 \text{ pixel}$ 、 $20 \text{ pixel} \times 20 \text{ pixel}$  和  $10 \text{ pixel} \times 10 \text{ pixel}$  3 个不同分辨率的特征图。低分辨率的特征图逐层向上经过 2 倍上采样之后与高分辨率的特征图融合, 高分辨率的特征图逐层向下经过 1/2 池化操作与低分辨率的特征图融合。此外, 与单向结

构的 FPN 相比, BiFPN 增加了一条从高分辨率特征图到低分辨率特征图融合的路径。与具有双向结构的 PANet 相比, 它删除了 PANet 对特征融合贡献较小的节点, 使得 BiFPN 比 PANet 更高效。

## 2.4 实验环境与参数设置

本研究的神经网络框架使用 PyTorch1.11 搭建, 实验平台操作系统为 Ubuntu 18.04 LTS, CPU 型号为 Intel (R) Xeon (R) @2.20 GHz, GPU 型号为 Tesla P100-PCIE-16 GB。Batch size 设置为 16, epoch 设置

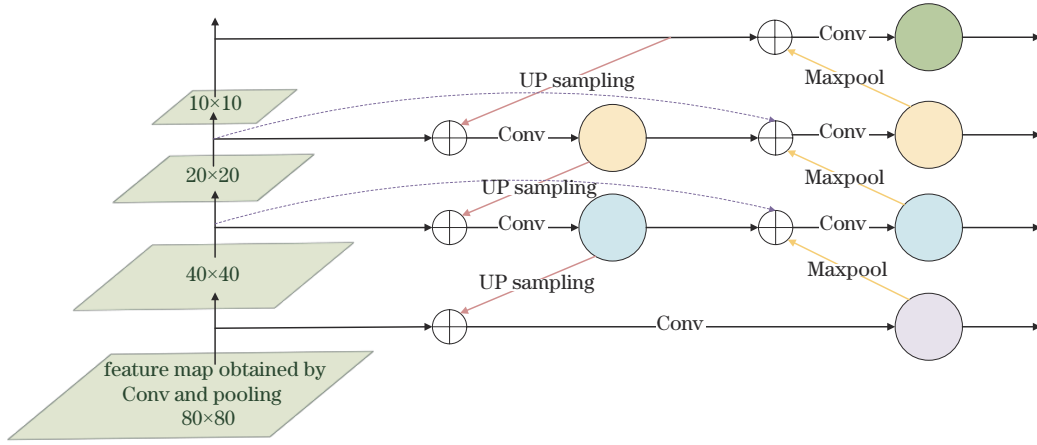


图6 BiFPN结构  
Fig. 6 Schematic of BiFPN

为 300 次,使用随机梯度下降法(SGD)对网络参数进行调整。图像预处理时将图像的宽和高均固定为 320 pixel。针对实验结果,选取平均精度、mAP@0.5 (置信度为 0.5 时的平均精度均值)、模型参数量(模型体积)和实际检测图像时的处理时间作为模型评价指标。

### 3 实验结果和分析

#### 3.1 结果评价指标

根据标记的真实标签和预测标签的组合,每张图片会被分为 true positive (TP)、true negative (TN)、false positive (FP) 和 false negative (FN) 4 类。其中 TP 是被正确识别的图像中实际存在的对象, FN 是图像中存在但未检测到的对象, FP 是被错误识别的图像中实际存在的对象, FN 是图像中存在但未被检测到的对象。

为了检验模型的性能,选取精确率 (precision,  $P$ )、召回率 (recall,  $R$ )、F1 score ( $F_1$ )、平均精度均值 (mAP) 作为评价指标。精确率表征模型的查准率,召回率表征模型的查全率, F1 score 是精确率和召回率的调和平均值。各指标的计算公式分别为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (1)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (2)$$

$$F_1 = \frac{2 \times P \times R}{P + R}, \quad (3)$$

$$P_{AP} = \int_0^1 P(R) dR, \quad (4)$$

$$P_{mAP} = \frac{\sum_{i=0}^N P_{AP_i}}{N}, \quad (5)$$

式中: AP 是 P-R 曲线下的面积;  $N$  代表训练样本的类别数; mAP 代表各类缺陷 AP 指标的平均值, mAP 数

值越大,表示模型识别效果越好。

#### 3.2 训练结果分析

将训练集和验证集输入网络进行训练。经过 300 轮迭代训练,得到训练集损失、验证集损失、mAP@0.5 及精确率  $P$  等指标。各指标随着迭代次数增加的变化趋势如图 7 所示。

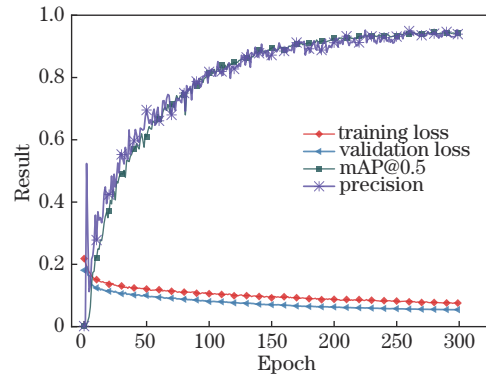


图7 训练过程中的结果变化趋势  
Fig. 7 Trend chart of results during training

由图 7 可知:训练集损失和验证集损失随着迭代次数的增加持续减小,迭代至 250 次左右,验证集和训练集的损失下降到 0.035 左右,趋近于 0,说明此时模型在本文数据集上已收敛;验证集上的分类精确率在前 25 次迭代有较大起伏,此后随着迭代次数的增加逐渐增大并收敛至 0.952 左右; mAP@0.5 在训练过程中持续增大,250 次迭代训练之后收敛于 0.947。

为了比较数据类别对检测结果的影响,对 4 类缺陷同时进行训练,训练结果如图 8 所示。所提模型在验证集上训练得到的混淆矩阵如图 8(a) 所示,混淆矩阵的每一行代表预测的类别,每一列代表实际标注的类别,对角线上的数值代表每一类被正确预测的比例。由此可知隐裂、裂片、黑斑和断栅的识别召回率分别为 94%、95%、93% 和 97%,所提模型对断栅的查全率最高。模型训练后的 P-R 曲线如图 8(b) 所示,

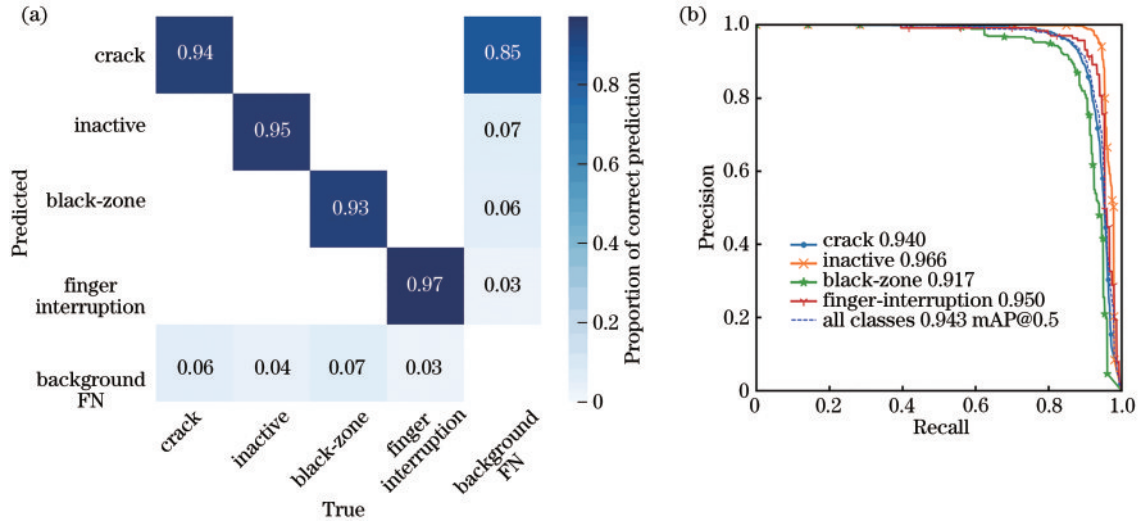


图 8 对不同种类缺陷进行检测的性能比较。(a)混淆矩阵;(b)P-R 曲线

Fig. 8 Comparison of the detection performance for different kinds of defects. (a) Confusion matrix; (b) P-R curve

每一条曲线下的面积代表平均准确率 (AP), 该数值被标注在图例中。由图 8(b)可知: 在不同置信度条件下, 对裂片的平均准确率为 96.6%; 对黑斑的平均识别精度为 91.7%, 最低; 裂片的 P-R 曲线依次包围了断栅、隐裂和黑斑的缺陷, 因此所提模型对裂片的查全率和查准率综合性最高, 分类性能最优, 对黑斑

的分类性能最差, 主要原因在于黑斑的样本数据量最少。

### 3.3 消融实验

为了验证各个改进方法对算法性能的作用, 进行递进消融实验, 并与原模型进行对比, 结果如表 2 所示。

表 2 消融实验结果

Table 2 Results of the ablation experiment

Model	Precision for different defects				Precision of all	Recall	mAP@0.5	Model size / 10 <sup>6</sup>
	Crack	Inactive	Black-zone	Finger-interruption				
Baseline	0.952	0.985	0.910	0.937	0.946	0.910	0.950	16.1
GhostNet	0.905	0.962	0.909	0.932	0.927	0.900	0.938	12.2
GhostNet-SE	0.953	0.973	0.897	0.938	0.941	0.886	0.943	12.6
GhostNet-BiFPN	0.927	0.973	0.901	0.937	0.935	0.888	0.939	12.4
GhostNet-SE-BiFPN	0.956	0.976	0.921	0.957	0.952	0.880	0.943	12.7

由表 2 可知: 原始的 YOLOv5s 模型在本文数据集上的平均分类精度为 94.6%, 模型体积为 16.1 × 10<sup>6</sup>; 将主干网络中的 C3 模块替换为 GhostNet 后, 平均分类精度与原模型相比略有降低, 为 92.7%, 但是模型体积降低为 12.2 × 10<sup>6</sup>, 下降了 24.2%; 在主干网尾部加入 SE 注意力机制模块后, 平均分类精度上升为 94.1%, 同时 mAP@0.5 与前一步改进相比也略有上升, 从 93.8% 上升至 94.3%, 此时模型体积为 12.6 × 10<sup>6</sup>; 在轻量化骨干网络的同时, 将颈部网络改为 BiFPN 结构, 模型的平均分类精度和 mAP@0.5 分别从 92.7%、93.8% 上升至 93.5% 和 93.9%; 最终, 应用前述三种技术对模型进行递进改进后, 模型对各类缺陷的平均分类精度达 95.2%, 较原模型相比提升了 0.6 个百分点, mAP@0.5 由 0.950 降低至 0.943, 降低幅度较小, 模型体积由 16.1 × 10<sup>6</sup> 减小为 12.7 × 10<sup>6</sup>, 减小了 21.1%。改进后的模型对隐裂、断栅和黑斑 3 类

缺陷的分类精度均有所提升, 总体而言, 本实验在保证较高的缺陷分类精度的同时减少了模型的参数量。

为了验证 SE 注意力机制和 BiFPN 结构的有效性, 对测试集图片进行热图实验, 结果如图 9 所示。第一行的左右两张图片分别是待测试图片和其在原模型 (YOLOv5s) 中的最高层特征图类激活可视化结果 (热力图)。第二行的图片是将原模型骨干网中的 C3 模块替换成 C3Ghost 模块之后的热图实验结果, 图 9(b) 和图 9(c) 中, 依次在图 9(a) 模型中添加了 SE 注意力模块和 BiFPN 结构, 图 9(d) 为所提算法处理的结果, SE 模块和 BiFPN 结构兼有。由图 9(b) 和图 9(a) 对比可知, 加入 SE 注意力模块之后, 图像中的缺陷部位的特征被加强, 来自图片背景的干扰被抑制, 证明了 SE 注意力机制能提升网络聚焦重要特征能力的结论。由图 9(c) 可知, 将网络的 Neck 部分改为 BiFPN 结构后, 重要特征被加强而背景中的无效特征被减弱, 这是因为 BiFPN 可



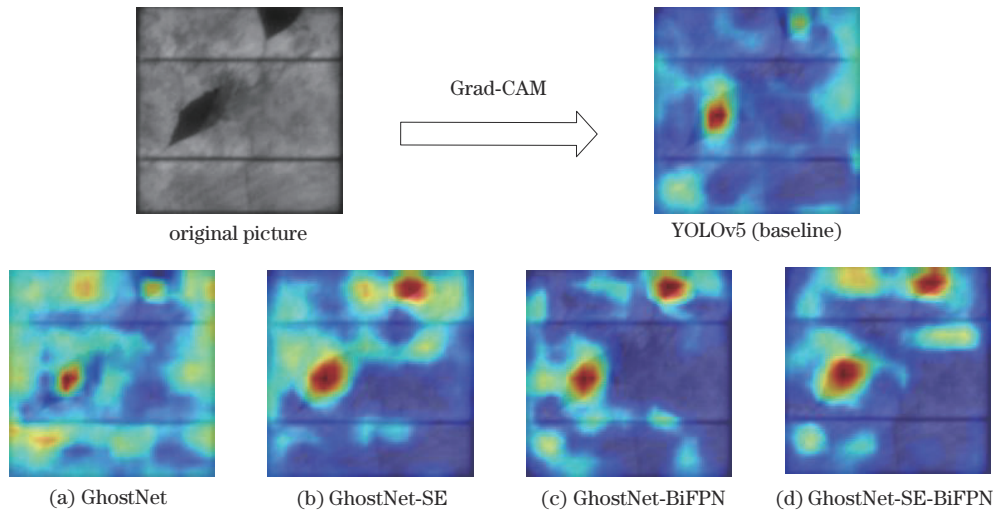


图9 算法改进前后的最高层特征图类激活可视化结果

Fig. 9 Visualisation of the highest-level feature maps by class activation mapping (grad-CAM) before and after algorithm improvement

以聚合不同分辨率的特征,由于深度网络中的特征更复杂,语义更丰富,利用深度网络进行不同尺度的特征融合可以提高算法的特征提取能力。由图9(d)可知,所提算法对检测目标具有一定的聚焦能力。

为了更直观地展示所提算法的效果,部分测试结

果的可视化展示如图10所示。图10中第1列和第3列图片分别展示了模型对第2列和第4列EL原图的诊断结果。诊断结果中包含表征缺陷位置信息的矩形框,对隐裂、黑斑、裂片及断栅4类缺陷的类型标注和判定为不同缺陷的置信度信息。




图10 部分测试结果可视化

Fig. 10 Visual presentation of partial test results

### 3.4 与其他算法的比较

为了验证所提算法性能的优越性,选取了经典的一阶段目标检测算法YOLOv3、YOLOv3-tiny和YOLOv7作为比较对象,对F1 score、mAP@.5、模型大小和单张图片处理时间这几个指标进行对比分析,结果如表3所示。

根据表3可知:YOLOv3模型的mAP@.5和F1 score这两个性能指标得分最高,但是模型体积最大,

且在实际检测中对单张图片的处理时间也最长;YOLOv3-tiny是YOLOv3的轻量化模型,虽然有着更小的模型体积和更快的图片处理速度,但是mAP@.5和F1 score这两个指标得分最差,不到0.9;所提算法与YOLOv5相比,mAP@.5指标低了0.7个百分点,F1 score高了0.6个百分点,模型体积减小了21%,总体来说对缺陷的查全率和查准率变化不大;YOLOv7算法在本文数据集上的分类精度为0.949,比所提算

表 3 与主流模型的性能对比  
Table 3 Performance comparison with mainstream models

Model	mAP@.5	F1 score	Model size /MB	Consuming time /ms	
				With GPU	out GPU
YOLOv3	0.980	0.984	127.6	45.4	988.4
YOLOv3-tiny	0.864	0.830	17.9	7.5	137.4
YOLOv5(Baseline)	0.950	0.946	16.1	19.9	164.5
YOLOv7	0.949	0.930	74.8	17.6	705.5
Proposed algorithm	0.943	0.952	12.7	22.2	135.8

法高 0.6 个百分点。在实际缺陷检测中,虽然 Tesla-P100 加速时所提算法比 YOLOv5 模型的单张图片处理时间慢 2.3 ms,但是仍然达到了实时检测的效果;在没有 GPU 加速时所提算法比 YOLOv5 快 28.7 ms,提速 17.4%。YOLOv7 算法在有 GPU 加速时平均推理速度比所提算法快 4.6 ms,但 YOLOv7 模型参数众多,体积大,在没有 GPU 加速时推理速度较慢。总体来说,所提算法在模型体积和分类性能、推理速度上达到了良好的平衡。

## 4 结 论

在 YOLOv5 算法模型的基础上提出了一种轻量化的光伏组件缺陷检测模型。首先,利用训练过程中产生特征图冗余的特点,将特征提取骨干网络中的 C3 模块替换成 GhostNet 结构,减少模型参数量。其次,引入可以选择性突出关键特征的 SE 注意力机制模块和高效的 BiFPN 结构,提升模型的分类精度。所提模型可用于检测和定位隐裂、断栅、裂片和黑斑 4 类主要缺陷。结果表明:与 YOLOv5 相比,所提轻量化模型在没有牺牲分类精度的前提下将模型体积压缩了 21%;与以往研究中的算法相比,所提方法具有更优的分类性能和更快的推理速度。此外,为了验证所提算法的泛化能力,在实验室采集到的组件 EL 图片上进行模型测试,结果显示所提算法能有效识别出 4 类缺陷,未来有望部署到组件清洗机器人、无人机等便携式组件运维设备中。遗憾的是,限于当前数据集的体量,未能覆盖实际生产和运用过程中的全部缺陷。未来的工作将考虑扩充数据样本,增加可检测的缺陷种类,并将工作聚焦于将现有模型应用到视频中的缺陷检测,进一步优化网络结构,减少模型参数量,同时提升检测速度和精度,使算法更具实用性。

## 参 考 文 献

- [1] Xu M, Xie P, Xie B C. Study of China's optimal solar photovoltaic power development path to 2050[J]. Resources Policy, 2020, 65: 101541.
- [2] Ahmad J, Ciocia A, Fichera S, et al. Detection of typical defects in silicon photovoltaic modules and application for plants with distributed MPPT configuration[J]. Energies, 2019, 12(23): 4547.
- [3] Hernández-Callejo L, Gallardo-Saavedra S, Alonso-Gómez V. A review of photovoltaic systems: design, operation, and maintenance[J]. Solar Energy, 2019, 188: 426-440.
- [4] Peinado Gonzalo A, Pliego Marugán A, García Márquez F P. A survey of maintenance management of photovoltaic power systems[J]. Renewable and Sustainable Energy Reviews, 2020, 134: 110347.
- [5] Fuyuki T, Kitiyanan A. Photographic diagnosis of crystalline silicon solar cells utilising electroluminescence[J]. Applied Physics A, 2009, 96(1): 189-196.
- [6] Mansouri A, Zettl M, Mayer O, et al. Defect detection in photovoltaic modules using electroluminescence imaging[EB/OL]. [2022-05-06]. <http://www.greateyes.de/projects/greateyes/static/custom/file/2012%20Defect%20detection%20in%20Modules%20with%20EL.pdf>.
- [7] Fuyuki T, Tani A. Photographic diagnosis of crystalline silicon solar cells by electroluminescence[M]//Proulx T. Experimental and applied mechanics. Conference proceedings of the society for experimental mechanics series. New York: Springer, 2011: 159-162.
- [8] Abdelhamid M, Singh R, Omar M. A review of microcracks detection techniques for silicon solar cells[J]. IEEE Journal of Photovoltaics, 2014, 4(1): 514-524.
- [9] Dunderdale C, Brettenny W, Clohessy C, et al. Photovoltaic defect classification through thermal infra-red imaging using a machine learning approach[J]. Progress in Photovoltaics: Research and Applications, 2020, 28(3): 177-188.
- [10] Liu H G, Ding W C, Huang Q W, et al. Research on the online defect detection method of solar cell components based on lightweight convolutional neural network[J]. The international Journal of Photoenergy, 2021, 2021: 7272928.
- [11] Yahya Z, Imane S, Hicham H, et al. Applied imagery pattern recognition for photovoltaic modules' inspection: a review on methods, challenges, and future development [J]. Sustainable Energy Technologies and Assessments, 2022, 52: 102071.
- [12] Bartler A, Mauch L, Yang B, et al. Automated detection of solar cell defects with deep learning[C]//2018 26th European Signal Processing Conference (EUSIPCO), September 3-7, 2018, Rome. New York: IEEE Press, 2018: 2035-2039.
- [13] Deitsch S, Christlein V, Berger S, et al. Automatic



- classification of defective photovoltaic module cells in electroluminescence images[J]. *Solar Energy*, 2019, 185: 455-468.
- [14] Tang W Q, Yang Q, Xiong K, et al. Deep learning - based automatic defect identification of the photovoltaic module using electroluminescence images[J]. *Solar Energy*, 2020, 201: 453-460.
- [15] Su B Y, Chen H Y, Zhou Z. BAF-detector: an efficient CNN-based detector for photovoltaic cell defect detection [J]. *IEEE Transactions on Industrial Electronics*, 2022, 69(3): 3161-3171.
- [16] Zhao Z Q, Zheng P, Xu S T, et al. Object detection with deep learning: a review[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(11): 3212-3232.
- [17] Alahmadi A N M, Rezk H. A robust single-sensor MPPT strategy for a shaded photovoltaic-battery system [J]. *Computer Systems Science and Engineering*, 2021, 37(1): 63-71.
- [18] Hong F, Song J, Meng H, et al. A novel framework for intelligent detection for module defects of PV plant combining the visible and infra-red images[J]. *Solar Energy*, 2022, 236: 406-416.
- [19] Jin R, Niu Q. Automatic fabric defect detection based on an improved YOLOv5[J]. *Mathematical Problems in Engineering*, 2021, 2021: 7321394.
- [20] Wang B W, Huang F. A lightweight deep network for defect detection of insert moulding based on X-ray imaging[J]. *Sensors*, 2021, 21(16): 5612.
- [21] Wang H Q, Shang S Q, Wang D W, et al. Plant disease detection and classification method based on the optimised lightweight YOLOv5 model[J]. *Agriculture*, 2022, 12(7): 931.
- [22] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1577-1586.
- [23] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [24] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2018, Seattle, WA, USA. New York: IEEE Press, 2020: 10778-10787.
- [25] Kontges M, Kurtz S, Packard C, et al. A review of the failures of photovoltaic modules[J]. *Report IEA-PVPS T13-01*, 2014: 33-35.
- [26] Deutsch S, Buerhop-Lutz C, Sovetkin E, et al. Segmentation of photovoltaic module cells in uncalibrated electroluminescence images[J]. *Machine Vision and Applications*, 2021, 32(4): 84.