

密集主干网络算法对太阳能电池的缺陷检测

唐政, 张会林, 马立新*

上海理工大学机械工程学院, 上海 200093

摘要 针对太阳能电池存在的缺陷问题,通过电致发光成像得到相关图像数据集,采用深度学习图像检测算法进行识别。对 YOLOv4 目标检测算法进行改进,将原算法的主干网络替换为 DenseNet121,利用 DenseNet121 中的密集块对特征图像信息进行密集连接,以提升检测精度和检测速度;采用 Softer-NMS 改进原算法中的非极大值抑制(NMS),提高边界框定位精确度,减少误检、漏检数量。由结果分析可知,在使用改进型算法后,模型检测精度提升 5.94 个百分点。同时,设置消融实验探究所提改进方法对模型性能的影响程度。在与其他相关算法的参数性能对比中,参数指标表现良好,证明了所提方法的有效性和可行性。

关键词 太阳能电池; YOLOv4; 目标检测; 特征提取

中图分类号 TP391.4 **文献标志码** A

DOI: 10.3788/LOP222422

Defect Detection for Solar Cells using Dense Backbone Network Algorithm

Tang Zheng, Zhang Huilin, Ma Lixin*

School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract This paper obtains image datasets through electroluminescence imaging and uses deep learning image detection algorithms to identify defects in solar cells. We improve the YOLOv4 target detection algorithm by replacing the backbone network of the original algorithm with DenseNet121 and connecting the feature image information through the dense blocks in DenseNet121 to increase the detection accuracy and speed. We also enhance the nonmaximum suppression (NMS) of the original algorithm with Softer-NMS to improve the positioning accuracy of the bounding box and reduce number of false and missed detections. The results indicate that the model's detection accuracy has increased by 5.94 percentage points due to the use of the improved algorithm. Moreover, ablation experiments are set to verify the impact of the proposed improved algorithm on the model performance. In the parameter performance comparison with other related algorithms, the parameter indicators perform well, proving the effectiveness and feasibility of the proposed algorithm.

Key words solar cell; YOLOv4; target detection; feature extraction

1 引言

光伏发电因低成本、便于维护、无污染等特点,如今已广泛应用于社会生产和生活。在环境、人为等外力作用下,光伏面板在生产使用过程中不可避免地会出现一些瑕疵和问题,这些瑕疵和问题对发电效率和用电成本造成一定影响。太阳能电池(PV)作为构成光伏组件的关键部件^[1],对其进行缺陷检测就显得尤为重要。

硅晶片作为生产太阳能电池板的主要材料,目前主要分为单晶硅和多晶硅两种类型。由于材质、特性

等因素的影响,太阳能电池的部分缺陷并不能通过人眼观测得到有效识别,但可以采用相应技术手段对其进行检测识别。目前已有多种方法应用于太阳能电池的缺陷检测。文献[2-3]利用红外热成像方式获取光伏板图像数据,并进行缺陷检测,该方法并不适用于表面纹理不规则的多晶硅。文献[4-5]采用超声波共振方法对硅晶片表面进行检测,对采集的频率数据与正常硅片的频率进行比较分析,从而判断PV是否存在裂纹缺陷,但该方法无法对裂纹缺陷位置进行有效定位。文献[6]对PV图像进行二值化处理,突出缺陷部位,并采用傅里叶变换进行处理和分析,提高对缺陷的

收稿日期: 2022-08-30; 修回日期: 2022-08-31; 录用日期: 2022-09-05; 网络首发日期: 2022-09-15

基金项目: 国家自然科学基金(61205076)

通信作者: *ma_eeepsi@163.com

检测能力。文献[7]采用光致发光方法获取硅片表面的荧光照片,进而判断缺陷种类及其所在位置。文献[8]通过 Canny 算子方法对图像进行边缘检测,标记出缺陷的边沿轮廓,实现对裂纹的检测识别。

近年来,随着人工智能技术的发展,深度学习图像检测方法也能够实现对光伏面板的缺陷检测。深度学习图像检测算法通过对大量图像数据进行标记学习,实现对检测目标特征参数的自主提取和识别,通过多轮迭代训练优化学习权重,提高检测效果。本文对获取的图像数据进行标记分类,并采用先冻结后解冻主干权重的方式对学习权重进行训练。将 YOLOv4 算法改进为密集主干网络算法,使该算法在多晶硅这种复杂场景里依然能准确检测出相应目标。对所提方法与其他方法进行漏检、误检、平均精确度(AP)、F1 值及相关综合参数的对比,结果证明所提方法较好实现了对太阳能电池缺陷目标的检测。

2 数据集获取和预处理

2.1 光致发光原理

电致发光成像作为一种无损、非接触式技术,目前主要用于 PV 缺陷检测、产品质量控制方面^[9]。电致发光测试流程如图 1 所示,通过对晶体硅片外加正向偏




图 1 电致发光测试流程

Fig. 1 Electroluminescence test procedure

置电压,向 PV 中注入大量非平衡载流子。由于晶体硅的 PN 结中存在电场,非平衡载流子在电场中不断进行运动、扩散。电致发光依靠从扩散区注入的非平衡载流子与多数载流子进行复合,发生跃迁并发出光子^[10-11]。再利用 CCD 相机捕捉到这些光子,并通过计算机处理生成相应图像,整个测试过程是在暗室中进行的。

2.2 缺陷分类

缺陷目标分为裂纹和断栅这两类。裂纹:硅材料脆度较大,在机械、应力作用下会产生裂缝、裂片^[12],如图 2(a)和图 2(b)所示。断栅:在生产过程中,由于印刷不良,PV 正面银栅线断开,硅晶片通入电流后,断栅附近电流密度较小,导致电致发光图像上呈现黑条状^[13],如图 2(c)和图 2(d)所示。




图 2 缺陷图像分类。(a)单晶硅裂纹;(b)多晶硅裂纹;(c)单晶硅断栅;(d)多晶硅断栅

Fig. 2 Defect image classification. (a) Single crystal silicon crack; (b) polysilicon crack; (c) single crystal silicon finger-interruption; (d) polysilicon finger-interruption

由图 2 可以看出:在单晶硅中,缺陷目标比较明显;在多晶硅中,由于晶界的影响,硅晶片表面纹理不均匀,含缺陷目标的图像场景较为复杂,检测识别难度相对增加。

3 密集主干网络算法

3.1 YOLOv4 算法

YOLOv4 网络结构包括主干网络(Backbone)、金字塔模块(SPP 和 PANet)、预测模块(YOLO Head)。YOLOv4 网络结构如图 3 所示。YOLOv4 的主干网络为 CSPDarkNet53,其作用是对输入图像进行初步特征提取。相比于 YOLOv3, YOLOv4 采用 CSP 结构对残差模块进行修改:对输入图像特征进行卷积处理,将其分为上、下两个分支,上分支通过 N 个残差组件进行堆叠,下分支则通过卷积处理后与上分支进行特征融合。SPP 模块由 13×13 、 9×9 、 5×5 三个不同尺度的

池化核组成,目的是对主干网络初步提取到的最后一个特征层进行加强提取^[14]。PANet 模块利用上采样、下采样及堆叠功能对特征图像进行反复提取,输出 3 个特征层供预测模块使用。YOLO Head 模块对 PANet 模块输出的 3 个特征层进行融合并解码预测,在得到检测目标的预测框后,对预测框的得分进行排序并采用非极大值抑制(NMS)进行筛选。

3.2 主干网络替换

当图像数据输入卷积神经网络时,随着卷积层数变深,特征图像从输出到输入的路径也随之变长,容易产生梯度消失问题。密集卷积网络(DenseNet121)通过密集块(dense block)在前面卷积层与后面卷积层建立密集连接,在输出特征层上加上输入特征层信息,充分利用前面得到的特征图^[15]。DenseNet121 网络模型参数如表 1 所示。

从表 1 可以看出,通过在卷积层之间加入密集块,

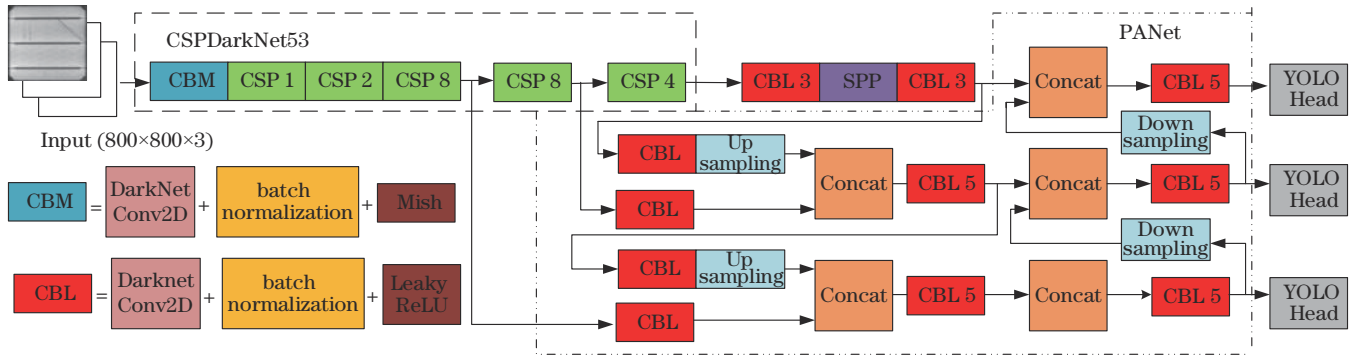


图3 YOLOv4网络结构

Fig. 3 YOLOv4 network structure

表1 DenseNet121模型参数
Table 1 DenseNet121 model parameters

Layer	Module	Stride	Output size
Convolution	7×7 Conv	2	800×800
Pooling	7×7 max pooling	2	400×400
Dense block	(1×1 Conv)×6		400×400
	(3×3 Conv)×6		
Transition layer	1×1 Conv	1	400×400
	2×2 average pooling	2	
Dense block	(1×1 Conv)×12		200×200
	(3×3 Conv)×12		
Transition layer	1×1 Conv	1	200×200
	2×2 average pooling	2	
Dense block	(1×1 Conv)×24		100×100
	(3×3 Conv)×24		
Transition layer	1×1 Conv	1	100×100
	2×2 average pooling	2	
Dense block	(1×1 Conv)×16		50×50
	(3×3 Conv)×16		
Classification layer			1×1

网络中各层连接更为紧密。本文将 DenseNet121 作为主干网络替换原算法的 CSPDarkNet53, 提升对特征图像的初步提取能力, 减少传输路径过长造成的图像特征缺失, 同时减少参数计算量。

3.3 非极大值抑制改进

NMS 是一种获取局部最大值的有效方法, 该方法对预测框进行有效筛选, 以此来提高目标定位精确度。YOLOv4 预测模块利用分类器生成多个预测框, 从而对目标进行判断。每个预测框都对应一个得分, NMS 对预测框的得分进行排序, 选出得分最高的预测框, 计算其余预测框与得分最高预测框的交并比 (IoU) 值^[16], 当 IoU 值大于某一阈值时, 将其删除。在未处理的预测框中选出得分最高的, 重复上述步骤进行迭代。NMS 虽能够通过筛选预测框实现对目标定位精确度的提高, 但也存在以下问题: 1) 预测框位置精确度不够; 2) 对排列密集、重合程度较高的检测目标会产生误检、漏检问题。

针对 NMS 存在的问题, 采用 Softer-NMS 进行改善。在 Softer-NMS 中, 预测框的位置满足高斯分布, 真实框的位置满足标准方差为 0 的高斯分布, 对应公式分别为

$$P_{\theta}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-x_e)^2}{2\sigma^2}}, \quad (1)$$

$$P_D(x) = \delta(x - x_g), \quad (2)$$

式中: x_e 为预测框的位置; x_g 为真实框的位置; σ 为标准差, 当 σ 越小, 表示置信度越高; $P_{\theta}(x)$ 为高斯分布, $P_D(x)$ 是标准方差为 0 的高斯分布, 当这两种分布值越接近时, 则代表模型算法能够越准确地对检测目标进行定位。Softer-NMS 采用 L_{loss} 对这两种分布的接近程度进行衡量, 相对应的公式为

$$L_{\text{loss}} = \int P_D(x) \log P_D(x) dx - \int P_D(x) \log P_{\theta}(x) dx = \frac{(x_g - x_e)^2}{2\sigma^2} + \frac{\log \sigma^2}{2} + \frac{\log(2\pi)}{2} - H[P_D(x)]. \quad (3)$$

式(3)利用方差形式描述预测框与真实框之间的距离关系。当 $P_{\theta}(x)$ 值越小, 则 L_{loss} 值越小, 两种分布也越接近, 同时表明 x_e 与 x_g 越接近, 即预测框与真实框距离越小, 此时预测框的定位越准确、有效。

在得到相应预测框后, 对于 IoU 值超过阈值的预测框, NMS 算法采用直接删除的方式, 而 Softer-NMS 则选取得分值最大的预测框, 并对该预测框与其相邻的预测框按 IoU 置信度进行加权平均, 最终确定预测框位置。设预测框 a 的位置为 x , 则预测框 a 经过加权平均后的最终位置公式为

$$p_i = e^{-[1 - \text{IoU}(x, x_i)]/\sigma_i}, \quad (4)$$

$$X = \frac{\sum_i p_i x_i / \sigma_i^2}{\sum_i p_i / \sigma_i^2}, \quad (5)$$

式中: X 为预测框 a 经过加权平均后的位置; x_i 表示预测框 i 的位置, 其中预测框 i 与预测框 a 的 IoU 值要求超过所设阈值, 设符合该要求的预测框为集合 $\{x_i\}$, 集合中元素数量为 i ; σ_i 为设定超参数; p_i 为相应的权重

系数; σ_i^2 为预测框 a 与预测框集合 $\{x_i\}$ 位置的标准差。分析式(4)和式(5)可以发现: 预测框 a 与预测框集合 $\{x_i\}$ 的位置方差越大, 预测框 a 的最终位置所受影响越小; 预测框 a 与预测框集合 $\{x_i\}$ 的 IoU 值越大, 预测框 a 的最终位置所受影响越大。

4 实验数据分析

4.1 实验参数设置

实验检测目标为太阳能电池单晶硅、多晶硅上的裂纹、断栅缺陷。对目标权重的训练采用迁移学习模式, 迁移学习可以对源域数据集中的图像信息及特征、关系进行多轮训练迭代, 这些信息逐步迁移到需要的目标检测任务中, 以此形成符合任务需求的独特训练权重。在迁移学习的训练模式中, 前 100 轮训练, 冻结主干权重, 加快训练速度, 对模型结构进行微调; 后 100 轮训练, 解冻主干权重, 提高检测精准度。实验测试平台环境为 Python3.7, CPU 为 INTER i7 8700, 显卡为 NVIDIA GTX1080, 内存 16G。模型对应参数设置如表 2 所示, 其中 N_T 表示训练集中的图片数量, N_V 代表验证集中的图片数量。

表 2 模型参数设置

Table 2 Model parameter setting

Parameter	Value
Input size	800×800
Freeze training epoch	100
Freeze training learning rate	0.001
Unfreeze training epoch	100
Unfreeze training learning rate	0.0001
Label_smoothing	0.005
$N_T:N_V$	4:1

4.2 图像检测结果

图 4 和图 5 为两种算法的图像检测结果, 第一行为单晶硅太阳能电池的检测结果, 第二行为多晶硅太阳能电池的检测结果。对比可以看出: 在单晶硅这种普




图 4 所提算法的检测结果

Fig. 4 Detection results of the proposed algorithm




图 5 YOLOv4 算法的检测结果

Fig. 5 Detection results of the YOLOv4 algorithm

通图像场景中, YOLOv4 的目标检测得分表现理想, 但出现了断栅目标漏检的情况; 在多晶硅这种复杂图像场景中, 所提算法由于使用了 Softer-NMS, 没有出现类似于 YOLOv4 算法的漏检、误检、边界框定位不准问题。在目标检测准确率上, 所提算法优于 YOLOv4 算法。

4.3 评价指标

为检验所提算法的整体性能, 选取 YOLOv4、Efficientnet-YOLOv3、YOLOv4-tiny、Faster-rcnn、YOLOv5 共 6 种检测算法进行对比。选用平均精度均值 (mAP)、检测速率 (Speed) 作为综合性能指标来评价图像检测算法模型。mAP 是对各个缺陷目标的平均精确度 (AP) 取均值的指标; AP 值为查准率 (precision) 与查全率 (recall) 所围成曲线 (P-R 曲线) 的面积^[17]; precision 指在模型算法检测为正确目标总数中, 实际正确目标所占比例; recall 为在实际正确目标总数中, 被模型算法正确识别目标所占的比例。precision 与 recall 的计算公式为

$$P_{\text{precision}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}, \quad (6)$$

$$P_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}}, \quad (7)$$

式中: N_{TP} 表示正确检测缺陷目标的数量, 即正确检测数, 本文设定当 IoU 值大于等于 0.5 时, 目标被正确识别; N_{FP} 表示错误检测缺陷目标的数量, 即误检数; N_{FN} 表示漏检缺陷目标的数量, 即漏检数。

所检测目标种类为 2, mAP 的计算公式为

$$P_{\text{mAP}} = \frac{1}{2} \sum_{i=1}^2 P_{\text{AP}_i}. \quad (8)$$

模型的查准率与查全率这两项指标相互制约, 通常当模型查准率较高时, 其查全率较低, 反之亦然, 故单一指标并不能有效地评价检测结果。选用 F1 值这一指标来衡量模型精确度, F1 值对准确率和召回率这两项指标进行调和平均, 兼顾了分类模型的准确率和召回率, 其值越大, 检测效果越好, 公式为

$$F_1 = \frac{2(P_{\text{precision}} \times P_{\text{recall}})}{P_{\text{precision}} + P_{\text{recall}}} \quad (9)$$

Speed 指在 1 s 内设备能检测的图像数量,用来显示模型的检测速度,公式为

$$S = \frac{1}{t_c} \quad (10)$$

式中: t_c 为检测一张图片所需的时间,一般 Speed 值越好,算法越能满足实际工程需求。

图 6 为几种算法的 AP 值对比,可以看出:所提算法对断栅、裂纹两个缺陷目标的检测精确度较高;YOLOv4、YOLOv4-tiny、Efficientnet-YOLOv3 的检测精确度也能满足需求;Faster-rcnn 对断栅类别的 AP 仅为 49.95%,不满足检测需求。

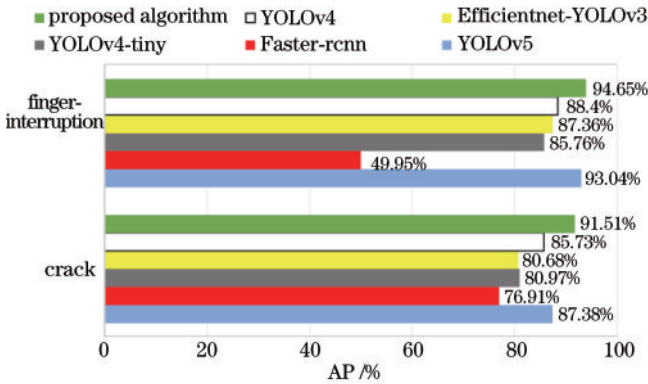


图 6 AP 值对比

Fig. 6 AP value comparison

图 7 为所提算法的损失值曲线。在前 20 轮,训练组、对照组损失值都在迅速降低;前 100 轮为冻结训练,学习率值设置相对较大且采用余弦退火算法,故损失值呈现周期波动;在 100~200 轮时,加入主干网络权重进行训练,由于学习率值设置变小,损失值波动逐渐减小,训练组损失值缓慢降低,并稳定在 1.7 左右。对照组由于训练图像数量相对较少,损失值未出现降低情况。

检测的缺陷目标中,断栅类别的总目标数为 3211 个,裂纹类别的总目标数为 1916 个。观察表 3 可以看




图 7 损失值曲线

Fig. 7 Loss value curve

表 3 不同算法的检测结果对比

Table 3 Comparison of detection results of different algorithms

Algorithm	Defect	TP	FP	FN
Proposed algorithm	Finger-interruption	3148	551	63
	crack	1865	325	51
YOLOv4	Finger-interruption	3027	711	184
	crack	1772	474	144
Efficientnet-YOLOv3	Finger-interruption	2907	912	304
	crack	1645	864	271
YOLOv4-tiny	Finger-interruption	2953	735	258
	crack	1659	589	257
Faster-rcnn	Finger-interruption	2775	17236	441
	crack	1721	10879	195
YOLOv5	Finger-interruption	3097	596	114
	crack	1827	412	89

出:由于更换了主干提取网络,所提算法的特征提取能力得以提高,正确检测的目标个数也变多;相比于其他算法,所提算法在采用 Softer-NMS 方法后,误检数、漏检数都相对较低;YOLOv4、YOLOv4-tiny、YOLOv5、Efficientnet-YOLOv3 在 3 个参数的表现上亦符合要求;Faster-rcnn 缺乏对图像的特征融合能力,对小目标检测能力不够,出现大量误检情况。

由图 8 和图 9 可以看出:在阈值为 0.3~0.7 时,所

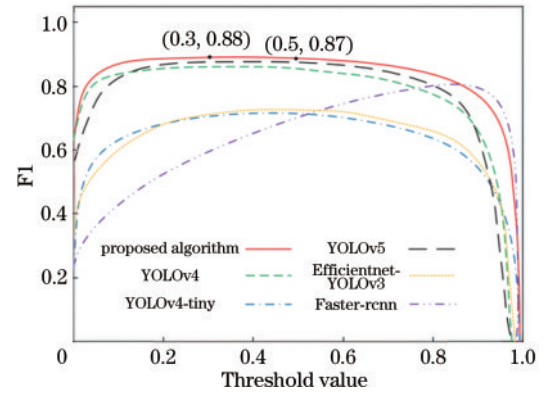


图 8 裂纹 F1 值

Fig. 8 F1 value of crack




图 9 断栅 F1 值

Fig. 9 F1 value of finger-interruption

提算法的 F1 值均大于其他算法;在默认阈值 0.5 的情况下,所提算法对裂纹、断栅的 F1 值分别为 0.87、0.88;裂纹目标类别中,所提算法的 F1 值极值点为 (0.3, 0.88),断栅目标类别中,F1 值极值点为 (0.21, 0.9)。

4.4 消融实验

为研究所提改进方法对模型综合性能指标的影响,设置消融实验进行验证,结果如表 4 所示。

表 4 的第 1~4 列分别表示对 YOLOv4 的主干网络进行替换的 4 种不同的主干特征提取网络。第 5 列和第 6 列表示采用原 NMS 方法及采用 Softer-NMS。从对比结果可以看出:由于 DenseNet121 在参数计算量上优于 CSPDarkNet53,故在检测速率上优于

YOLOv4 算法,同时 DenseNet121 对特征图像更强的提取能力也使得其的 mAP 值表现更好;Ghostnet、Mobilenetv1 在参数计算量上略少于 DenseNet121,故检测速度也稍优于 DenseNet121,但其 mAP 值不及 DenseNet121;在采用 Softer-NMS 方法后,模型的 mAP 值提高了 3.1 个百分点,Speed 值下降 3.08 frame/s;当两种改进方法同时使用时,DenseNet121 弥补 Softer-NMS 带来的检测速率下降问题,使模型的 Speed 值得以提升,同时 mAP 值也得到进一步提高。在误检、漏检对比方面,CSPDarkNet53 比 Ghostnet、Mobilenetv1 表现更好,在将 NMS 更换为 Softer-NMS 后,相应算法在正确检测数、漏检、错检数量上都有不错的表现。

表 4 消融实验

Table 4 Ablation experiment

Ghostnet	Mobilenetv1	CSPDarkNet53	DenseNet121	NMS	Softer-NMS	mAP / %	Speed / (frame·s ⁻¹)	TP	FP	FN
		✓		✓		87.14	22.73	4799	1185	328
			✓	✓		90.37	30.16	4908	1002	219
		✓			✓	90.24	19.65	4926	1096	206
			✓		✓	93.08	27.35	5013	876	114
	✓				✓	81.95	28.42	4611	1328	516
✓					✓	84.26	28.87	4685	1127	442

4.5 模型参数指标对比

表 5 为不同算法的指标对比,其中 Param 为参数计算量,用来衡量模型的参数计算复杂程度。由表 5 可以看出:所提算法的 mAP 值为 93.08%,优于其他几种算法,检测速率为 27.35 frame/s,达到基本检测速度要求,由于更换了主干网络,所提算法的参数计算量也明显低于原算法;YOLOv4、Efficientnet-YOLOv3 也达到了较高的检测精确度,但检测速率稍低于所提算法;YOLOv4-tiny 将 YOLOv4 算法的结构整体简化,当达到一定训练次数时,也能取得不错的检测成绩,由于本身轻量化的网络结构,YOLOv4-tiny 参数计算量远低于其他算法,其检测速度达 113.5 frame/s;Faster-rcnn 的检测精确度较低,相比 YOLO 系列单阶段目标检测算法,双阶段目标检测算法 Faster-rcnn 的第二阶段存在全连接层,需要大量参数计算,因此检测

速率较低。

5 结 论

针对太阳能电池板的缺陷问题,获取相关图像数据,对 YOLOv4 目标检测算法进行改进,并设立消融实验。所提改进方法对算法模型的 mAP 值和检测速度都有一定改善。在实验数据分析环节,通过对图像检测结果进行直观对比,看出改进算法在检测精确度及漏检率上都有一定改善。并对所提算法与其他几种算法进行 F1 值、AP 值、TP、FP、FN、mAP 值、检测速度对比,验证了所提方法的有效性,同时也为太阳能面板缺陷检测提供了相关参考。

参 考 文 献

- [1] 范程华. 太阳能电池片表面缺陷高效检测系统研究[D]. 合肥: 安徽大学, 2019: 12-17.
Fan C H. Research on highly efficient system for surface defects detection of solar cells[D]. Hefei: Anhui University, 2019: 12-17.
- [2] 柳扬, 陈美珍, 徐胜彬, 等. 基于热成像与灰度转换技术的光伏阵列缺陷检测方法[J]. 电子测量技术, 2021, 44(11): 96-102.
Liu Y, Chen M Z, Xu S B, et al. Defect detection method for photovoltaic arrays based on thermal imaging and gray conversion technology[J]. Electronic Measurement Technology, 2021, 44(11): 96-102.
- [3] 王亚丽. 基于红外热成像的太阳能板缺陷检测[D]. 杭

表 5 模型指标对比

Table 5 Comparison of model indicators

Algorithm	mAP / %	Speed / (frame·s ⁻¹)	Param / MB
Proposed algorithm	93.08	27.35	160.4
YOLOv4	87.14	22.73	244.6
Efficientnet-YOLOv3	84.02	23.20	154.1
YOLOv4-tiny	83.36	113.5	22.6
Faster-rcnn	63.48	12.06	108.7
YOLOv5	90.21	19.47	335.3

- 州: 中国计量学院, 2015: 8-14.
- Wang Y L. Defect detection of solar panels based on infrared thermal imaging[D]. Hangzhou: China University of Metrology, 2015: 8-14.
- [4] Belyaev A, Polupan O, Ostapenko S, et al. Resonance ultrasonic vibration diagnostics of elastic stress in full-size silicon wafers[J]. Semiconductor Science and Technology, 2006, 21(3): 254-260.
- [5] Dallas W, Polupan O, Ostapenko S. Resonance ultrasonic vibrations for crack detection in photovoltaic silicon wafers[J]. Measurement Science and Technology, 2007, 18(3): 852-858.
- [6] Dhimish M, Holmes V. Solar cells micro crack detection technique using state-of-the-art electroluminescence imaging[J]. Journal of Science: Advanced Materials and Devices, 2019, 4(4): 499-508.
- [7] Olsen E, Flø A S. Spectral and spatially resolved imaging of photoluminescence in multicrystalline silicon wafers[J]. Applied Physics Letters, 2011, 99(1): 011903.
- [8] 于博. 太阳能电池检测系统的运动控制实现及裂痕识别算法研究[D]. 长春: 吉林大学, 2010: 20-24.
- Yu B. Implementation of motion control module and study on crack identification algorithm in the solar cell detection system[D]. Changchun: Jilin University, 2010: 20-24.
- [9] 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.
- [10] 马桂艳, 张红妹, 史金超, 等. 基于电致发光的太阳能电池检测方法研究[J]. 光电子技术, 2020, 40(3): 213-216.
- Ma G Y, Zhang H M, Shi J C, et al. Study of electroluminescence imaging as a method to detect the defects of solar cells[J]. Optoelectronic Technology, 2020, 40(3): 213-216.
- [11] Chen H Y, Zhao H F, Han D, et al. Accurate and robust crack detection using steerable evidence filtering in electroluminescence images of solar cells[J]. Optics and Lasers in Engineering, 2019, 118: 22-33.
- [12] Tang W Q, Yang Q, Xiong K X, et al. Deep learning based automatic defect identification of photovoltaic module using electroluminescence images[J]. Solar Energy, 2020, 201: 453-460.
- [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] 李彬, 汪诚, 吴静, 等. 改进YOLOv4算法的航空发动机部件表面缺陷检测[J]. 激光与光电子学进展, 2021, 58(14): 1415004.
- Li B, Wang C, Wu J, et al. Surface defect detection of aeroengine components based on improved YOLOv4 algorithm[J]. Laser & Optoelectronics Progress, 2021, 58(14): 1415004.
- [15] 曾富亮, 胡文瑾, 何国源, 等. 基于DenseNet的唐卡图像分类[J]. 现代电子技术, 2022, 45(6): 153-157.
- Zeng F L, Hu W J, He G Y, et al. Thangka image classification based on DenseNet[J]. Modern Electronics Technique, 2022, 45(6): 153-157.
- [16] 张长伦, 张翠文, 王恒友, 等. 基于注意力机制的NMS在目标检测中的研究[J]. 电子测量技术, 2021, 44(19): 82-88.
- Zhang C L, Zhang C W, Wang H Y, et al. Research on non-maximum suppression based on attention mechanism in object detection[J]. Electronic Measurement Technology, 2021, 44(19): 82-88.
- [17] 高健宸, 张家洪, 李英娜, 等. 基于YOLOv4的绝缘子爆裂故障识别研究[J]. 激光与光电子学进展, 2022, 59(2): 0210005.
- Gao J C, Zhang J H, Li Y N, et al. Insulator burst fault identification based on YOLOv4[J]. Laser & Optoelectronics Progress, 2022, 59(2): 0210005.