

基于改进 YOLOX-s 算法的航天太阳电池缺陷检测

李振伟, 张仕海, 屈重年, 汝承印, 陈康静

(天津职业技术师范大学机械工程学院, 天津 300222)

摘要: 针对航天太阳电池表面缺陷检测问题, 提出基于机器视觉与深度学习的缺陷检测方法。通过航天太阳电池缺陷检测系统获取图像, 并依据企业电池片缺陷的分类标准构建航天太阳电池缺陷数据集。采用切片技术获取包含缺陷目标的子图像数据集, 解决卷积和下采样操作信息丢失而导致召回率低的问题。针对不同缺陷采取适当的图像增强方式进行扩充数据集, 以避免训练过程中因数据集不足导致的过拟合问题。采用深度可分离卷积、优化损失函数、双线性插值上采样及引入注意力机制等方法对 YOLOX-s 算法进行改进, 以获得综合效果最佳的航天太阳电池缺陷检测模型。通过不同数据集训练及检测精度指标对比, 以及消融实验验证改进模型的有效性。通过改进模型与同类主流模型对比实验, 验证改进模型在航天太阳电池缺陷检测方面的优越性。

关键词: 太阳电池; 机器视觉; 深度学习; YOLOX-s; 缺陷检测

中图分类号: TK51; TP391.5

文献标志码: A

0 引言

太阳电池作为太阳能发电系统中的核心部件, 其材料结构、制造工艺、表面缺陷等都是影响光伏发电系统发电效率和使用寿命的关键因素。目前, 实验室内的砷化镓太阳电池的光电转换效率高达 50%, 具有抗辐照性强、耐高温性能好等优点^[1], 广泛用于航天领域。但砷化镓太阳电池在生产过程中常出现电池裂、错位、气泡、盖片裂和盖片反等缺陷, 严重影响光电转换效率和太阳电池使用寿命。为此, 生产企业多采用人工全检的模式来尽量避免缺陷产品投入使用, 但该模式存在主观性强、标准不统一、成本高、工作量大、效率低, 以及疲劳而产生误检漏检等问题。

近年来, 基于深度学习的太阳电池缺陷检测方法具有精度高、速度快、鲁棒性强等特点, 并取得了一定的应用效果。例如, Deitsch 等^[2]利用卷积神经网络(convolutional neural network, CNN)对采用电致发光(electro luminescence, EL)方式获取的太阳电池缺陷图像进行缺陷检测, 取得了 88.42% 的平均精度均值, 而使用传统支持向量机方法检测得到的平均精度均值为 82.44%; 陶志勇等^[3]针对太阳电池电致发光图像, 将注意力机制和 Ghost 卷积层引入批标准化的 T-VGG 轻量级 CNN 模型, 提高了太阳电池缺陷的检测精度; Bartler 等^[4]通过对基于 EL 成像的太阳电池图像引入深度学习的检测方法, 实现了二分类问题 92.27% 的准确率;

邓堡元等^[5]通过采用深度卷积神经网络, 实现了对太阳电池内部缺陷和表面缺陷的有效识别; 张一平等^[6]设计了全连接辅助分类器生成式对抗网络(FC-ACGAN), 对已有的单晶硅太阳电池电致发光图像数据集进行数据增强, 并用于 LeNet 网络模型训练, 获得了较高的缺陷识别率; 蒋尚俊等^[7]提出一种基于迁移学习与 ResNet 的太阳电池缺陷检测方法, 并实现了模型快速训练并提高太阳电池缺陷检测的准确率。综上, 国内外相关学者将深度学习引入太阳电池缺陷检测, 已取得常规图像分析与处理方法难以实现的效果。

本文所研究航天砷化镓太阳电池, 其结构、外形、材料、生产工艺及缺陷特征与晶体硅电池均存在一定差异, 其应用领域对电池缺陷具有极低的容忍度。为提高航天太阳电池缺陷的检测精度, 本文针对航天太阳电池数据集的构建、预处理, 对 YOLOX-s 模型的优化与应用开展全面研究。

1 基于机器视觉的航天太阳电池缺陷检测系统

高精度视觉检测可获得高质量的图像信息, 将航天太阳电池缺陷特征更好地呈现出来, 进而用于模型训练和在线检测, 图 1 为基于机器视觉的航天太阳电池缺陷检测系统。图 1 中服务器控制上料机械手将电池抓取到传送带上, 电池依次经过 4 个检测工位, 4 个工位均采用工业灰度相机

收稿日期: 2023-05-10

基金项目: 天津市自然科学基金面上项目(22JCYBJC01640); 天津市教委科研计划重点项目(2022ZD025); 天津市研究生科研创新项目(2022SKYZ293)

通信作者: 张仕海(1977—), 男, 博士、教授, 主要从事智能控制、深度学习等方面的研究。zshky77@163.com

采集电池图像。工位 1 采用棒型白光光源,主要用于错位缺陷的检测;工位 2 采用单射蓝光源,主要用于电池裂缺陷的检测;工位 3 采用远心镜头+面板式红光源,主要用于气泡和盖片反缺陷的检测;工位 4 采用低角度环形白光光源,主要用于盖片裂缺陷检测。另外,同一种缺陷可能在多个检测工位体现,多工位的融合亦是提高缺陷检出率的重要举措。基于深度学习的缺陷检测系统对 4 个工位的图像依次识别,服务器根据检测结果控制分拣机械手进行缺陷与正常电池片的分拣。

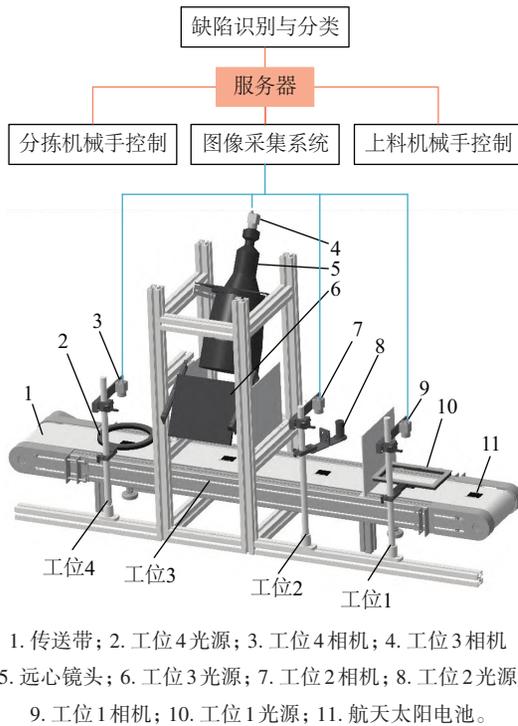


图1 航天太阳电池缺陷检测系统
Fig. 1 Defect detection system for aerospace solar cells

2 数据集的构建、预处理及标注

2.1 数据来源

本文所开展的航天太阳电池缺陷检测研究,目前尚无开源数据集可用,需基于现场的积累,结合数据增强、预处理等手段,构建完整的缺陷样本数据集。基于生产积累及图 1 图像采集系统,获得一定数量的 30 mm×40 mm 规格缺陷电池片原始图像。典型缺陷图像如图 2 所示。

2.2 数据裁剪

为满足不同尺寸电池的检测需求,各检测工位的视域均有一定冗余,实际的检测图片均有一定的无效区域。为降低对无效区域的计算量、改善卷积和下采样操作过程中信息损失导致召回率低的问题,首先对采集图像进行初步的边缘裁剪,仅保留电池及其边缘较小的区域用于模型训练和检测(图 2 所示)。

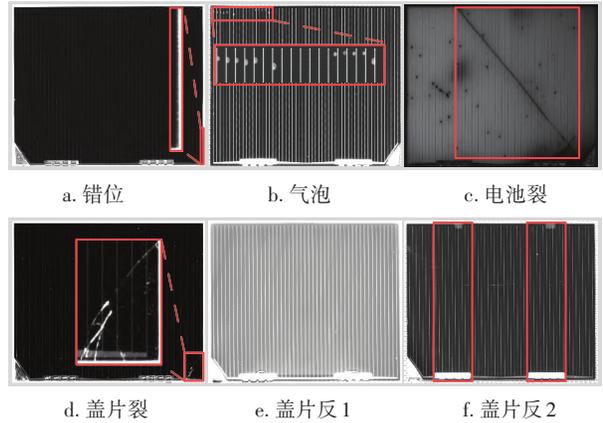


图2 航天太阳电池5类缺陷
Fig. 2 Five types defect of aerospace solar cells

基于图像边缘裁剪所获得的航天太阳电池图像分辨率为 1834 像素×1372 像素,若将图像压缩至分辨率为 640 像素×640 像素进行模型训练会导致小目标信息丢失严重,从而降低小缺陷检测的召回率。若使用原始图像尺寸训练会受制于 GPU 显存限制。为此,本文采用图像切片技术,将高分辨率图像切片为包含缺陷特征的子图像,再对每个小尺寸子图像进行训练和预测。图像切片方法如图 3 所示。

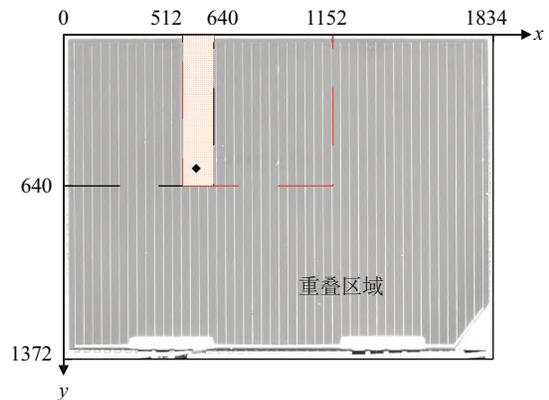


图3 图像切片方法
Fig. 3 Slicing method of image

切片过程中设置重叠比为 0.2,步长为 512。切片完成后,再逐一筛选包含缺陷目标的图像作为训练使用的数据集。通过这种方式可保留更多小缺陷信息,提高航天太阳电池缺陷的检测精度。

2.3 数据增强与扩充

在监督式学习过程中,为防止因样本数据不足导致训练过程中出现过拟合现象,对现有数据集进行图像增强以增加缺陷数据集的数量。其中,为尽可能保留小目标特征的完整性,对错位和盖片裂难检缺陷采用几何变换和亮度调整的增强方式;对电池裂、气泡和盖片反缺陷采用高斯模糊、对比度增强和几何变换的增强方式。图像增强前后缺陷数据集的数量变化如表 1 所示。以工位 3 电池图像为例,其增强效果如图 4 所示。

表 1 图像增强前后的缺陷数据集

Table 1 Defect datasets before and after image enhancement

数据集	错位	电池裂	气泡	盖片裂	盖片反	总计
原始图像数量/张	236	282	152	460	312	1442
增强图像数量/张	708	846	1280	920	984	4738

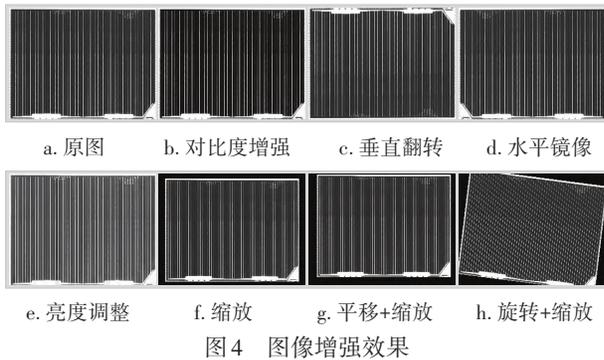


Fig. 4 Image enhancement effect

2.4 数据标注

利用 LabelImg 标注工具对图像进行标注,缺陷与标签的对应关系:错位 -mismatch、盖片裂 -glass_crack、电池裂 -cell_crack、气泡 -bubble、盖片反 -glass_contrary。将表 1 数据集的 90% 随机划分为训练集,数据集的 10% 随机划分为测试集,再从训练集中随机抽取 10% 作为验证集。

3 深度学习模型选取与优化

3.1 模型选取

通过对多种模型检测效果的比较分析,选取综合效果较好的 YOLOX-s 模型用于航天太阳能电池缺陷检测。YOLOX-s 网络结构如图 5 所示(图中引入了注意力模块)。

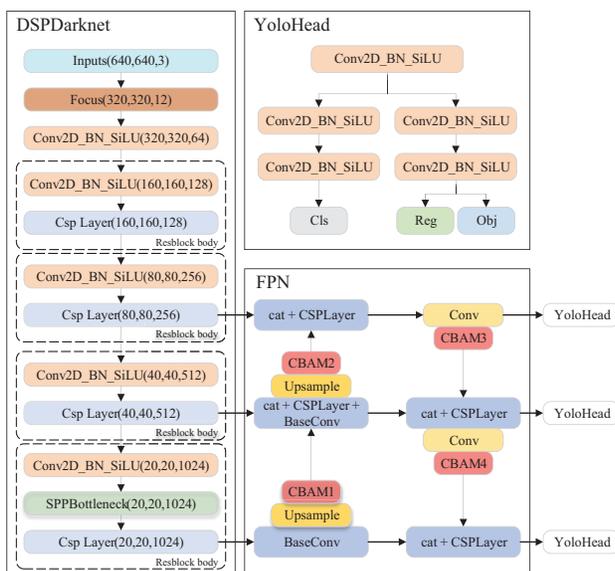


图 5 YOLOX-s 网络结构

Fig. 5 YOLOX-s network structure

YOLOX-s 模型的主要特点如下:

1) 通过引入 Anchor Free 方法,输出层直接计算目标的边界框坐标和类别预测值,避免了锚框点及其偏移量的计算量。相较于 Anchor Based 方法预测框中存在大量的负样本,Anchor Free 减少了负样本的预测,缓解了正负样本不平衡问题。Anchor Free 还避免了 Anchor Box 超参数的反复优化过程,降低了模型训练的难度。

2) 主干网络通过使用 Focus 结构对输入图像进行下采样和压缩,在保留输入特征图高维特征的同时减少了模型的计算量和内存占用。

3) 主干网络的 ReLU 激活函数替换为导数值较大的 SiLU 激活函数,加快了训练初期反向传播的计算。同时, SiLU 激活函数可将所有输入映射到非零值范围内,有效减少了信息丢失,显著提高了模型的泛化能力^[8]。

4) 采用动态标签分配策略,能动态调节阈值选择正负样本,更好地缓解了正负样本不平衡的问题,更好地适应了不同目标的检测场景。采用解耦头将目标分类和回归任务解耦,提高了模型的检测精度并加快网络收敛速度。

3.2 YOLOX-s 模型优化

YOLOX-s 性能强大,但对多类别目标识别场景,其检测精度存在一定差异。针对航天太阳能电池缺陷多类别、多尺度识别问题,本文从 YOLOX-s 模型的卷积操作、上采样方法和损失函数等方面开展研究,并引入注意力机制提高模型对航天太阳能电池各类缺陷的综合检测效果。

3.2.1 深度可分离卷积

深度可分离卷积(depthwise separable convolution, DSC)将标准卷积拆分为逐通道卷积(depthwise convolution, DC)和逐点卷积(pointwise convolution, PC)^[9]。传统卷积需同时考虑输入特征图中每个位置和每个通道之间的相关性。而 DS 只负责每个通道内部的相关性,PC 则负责将不同通道的结果进行融合。DSC 通过分步考虑图像的空间和通道信息,减少参数量和计算的复杂度,提高了深度神经网络的效率和轻量化程度。

为保证航天太阳能电池缺陷检测精度的同时减少模型的参数量和计算量,在 YOLOX-s 模型的主干网络(CSPDarknet)、特征提取网络(feature pyramid networks, FPN)和检测头(YOLO head)中采用 DSC。

3.2.2 注意力机制

卷积注意力模块(convolutional block attention module,

CBAM)是用于图像分类和目标检测的神经网络模块,由通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)组成^[10]。CAM使用全局最大池化和全局平均池化来获取特征图中每个通道的信息,并使用两个卷积层来融合池化后的特征图。使用sigmoid激活函数将得到的特征图缩放到 $[0, 1]$ 范围内,并作为通道注意力的权重系数。SAM则将通道注意力模块输出的特征图作为该模块的输入特征图,接着进行基于通道的全局最大池化和全局均值池化,并将两个池化结果进行融合。最后经过sigmoid生成特征图。

考虑到YOLOX-s特征金字塔中各层特征对于不同缺陷类别的检测具有不同的重要程度。通过引入注意力机制,可更加灵活地调整特征的权重,更好地适应不同的检测目标。另外,不同层级的特征可能存在大量冗余信息,而注意力机制可帮助模型快速定位重要特征,从而减少不必要的计算和存储开销。因此,在YOLOX-s特征金字塔的上采样和下采样后引入注意力机制CBAM(参见图5)。

3.2.3 双线性插值上采样

YOLOX-s网络Neck特征融合的核心是特征金字塔(feature pyramid networks, FPN)和路径聚合(path aggregation networks, PAN)^[11]。在PAN结构中,使用最近邻插值完成上采样操作,该方法计算速度快,但采样效果不佳。相比于邻近插值和单次线性插值上采样方法,双线性插值具有更好的平滑性和图像质量;相比于双三次插值上采样方法,双线性插值具有更快的训练速度。本文使用双线性插值进行上采样,在保证训练速度的同时减少缺陷特征在采样过程中的信息损失。

3.2.4 损失函数

损失函数用于衡量模型预测值与真实值之间的偏离程度。YOLOX-s目标检测算法中,损失函数主要由回归损失、置信度损失和类别损失组成。

目前,常用的回归损失函数包括交并比(intersection over union, IOU)^[12]、广义交并比(generalized intersection over union, GIoU)^[13]、距离交并比(distance intersection over union, DIOU)^[14]、完全交并比(complete intersection over union, CIOU)^[15]等方法,这些方法各有优缺点,且暂无一种通用的损失函数适用于所有的目标检测任务,针对航天太阳能电池多缺陷目标的定位和分类问题,采用实验对比方法选取最优的回归损失函数。

类别损失是用于解决目标检测模型在训练过程中存在正负样本不平衡问题和检测难易程度不平衡问题的损失函数。二元交叉熵损失函数解决了正负样本不平衡问题,但一阶段检测算法的精度同样受限于难易检测程度不平衡问题。

针对该问题,Focal Loss损失函数通过引入调制系数降低易分类样本权重,使模型训练时更加注重难分类目标的损失。在航天太阳能电池缺陷中,盖片反、电池裂和气泡是易检测样本,而错位、盖片裂属于难检测样本,引入Focal Loss损失函数使模型更加关注难检样本,从而提高模型的综合检测效果。

4 实验分析

4.1 模型训练

实验平台采用Intel® Core™ i9-12900K处理器,图形处理器为NVIDIA GeForce RTX3080Ti,内存为32 GB,显存为12 GB。采用Pytorch深度学习框架,并使用CUDA10.1和对应版本的CUDnn进行GPU加速训练。本文模型的训练参数统一设置如表2所示。训练过程中采用迁移学习方式,并冻结训练前50世代提高模型的收敛速度。

表2 训练参数设置

Table 2 Training parameters setting

参数	取值	参数	取值
Input_shape	[640, 640]	Optimizer_type	adam
Init_lr	0.001	Momentum	0.937
Min_lr	0.00001	Lr_decay_type	cos

4.2 数据集优化方案分析

为验证所提出切片方案的有效性,分别基于原始VOC数据集和切片VOC_Crop数据集训练YOLOX-s模型,并控制训练参数一致。最终两个模型的评估结果对比如表3所示。为评估模型的检测性能,引入平均精度(average precision, AP)、平均精度均值(mean average precision, mAP)、准确率 P 、召回率 R 和F1分数、帧率(frames per second, FPS)等指标。其中,AP为 P - R 曲线下包含的面积,mAP为检测多个类别时所有类别AP的平均值,mAP@0.5是IOU阈值为0.5时的mAP。 P 反映模型预测的所有目标中预测正确的比例, R 反映所有真实目标中模型预测正确的比例。F1分数同时考虑了 P 和 R 两个指标,是两个指标的调和平均值。FPS是反映目标检测速度快慢的指标。

表3中,基于VOC数据集训练的模型,其mAP为92.56%,错位和盖片裂缺陷F1分数均为0.85;基于VOC_Crop数据集训练的模型,其mAP为93.73%,盖片裂F1分数为0.9,错位F1分数达到0.93,且检测速度显著提高。表3结果证实:由于卷积和下采样过程会导致信息损失,使用VOC数据集训练时小目标信息提取难度大,错位和盖片裂的召回率较差。使用切片方案可显著提高小目标错位和盖片裂缺陷的召回率。

表3 模型评估结果对比

Table 3 Comparison of models evaluation results

数据集	缺陷标签	F1 分数	R/%	P/%	AP/%	mAP@0.5/%	FPS/(帧/s)
VOC	bubble	0.94	92.45	95.45	94.09		
	cell_crack	0.96	95.80	96.61	97.12		
	glass_contrary	0.99	100.00	98.62	100.00	92.56	1.28
	glass_crack	0.85	79.71	90.16	85.99		
	mismatch	0.85	80.58	90.22	85.59		
VOC_Crop	bubble	0.95	96.25	93.90	96.00		
	cell_crack	0.86	85.56	85.56	86.92		
	glass_contrary	1.00	100.00	100.00	100.00	93.73	3.13
	glass_crack	0.90	89.19	90.83	89.21		
	mismatch	0.93	93.75	92.59	96.53		

4.3 消融实验

为研究不同改进方法对 YOLOX-s 模型检测精度的影响,设计多组实验对改进模块进行对比。模型训练均使用 VOC_Crop 数据集并控制训练参数一致。实验结果如表 4 所示。

在损失函数方面,对比 IOU、GIOU、DIOU 和 CIOU 这 4 种回归损失函数,基于 GIOU 损失函数的 v1 模型 mAP 最高,达到 94.96%,说明 GIOU 损失函数能更好地反映航天太阳能电池缺陷真实框与预测框的位置关系,更适用于航天太阳能电池缺陷的检测。而 v4 模型通过引入 Focal Loss 类别损失函数降低易分类样本权重,使模型训练时更注重难分类目标的损失,显著提高模型的综合检测效果。

在注意力机制方面,引入 CBAM 注意力模块的 v5 模型,其 mPA 比原模型 YOLOX-s 提高了 0.37 个百分点,表明

CBAM 能自适应地选择感兴趣的图像区域,从而提高目标检测模型的性能。

在卷积模块方面,相较于采用标准卷积的原模型 YOLOX-s,基于 DSC 的 v6 模型不仅参数量降低了 1.535×10^6 (参见表 5),其 mAP 提高了 0.85 个百分点。另外,基于双线性插值上采样(Bilinear)的 v7 模型相较于使用最近邻插值上采样的原模型,其 mAP 提高了 0.6 个百分点。

消融实验结果表明:GIOU 回归损失函数和 Focal Loss 类别损失函数能显著提高模型对航天太阳能电池缺陷目标的检测性能。此外,通过引入注意力机制、将最近邻插值替换为双线性插值上采样,以及标准卷积替换为 DSC 等均可在不同程度上提高模型的检测性能。综合以上方法对 YOLOX-s 改进的模型,其 mAP 达到 96.55%,较原 YOLOX-s 模型提高 2.82 个百分点,验证了改进模型检测性能的优越性。

表4 消融实验结果

Table 4 Results of ablation experiment

模型	IOU	GIOU	DIOU	CIOU	Focal Loss	CBAM	DSC	Bilinear	mAP@0.5/%
YOLOX-s	√								93.73
v1		√							94.96
v2			√						94.78
v3				√					93.96
v4					√				95.06
v5						√			94.10
v6							√		94.58
v7								√	94.33
改进模型		√			√	√	√	√	96.55

4.4 YOLO系列算法对比分析

为进一步验证改进方案的检测性能,选择YOLO系列主流模型与其对比实验。YOLOv5-s、YOLOv8-s和YOLOX-s模

型均采用原始VOC数据集训练,本文改进模型采用切片VOC_Crop数据集训练,设置相同的训练参数。模型性能对比结果如表5所示。

表5 模型性能对比

Table 5 Comparison of model performance

模型	mAP@0.5/%	F1分数					参数量/ 10^6	FPS/(帧/s)
		bubble	cell_crack	glass_contrary	glass_crack	mismatch		
YOLOv5-s	86.34	0.91	0.97	0.99	0.83	0.09	7.03	1.46
YOLOv8-s	90.43	0.89	0.97	1.00	0.81	0.46	11.17	1.41
YOLOX-s	92.56	0.94	0.96	0.99	0.85	0.85	8.94	1.28
改进模型	96.55	0.94	0.93	1.00	0.92	0.87	7.40	2.85

从表5数据可知,相较于YOLOv5-s模型,改进模型在增加较少参数量的情况下,错位和盖片裂缺陷的F1分数分别提高了0.78和0.09;相较于YOLOv8-s模型,改进模型的参数量降低了 3.763×10^6 ,且错位和盖片裂缺陷的F1分数分别提高了0.41和0.11;相较于YOLOX-s原模型,改进模型的mAP提高了3.99个百分点,并降低了 1.535×10^6 的参数量。综合而言,本文改进的YOLOX-s模型综合检测性能最佳,mAP最高,达到96.55%,FPS最快,达到2.85帧/s。

训练过程中4种模型的mAP变化如图6所示。可看出解冻训练(50 epoch)之后,本文改进模型的收敛速度快、验证集上的mAP高。改进模型训练损失和验证损失的变化过程如图7所示。随着训练次数的增加,训练损失和验证损失逐渐降低,并最终趋于收敛。4种模型对同一组典型缺陷电池片的检测效果对比如图8所示。

由图8可看出:4种模型均能准确检测出电池裂、气泡及盖片反缺陷及位置。对于错位和盖片裂难检缺陷,本文改进模型均能准确检出,而其他3种模型均存在漏检情况,且改进模型检测的综合精度值较高。

为进一步验证改进模型的应用效果,现场随机选出一定数量的典型缺陷电池进行在线检测,现场应用效果的对比结果如表6所示。由表6得出:1)由于气泡、盖片裂和错位存在较多的小目标缺陷,改进模型对该缺陷的正检率明显高于另外3种模型,说明改进后的模型对航天太阳能电池缺陷(尤其是小目标缺陷)的检测精度较高;2)由于盖片反特征较易识别,4种模型均可100%检出;3)电池裂由于存在部分较大缺陷(裂纹延伸

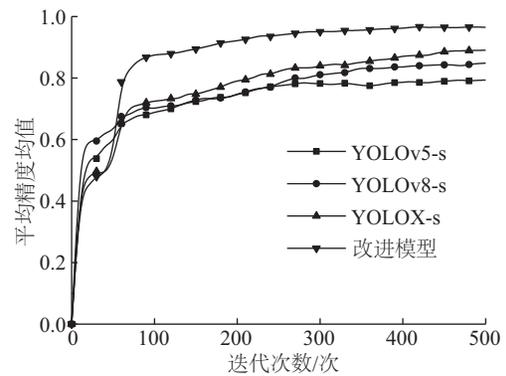


图6 不同模型的平均精度均值曲线
Fig. 6 mAP curves of different models

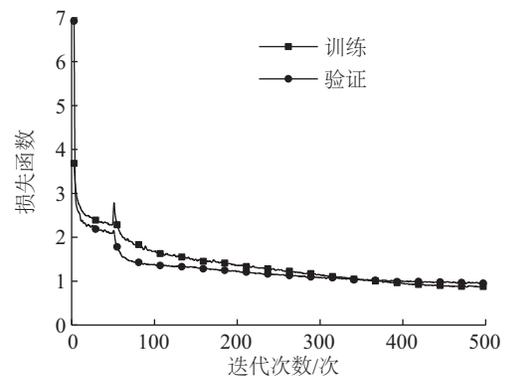
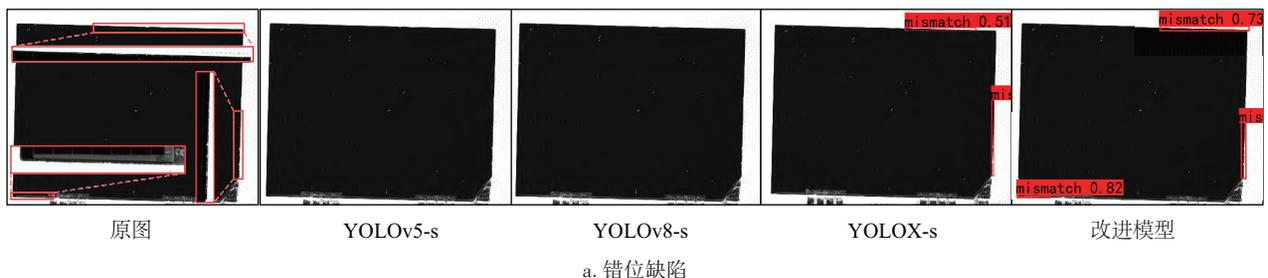


图7 改进模型的损失曲线
Fig. 7 Loss curves of improved model



a. 错位缺陷

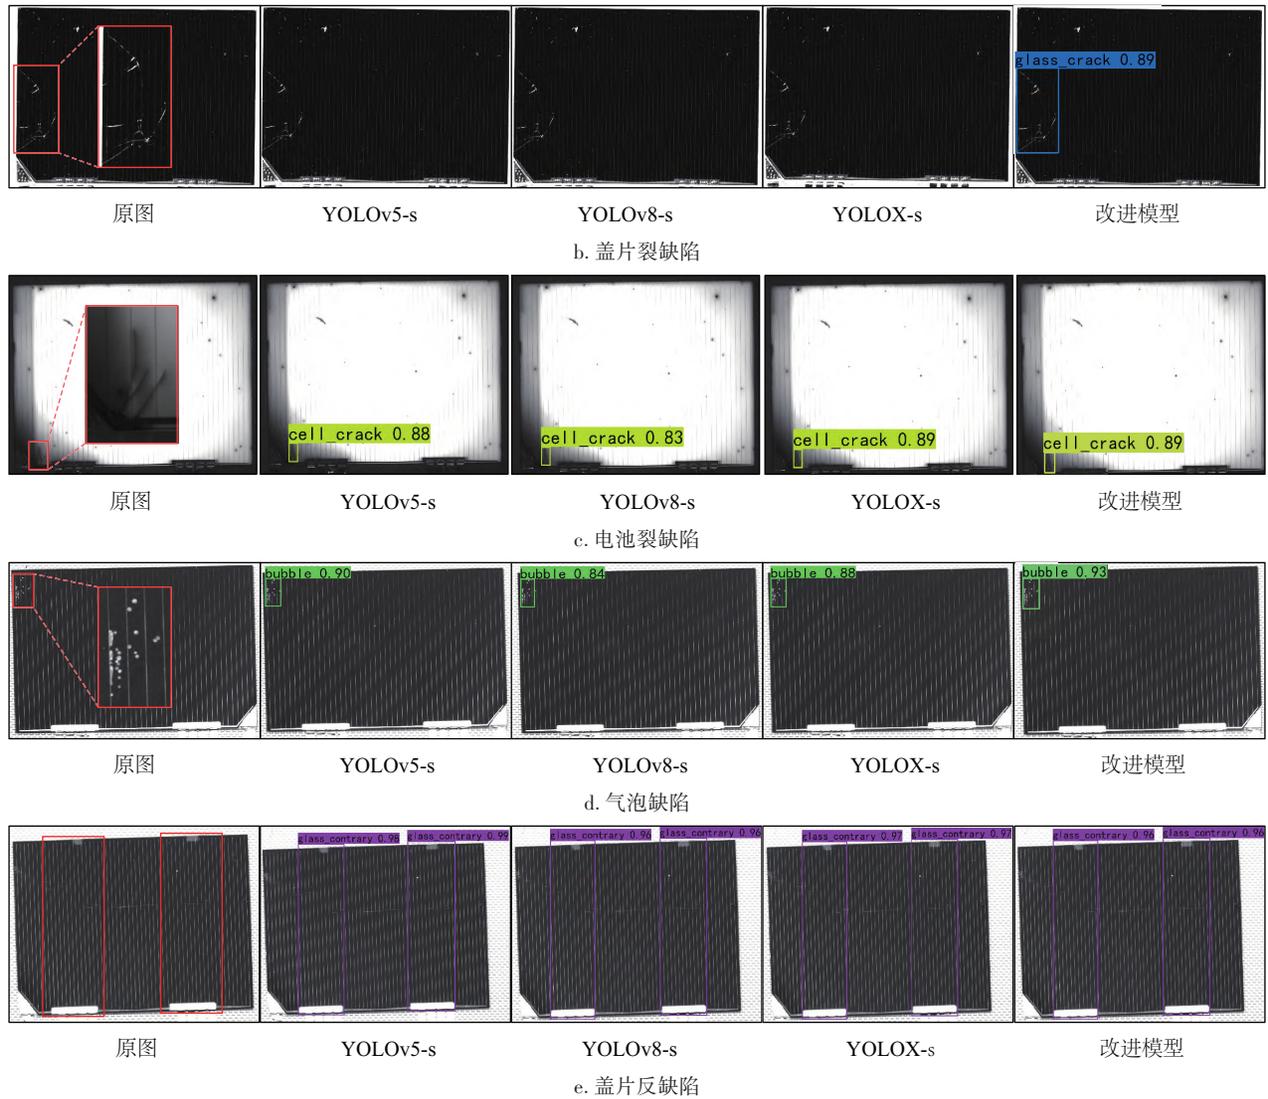


图 8 4 种模型对同一组典型缺陷检测的效果对比

Fig. 8 Detection effect of four models for same group solar cells with typical defects

表 6 现场应用效果对比

Table 6 Comparison of field application effects

模型	气泡(159片)		电池裂(119片)		盖片反(143片)		盖片裂(69片)		错位(103片)		正常电池(593片)	
	漏检	正检率	漏检	正检率	漏检	正检率	漏检	正检率	漏检	正检率	误检	过检率
YOLOv5-s	16	0.90	5	0.96	0	1.00	17	0.75	98	0.05	25	0.04
YOLOv8-s	23	0.86	5	0.96	0	1.00	20	0.71	71	0.31	19	0.03
YOLOX-s	12	0.92	5	0.96	0	1.00	14	0.80	20	0.81	28	0.05
改进模型	6	0.96	12	0.90	0	1.00	8	0.88	4	0.96	42	0.07

长),切片裁剪影响了电池裂大尺度缺陷的整体特征,进而导致训练出的模型检测结果不如另外 3 种模型。为进一步验证,在数据构建过程中,针对含有电池裂缺陷的电池图像不进行切片,直接原图标注、训练并测试,最终结果表明改进模型对其他缺陷检测效果不变,对电池裂缺陷亦获得 96% 的检

出率;4)针对正常电池测试,由于改进模型提高了对小目标缺陷的检测能力,部分由于裂纹延伸小而被客户视为质量合格的电池亦被改进模型检出,进而导致改进模型的过检率相对较高。实际应用中,基于企业的质量控制,所生产的航天太阳能电池缺陷率已控制在 5% 以下,由于整体数量少,适当的

过检量是允许的,可通过人工对所检测出的缺陷电池进行复核,关键在于提高对真实缺陷电池的检出率、避免漏检造成的损失。

综合而言,改进的YOLOX-s模型以较小的参数量取得了较好的检测效果,尤其是对小缺陷难检目标的检出率较高、FPS快,适合航天太阳能电池表面缺陷的检测。

5 结论

针对航天太阳能电池缺陷的检测需求,研究机器视觉与深度学习相结合的缺陷检测方法,主要研究内容及结论如下:

1)基于企业生产现场,设计了航天太阳能电池视觉检测系统,并构建了包含多种缺陷样本的数据集。针对不同缺陷特征,采用不同的数据增强方案,扩充了样本数据集。采用切片技术,获得包含缺陷目标的子图像数据集,使图像保留更多小尺度缺陷信息。实验表明:基于切片子图像数据集训练的模型,在测试集上的mAP提高了1.17个百分点,且错位和盖片裂难检缺陷的F1分数明显增大,FPS显著提高。

2)综合DSC、优化损失函数、双线性插值上采样及引入注意力机制等方法对YOLOX-s算法进行改进。消融实验结果表明:GIOU回归损失函数和Focal Loss类别损失函数能显著提高模型对航天太阳能电池缺陷目标的检测性能。改进模型的mAP达到96.55%,相较于原模型YOLOX-s提高了2.82个百分点。

3)现场随机选出一定数量的典型缺陷电池,并将改进模型与YOLO系列主流模型进行对比实验。对比试验结果表明:改进模型对小目标缺陷的检出率明显高于对比模型,但部分由于缺陷较小而被企业视为质量合格的电池亦被检出,导致改进模型的过检率相对较高。实际应用中,适当的过检量是允许的,关键在于提高对缺陷电池的检出率、避免漏检造成的损失。

[参考文献]

- [1] 李定海. 中国砷化镓太阳能电池的发展研究[J]. 中国金属通报, 2018(2): 39.
LI D H. Research on the development of GaAs solar cells in China[J]. China metal bulletin, 2018(2): 39.
- [2] 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.
- [3] 陶志勇, 杜福廷, 任晓奎, 等. 基于T-VGG的太阳能电池片缺陷检测[J]. 太阳能学报, 2022, 43(7): 145-151.
TAO Z Y, DU F T, REN X K, et al. Defect detection of solar cells based on T-VGG [J]. Acta energiae solaris sinica, 2022, 43(7): 145-151.
- [4] 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), Rome, Italy, 2018: 2035-2039.
- [5] 邓堡元, 何赞泽, 王洪金, 等. 光伏电池图像序列的深度学习检测方法[J]. 机械工程学报, 2021, 57(8): 98-106.
DENG B Y, HE B Z, WANG H J, et al. Deep learning inspection for photovoltaic cell image sequence [J]. Journal of mechanical engineering, 2021, 57(8): 98-106.
- [6] 张一平, 许盛之, 孟子尧, 等. 基于FC-ACGAN网络的太阳能电池EL图像的数据增强方法[J]. 太阳能学报, 2021, 42(10): 35-41.
ZHANG Y P, XU S Z, MENG Z Y, et al. Data enhancement method of solar cell el image based on FC-ACGAN network [J]. Acta energiae solaris sinica, 2021, 42(10): 35-41.
- [7] 蒋尚俊, 易辉, 李红涛, 等. 基于迁移学习与ResNet的太阳能电池缺陷检测方法[J]. 太阳能学报, 2023, 44(7): 116-121.
JIANG S J, YI H, LI H T, et al. Defect detection method of solar cells based on transfer learning and ResNet [J]. Acta energiae solaris sinica, 2023, 44(7): 116-121.
- [8] ELFWING S, UCHIBE E, DOYA K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning [J]. Neural networks, 2018, 107: 3-11.
- [9] CHOLLET F. Xception: deep learning with depthwise separable convolutions [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017: 1800-1807.
- [10] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [EB/OL]. 2018: arXiv: 1807.06521. <http://arxiv.org/abs/1807.06521>.
- [11] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017: 936-944.
- [12] YU J H, JIANG Y N, WANG Z Y, et al. UnitBox: an advanced object detection network [C]//Proceedings of the 24th ACM International Conference on Multimedia, Amsterdam, Netherlands, 2016.
- [13] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized intersection over union: a metric and a loss for bounding box regression [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019: 658-666.
- [14] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression [J]. Proceedings of the AAAI conference on artificial intelligence, 2020, 34(7): 12993-13000.

- [15] ZHENG Z H, WANG P, REN D W, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE transactions on cybernetics, 2022, 52(8): 8574-8586.

DEFECT DETECTION FOR AEROSPACE SOLAR CELLS BASED ON IMPROVED YOLOX-s ALGORITHM

Li Zhenwei, Zhang Shihai, Qu Chongnian, Ru Chengyin, Chen Kangjing

(School of Mechanical Engineering, Tianjin University of Technology and Education, Tianjin 300222, China)

Abstract: Aiming at the problems of defect detection for aerospace solar cells, the machine vision and deep learning are combined to detect the surface defect of solar cells. The aerospace solar cells images are obtained through the vision detection system and the aerospace solar cells defect dataset is constructed according to the enterprise's defect classification standard. So as to solve the problem of low recall rate caused by information loss of convolution and down sampling, the slicing technique is used to obtain the partial defect images of solar cells and the sub-image dataset is constructed. In order to avoid the overfitting problem caused by insufficient dataset in the model training process, the appropriate image enhancement methods are adopted to expand the dataset for different defects. The YOLOX-s algorithm is improved by using depth wise separable convolution, optimizing the loss function, adopting bilinear interpolation up sampling, and introducing convolutional block attention module, and the best comprehensive defect detection model for aerospace solar cells has been obtained. The effectiveness of the improved model has been verified through comparison of multiple detection accuracy indicators between the models trained by different datasets, as well as ablation experiments. The superiority of the improved model for aerospace solar cells defect detection is verified through comparative experiments between similar mainstream models.

Keywords: solar cells; machine vision; deep learning; YOLOX-s; defect detection