

多尺度融合的 CRC-RetinaNet 光伏板阴影检测方法

吴君, 范鹏辉, 王满利*

河南理工大学物理与电子信息学院, 河南 焦作 454003

摘要 光伏板阴影不仅会使光伏阵列的光照强度分布不均,降低发电效率,甚至还可能产生热斑效应,损坏光伏电池组件,造成系统故障。为解决光伏板阴影检测中目标密集度高、重叠度大、成本高和实时性差等问题,提出了一种基于 RetinaNet 算法的 CRC-RetinaNet 光伏板阴影检测算法。首先,所提算法特征提取网络采用 cross stage partial 结构,以提升准确率和检测速度;其次,采用循环特征融合结构处理提取到的特征图,以增强所有目标的特征信息;然后,改进算法的激活函数,以增强网络的鲁棒性;最后,使用 CIoU 损失来提高目标边框回归的定位精度。实验结果表明,所提算法的检测平均精度均值为 99.24%,与原 RetinaNet 算法相比提高了 4.02 个百分点,可以满足现实环境下光伏板实时检测的要求。

关键词 机器视觉; 光伏板阴影; 密集目标检测; RetinaNet; cross stage partial; 特征融合

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP202259.1615009

Shadow Detection Method for CRC-RetinaNet Photovoltaic Panel Based on Multiscale Fusion

Wu Jun, Fan Penghui, Wang Manli*

School of Physics & Electronic Information Engineering, Henan Polytechnic University, Jiaozuo 454003, Henan, China

Abstract The shadow of a photovoltaic panel makes the light intensity distribution of the photovoltaic array uneven and reduces the power generation efficiency. It can also produce a hotspot effect, damage photovoltaic cell modules, and cause a system failure. To solve the problems of high target density, large overlap, high cost, and poor real-time performance in the shadow detection of photovoltaic panels, this study proposes a shadow detection algorithm for CRC-RetinaNet photovoltaic panels based on the RetinaNet algorithm. First, cross stage partial structure was used in the feature extraction network to improve the accuracy and detection speed. Second, the feature map was extracted using the recursive feature fusion structure to enhance the feature information of all targets. Third, the activation function of the algorithm was improved to enhance the robustness of the network. Finally, the loss function was changed to CIoU loss to improve the positioning accuracy of the target border regression. The experimental results show that the average detection accuracy of the proposed algorithm is 99.24%, which is improved by 4.02% compared with the original RetinaNet algorithm, and meets the requirements of the real-time detection of photovoltaic panels in the environment.

Key words machine vision; photovoltaic panel shadow; dense target detection; RetinaNet; cross stage partial; feature fusion

1 引言

在当今时代背景下,电力对技术和经济的发展极

其重要。化石能源的弊端越来越突出,而新能源成为了世界关注的热点,其中太阳能得到了全世界广泛的重视和应用。但是,由于光伏发电系统安装环境复杂

收稿日期: 2021-07-30; 修回日期: 2021-08-23; 录用日期: 2021-09-24

基金项目: 国家自然科学基金(52074305)、河南省科技攻关(212102210005)、光电传感与智能测控河南省工程实验室开放基金(HELPSIMC-2020-00X)

通信作者: *wml920@163.com

多变,受树木、云层、电线杆和建筑物等阴影遮挡^[1]的问题几乎无法避免,光伏板遮挡(阴影)会造成光照强度不均匀、热斑效应等,最终导致发电效率降低,甚至损坏光伏元件。以上海地铁新能源中的某个基地为例,一年内因阴影遮挡损失电量为 $3.1 \times 10^4 \text{ kW} \cdot \text{h}$,阴影组串占比为 19.08%,平均每天损失 1069.38 $\text{kW} \cdot \text{h}$ 。早期光伏板阴影检测多使用人工观测和经验预测的方式,存在实时性差、成本高等问题,无法满足光伏板阴影监测的实际需要。

目前国内外光伏板遮挡检测方法主要有红外图像分析法^[2]、电路结构法^[3]、数学模型法^[4]及智能检测法^[5]。但是这些方法普遍存在成本高、精度不足、技术难度大、不具普适性等问题。因此开发一种基于图像数据、适用于大规模光伏板阴影检测的方法已迫在眉睫。

近年来,由于深度学习目标检测算法^[6]的快速发展,很多传统的检测方法被其替代,目前深度学习的检测算法主要分为两种类型。一种是一阶段(one-stage)检测算法,它是基于回归的端到端的目标检测算法,拥有检测速度快的特点。代表算法有 YOLO 系列^[7-10]、SSD^[11]、RetinaNet^[12]、EfficientDet^[13]、M2Det^[14]等。另一种是二阶段(two-stage)检测算法,它先生成可能存

在目标的候选区域(region proposal)^[15],再由卷积神经网络对候选区域中目标的位置和类别进行预测,其检测精度高,但是网络结构复杂,速度慢。代表算法有 R-CNN 系列^[16-18]、SPP Net^[19]等。

作为一阶段检测算法的 RetinaNet 算法,其准确度超过了许多二阶段算法,因此以 RetinaNet 算法为基础进行相应改进,来完成光伏板阴影检测任务。RetinaNet 算法在光伏板阴影检测任务中,达不到实时检测的要求,对目标密度和重叠度大的光伏板阴影目标的检测效果较差,尤其是对小目标的检测效果更差。因此,本文对 RetinaNet 算法中的主干网络、特征融合、损失函数、激活函数等进行改进和优化,提出了一种多尺度融合 CRC-RetinaNet 光伏板阴影检测算法。实验结果表明,该算法可实现光伏板阴影状态的实时检测。

2 CRC-RetinaNet 算法

为适用光伏板遮挡检测任务,本实验组针对 RetinaNet 算法进行了以下改进和优化。首先,基于 cross stage partial(CSP)结构对提取特征的特征网络进行了重新设计,其中还包含 Focus 结构和空间金字塔池化(SPP)结构,提升算法检测速度和准确度;其次,使用循环特征融合机制替代自顶向下的特征融合

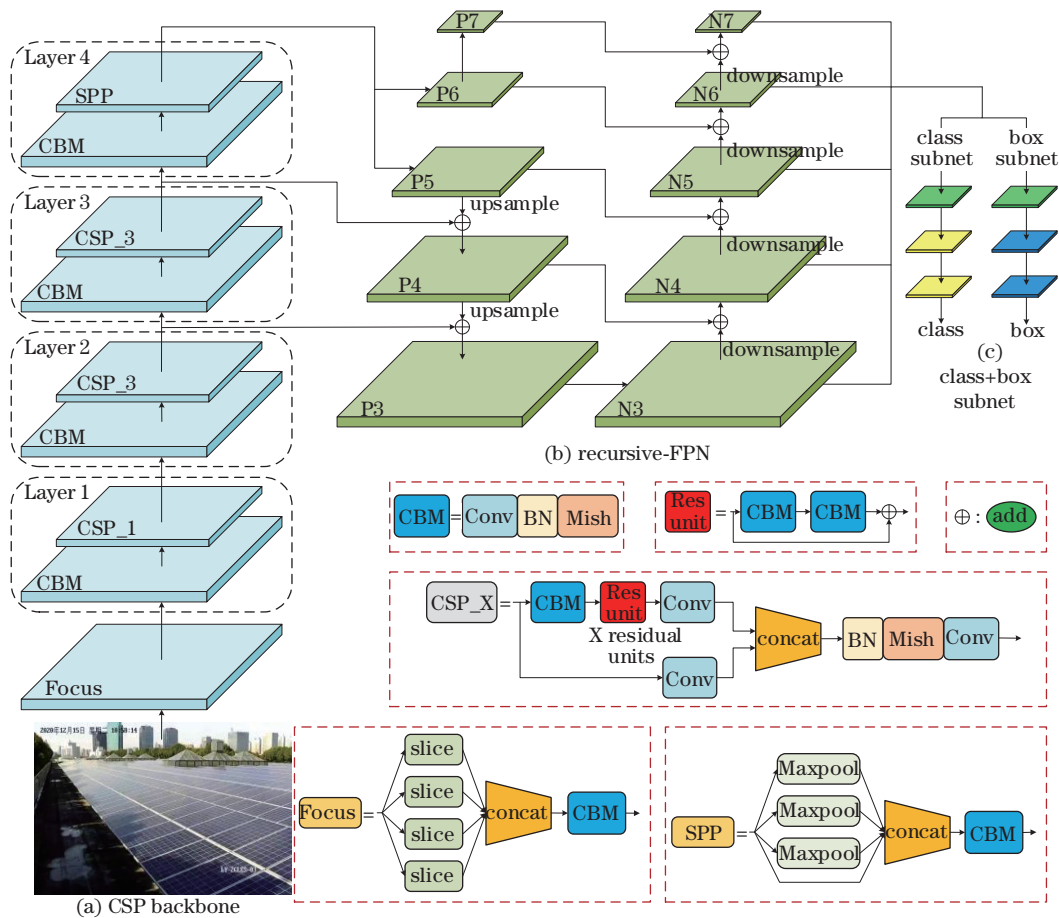


图 1 CRC-RetinaNet 结构。(a) CSP 主干网络; (b) recursive-FPN; (c) class+box subnet

Fig. 1 Structure of CRC-RetinaNet. (a) CSP backbone; (b) recursive-FPN; (c) class+box subnet

网络,增强全部目标的特征表达能力;然后,将 ReLU 激活函数改进为双激活函数,提升算法的学习能力和鲁棒性;最后,使用 CIoU 损失代替 smooth L1 损失,提升算法的预测精度和收敛速度。CRC-RetinaNet 算法结构如图 1 所示。

2.1 CSP backbone

针对残差网络^[20]计算量大、参数量大、梯度相对较小的问题,本实验组提出了一种基于 CSP 结构^[21]的主

干网络——CSP DenseNet,该网络加强了卷积神经网络的学习能力、减少了计算量、减少了内存损耗。

CSP DenseNet 的原理如图 2 所示,它的每个阶段均由一个 Partial Dense Block 和一个 Partial Transition Layer 组成。每个 Partial Dense Block 均由 k 个 Dense Layer 组成,第 i 个 Dense Layer 都是由卷积计算得到的输出和输入拼接在一起的。这种结构可增加梯度路径,平衡每层的计算量,并降低内存占用。

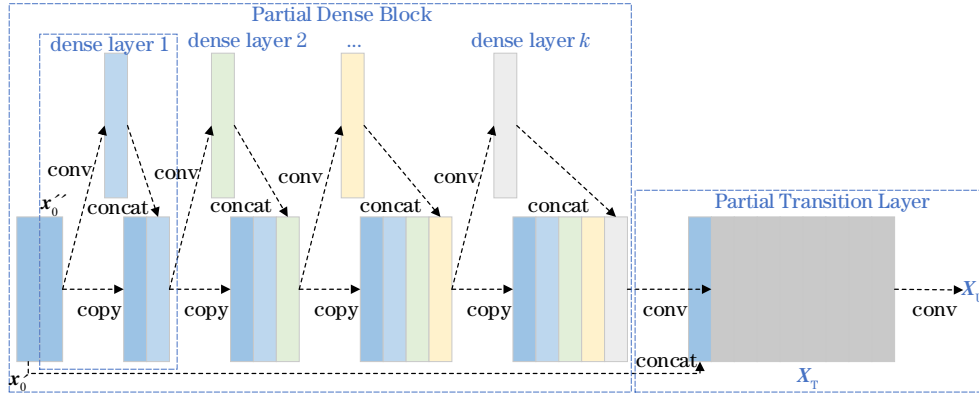


图 2 CSP DenseNet 原理图

Fig. 2 Schematic of CSP DenseNet

整个 CSP DenseNet 的前馈和权重更新方程为

$$\begin{cases} \mathbf{x}_k = \mathbf{w}_k * [\mathbf{x}_0'', \mathbf{x}_1, \dots, \mathbf{x}_{k-1}] \\ \mathbf{x}_T = \mathbf{w}_T * [\mathbf{x}_0'', \mathbf{x}_1, \dots, \mathbf{x}_k] \\ \mathbf{x}_U = \mathbf{w}_U * [\mathbf{x}_0', \mathbf{x}_T] \end{cases} \quad (1)$$

$$\begin{cases} \mathbf{w}_k' = f(\mathbf{w}_k, \mathbf{g}_0'', \mathbf{g}_1, \dots, \mathbf{g}_{k-1}) \\ \mathbf{w}_T' = f(\mathbf{w}_T, \mathbf{g}_0'', \mathbf{g}_1, \dots, \mathbf{g}_k) \\ \mathbf{w}_U' = f(\mathbf{w}_U, \mathbf{g}_0', \mathbf{g}_T) \end{cases} \quad (2)$$

式中： $*$ 为卷积操作； \mathbf{x}_i 为第 i 个 Dense Layer 的输出； $[\mathbf{x}_0, \mathbf{x}_1, \dots]$ 表示将 $\mathbf{x}_0, \mathbf{x}_1, \dots$ 拼接起来； \mathbf{w}_i 为第 i 个 Partial Dense Block 的权重； f 为网络权重的更新函数； \mathbf{g}_i 为第 i 个 Dense Layer 回传的梯度。

主干网络在底端采用 Focus 结构进行信息零丢失的下采样；然后进行 layer 1 操作,具体为先进行 CBM 操作(即先进行卷积,再批量标准化,最后进行 Mish 激活函数运算),再进行 CSP 操作;再经过 layer 2 和 layer 3 操作,分别得到 P3、P4 融合所需特征图,其操作与 layer 1 仅 CSP 中的残差单元数量不同;最后 layer 4 先经过 CBM 操作,再进行 SPP 操作,得到 P5、P6、P7 所需特征图,SPP 可以丰富 P5、P6、P7 特征信息并增大感受野。

CRC-RetinaNet 算法的主干网络结构如图 1(a) 所示,其参数量只有 ResNet50 的 14.6%,对密集且小的光伏板阴影目标来说,能提取到更多的特征,因此可以大幅提升算法检测速度和准确度。改进主干网络后

的 RetinaNet 算法简称为 C-RetinaNet 算法。

2.2 循环特征融合

RetinaNet 算法的特征金字塔网络(FPN)特征融合机制为自顶向下,这种融合方式主要丰富浅层特征图的语义信息。但高层次的特征图虽然语义信息比较丰富,位置信息却相对较差,这方面 RetinaNet 算法未进行相应处理。基于此,本实验组采用循环特征融合结构(RFPN)在原算法 FPN 的基础上再进行自底向上的特征融合。该操作的优点包括:1) 缩短特征信息的传输路径,实现高层次对低层次特征的精准定位信息的利用;2) 使得特征金字塔的所有特征层的信息都能被每个 anchor 利用;3) 增加特征信息来源,丰富全部特征层的特征信息。对本研究密集和重叠目标来说,语义信息和位置信息的增强可以在很大程度上增强算法的特征表达能力。

CRC-RetinaNet 算法的循环特征融合网络结构如图 1(b) 所示。在得到的 P3~P7 的基础上,P3 经过卷积得到 N3,N3 经过下采样与经过卷积的 P4 进行融合得到 N4,N4 经过下采样与经过卷积的 P5 进行融合得到 N5,N6 和 N7 以此类推。RFPN 的特征图增强了网络的特征表达能力,提升了所有尺寸的光伏板阴影检测能力。改进特征融合后的 RetinaNet 算法简称为 CR-RetinaNet 算法。

2.3 M-L 双激活函数

ReLU 激活函数将所有的负值都设为零,正值不变,它的优点是收敛和计算速度快。但是对于负值来说,输出和倒数均一直为 0,这会造成神经网络参数不

再更新,最终导致网络的学习能力受到限制。

所提算法的主干网络使用 Mish 激活函数,循环特征融合和分类回归子网络使用 Leaky ReLU 激活函数,简称为 M-L 双激活函数。

Mish 激活函数^[22]有 4 个特性:无上界、有下界、平滑和非单调。无上界能够保证网络不会出现梯度消失问题;有下界能够提升网络的正则化效果;平滑能提升网络的泛化能力,也能更好地优化网络,并可以避免 ReLU 在原点不连续带来的不可控问题;非单调能够保证一些小的负值也可以被保留,提高网络的可解释性,增强网络梯度。Mish 激活函数数学表达为

$$f(x) = x \times \tanh\{\ln[1 + \exp(x)]\} \quad (3)$$

Leaky ReLU 激活函数对负值采取抑制的方式,而不是直接置为 0,增强了网络的学习能力,避免了静默神经元的出现,同时还继承了 ReLU 的收敛速度和计算速度。Leaky ReLU 激活函数的数学表达式为

$$y_i = \begin{cases} x_i, & x_i \geq 0 \\ a_i x_i, & x_i < 0 \end{cases} \quad (4)$$

式中: a_i 是 (0, 1) 区间内的固定参数,本实验设 a_i 为 0.3。

2.4 CIoU 损失

CRC-RetinaNet 算法采用 CIoU 损失函数^[23]训练边框回归损失,CIoU 考虑了重叠面积、中心点距离、长宽比,具有收敛速度快、收敛精度高等特点,对光伏板阴影检测密集和重叠目标效果较好。

平滑 L1 损失函数(smooth L1 loss)虽然对 L1 损失函数进行了改进,但是它将边框的 4 个点单独进行计算,然后相加求出最终的边框损失,这种做法默认了目标边框的 4 个点是相互独立的,而边框检测的评价指标是交并比(IoU),在具有相同大小平滑 L1 损失的边框中,其 IoU 相差可能很大。因此,平滑 L1 损失函数对算法效果有一定的不利影响。CIoU 损失函数的数学表达为

$$L_{CIoU} = 1 - R_{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v, \quad (5)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2, \quad (6)$$

$$\alpha = \frac{v}{(1 - R_{IoU}) + v}, \quad (7)$$

式中: b 和 b^{gt} 分别表示预测框和真实框的中心点; $\rho(\cdot)$ 表示欧氏距离; c 为真实框和预测框的最小外接矩形的对角线距离; w^{gt} 和 h^{gt} 分别表示真实框的宽和高; w 和 h 分别表示预测框的宽和高。所提算法的损失由回归损失(CIoU 损失)和分类损失(Focal 损失)组成,总体损失为 Focal 损失与四分之一 CIoU 损失的和。改进损失函数后的 RetinaNet 算法简称为 CRC-RetinaNet 算法。

3 实验结果与分析

3.1 模型运行环境

为了验证 CRC-RetinaNet 算法的有效性,本实验组在相同的实验环境进行了相关实验。实验平台处理器为 Intel(R) Core(TM) i5-10400F,主频为 2.90 GHz,内存为 16 GB,显卡为 NVIDIA GeForce RTX 2070S,8 GB 显存,存储为 256 GB SSD+300 GB 机械硬盘,操作系统为 Windows 10 64 位,编程语言为 Python 3.6,深度学习框架为 Tensorflow 2.4/Keras。

3.2 实验评价标准

为客观评价算法性能,采用标准的评价指标查准率(precision)、查全率(recall)、平均精度(AP)、平均精度均值(mAP)、每秒传输帧数(FPS)、模型大小等来评价算法,并与具有代表性的深度学习算法进行了对比分析,来验证所提算法的实用性。

对于二分类问题,其分类结果的混淆矩阵如表 1 所示,结果分为 4 种情况,分别为真正例(TP)、假反例(FN)、假正例(FP)、真反例(TN)。

表 1 分类结果混淆矩阵

Table 1 Confusion matrix of classification results

Ground truth	Detection result	
	Positive	Negative
Positive	TP	FN
Negative	FP	TN

查准率又称准确率^[24],其含义为所有被预测结果为正例的样例中真正例所占的比例,其表达式为

$$R_{precision} = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (8)$$

查全率又称召回率^[25],其含义为所有真实情况为正例的样例中真正例的比例,其表达式为

$$R_{recall} = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (9)$$

平均精度的含义为某一类别在所有阈值情况下的查准率-查全率曲线的积分,它平衡了查准率和查全率,可以反映算法在某一类别上的综合能力,其表达式为

$$R_{AP(c)} = \int_0^1 P(c) dR(c), \quad (10)$$

式中: c 为某一类别。

平均精度均值为所有类别的平均精度的平均值,即反映算法的整体效果,其表达式为

$$R_{mAP} = \frac{1}{C} \sum_{c \in C} R_{AP(c)}, \quad (11)$$

式中: C 表示类别集合。

FPS 即每秒传输帧数,在这里的含义为每秒能检测的图片数量,代表了算法的检测速度。模型大小即模型所占内存的多少,代表了算法对存储空间的要求。

3.3 数据集制作与处理

本实验组采用光伏发电监控视频、无人机现场拍

摄及人工拍摄三种方式获得实际使用场景中的光伏板和光伏板阴影照片,并使用 pr 软件对视频数据进行处理,得到每一帧图片,筛选掉大量的相似照片和人工拍摄不合格的图片,最后对图片像素进行归一化调整。然后将这些图片数据用 LabelImg 标记软件标注,标注类别有 2 个: PVP(未遮挡的光伏板)、PVP_shielding(遮挡的光伏板),标注格式和文件分别为 VOC 格式和 xml 文件。最终数据集共 8402 张,其中未遮挡光伏板目标数量为 52220 个,阴影遮挡光伏板数量为 51269 个。本实验组采用随机缩放、随机反转、随机色域扭曲等方式实现在线数据增强,来扩大数据集样本数量,提升算法的准确度和泛化能力。

原 anchor 对光伏板阴影数据集已不再适用,因此本实验组对 anchor 进行了重新设计。针对本实验所用数据集, K-means 聚类结果如图 3 所示。

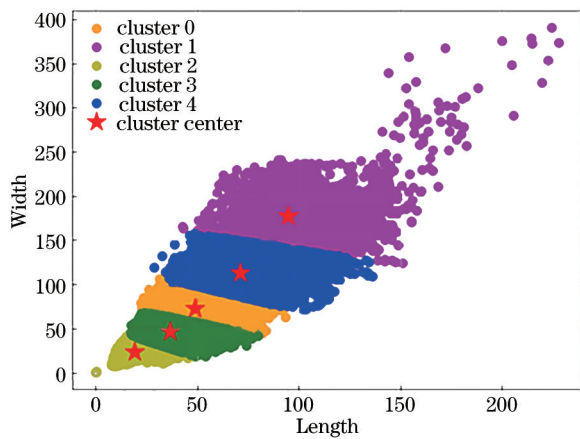


图 3 光伏板阴影数据集聚类结果

Fig. 3 Cluster results of photovoltaic panel shadow dataset

从图 3 可以看出,在这 5 个聚类簇中,光伏板阴影的长宽集中在 $[19, 23]$ 、 $[37, 46]$ 、 $[49, 73]$ 、 $[71, 113]$ 及 $[94, 178]$ 附近。最后经过实验验证,设置 5 个特征层的 anchor 尺寸分别为 $[20 \times 20, 40 \times 40, 60 \times 60, 130 \times 130, 240 \times 240]$,长宽比为 $[0.5, 0.8, 1]$ 。




图 5 CRC-RetinaNet 算法 P-R 曲线。(a) 光伏板; (b) 遮挡光伏板

Fig. 5 P-R curves of CRC-RetinaNet algorithm. (a) Photovoltaic panel; (b) photovoltaic panel shielding

3.4 模型训练与结果分析

数据集中测试集划分为数据集总量的 10%, 训练时再将剩余的数据集按照 9:1 的比例自动划分为训练集和验证集,具体数据分布如表 2 所示。

表 2 数据集分布表

Table 2 Dataset distribution

Class	Number of training set and verification set	Number of test set
PVP	46203	6017
PVP_shielding	46220	5049

受实验平台限制, batch 为 4, 每个 epoch 共迭代 1701 次。训练采用 Adam 优化器, 动量为 0.9, 初始学习率设为 0.0001, 根据训练中损失的变化动态调整学习率, 损失 3 次不变学习率减小 50%, 10 次损失不变停止训练。训练过程中, 学习率分别在迭代 44、52、66、72、78 个 epoch 后进行了调整。损失变化如图 4 所示, 损失在迭代 70000 次迭代之后趋于平稳, 最终稳定在 0.1082 左右。

在随机划分的 841 张测试集中进行测试, 所提 CRC-RetinaNet 算法检测结果的 P-R 曲线如图 5




图 4 训练损失下降曲线

Fig. 4 Training loss decline curve

所示。

P-R 曲线为所有置信度下的召回率和准确率值组成的曲线,该曲线的积分即为 AP 值。PVP 和 PVP_shielding 两种类别的 AP 值分别达到了 99.33%、99.15%。

3.5 不同算法的比较

为了验证所提算法的有效性,将其与代表性的一阶段和二阶段算法进行了比较,其中一阶段算法包括 SSD、YOLOv3、YOLOv4、EfficientDet、M2Det,二阶段算法为 faster R-CNN,其中 SSD、faster R-CNN 的 anchor 已经不适合本实验组数据集,所以进行聚类后得到新的 anchor,而 YOLOv3、YOLOv4 采用新聚类后的 anchor 效果没有变化,因此未列出。在相同实验环境和光伏板阴影数据集上实现这些算法,结果如表 3 所示,其中粗体表示最优结果。

由表 3 可知,除所提算法外,光伏板(PVP)检测的 AP 最高为 Faster R-CNN-anchor 的 97.68%,遮挡光伏板(PVP_shielding)检测的平均精度最高为 YOLOv3 的 98.33%,而所有种类的 mAP 最高为 YOLOv4 的 97.10%,而所提算法均高于这些算法

1.65 个百分点、0.82 个百分点、2.14 个百分点。而且所提算法不仅在 mAP 上优于 SSD-anchor、YOLOv3、YOLOv4、faster R-CNN-anchor、M2Det 算法,并且模型大小也远优于这些算法。虽然在检测速度上低于 SSD 和 YOLOv3,但也可以做到实时检测。由于所提算法是为了解决光伏板阴影检测问题,并为光伏系统故障检测提供新的思路 and 方向,需要准确度高、模型小、检测速度、满足实时性要求的算法,这些要求 CRC-RetinaNet 算法均满足,因此其更具优势。

3.6 消融实验

为了验证所提算法每一步改进的有效性,进行消融实验来分析每一步改进对算法整体的影响。本实验组将所提算法分为 4 组进行训练分析:第 1 组是 RetinaNet 算法;第 2 组在 RetinaNet 算法的基础上采用 CSP 特征提取网络,即 C-RetinaNet;第 3 组在第 2 组的基础上采用 RFPN,即 CR-RetinaNet;第 4 组在第 3 组的基础上采用 M-L 激活函数;第 5 组在第 4 组的基础上采用 CIoU 损失函数,即 CRC-RetinaNet。在光伏板阴影数据集上的实验结果如表 4 所示。

表 3 不同算法性能对比

Table 3 Performance comparison of different algorithms

Algorithms	AP / %		mAP / %	FPS	Model size / MB
	PVP	PVP_shielding			
M2Det	96.89	90.21	93.55	24.8	226.66
EfficientDet	86.29	39.09	62.69	30.7	16.16
SSD	55.07	30.55	42.81	41.4	100.40
SSD-anchor	63.23	52.15	57.69	42.3	100.40
Faster R-CNN	40.66	20.44	30.55	16.0	301.05
Faster R-CNN-anchor	97.68	94.42	96.05	18.5	301.05
YOLOv3	95.81	98.33	97.07	34.9	246.30
YOLOv4	96.12	98.09	97.10	30.2	266.30
RetinaNet	96.92	93.52	95.22	15.6	139.30
CRC-RetinaNet	99.33	99.15	99.24	32.4	66.26

表 4 不同模型检测精度比较

Table 4 Comparison of detection accuracy of different models

Group	CSP	RFPN	Mish + Leaky ReLU	CIoU loss	AP / %		mAP / %	FPS	Model size / MB
					PVP	PVP_shielding			
1	×	×	×	×	96.92	93.52	95.22	15.6	139.30
2	✓	×	×	×	98.29	97.12	97.71	33.5	45.98
3	✓	✓	×	×	98.92	98.17	98.55	32.1	66.26
4	✓	✓	✓	×	99.06	98.88	98.97	31.6	66.26
5	✓	✓	✓	✓	99.33	99.15	99.24	32.4	66.26

从表 4 可以看出,RetinaNet 算法在光伏板阴影检测中存在准确度不足的问题,尤其是光伏板阴影检测准确率较低,且检测速度过低,无法达到实时性的要求,模型大小也高达 139.3 MB;将特征提取网络由残差网络改进为 CSP 结构后,特征提取网络的参数量大

幅减少,使得模型大小变为 45.98 MB,检测速度提升为原来的 2.15 倍,满足了实时性的要求,平均准确率均值也达到了 97.71%,尤其是 PVP_shielding 的平均精度提升较为明显,提升了 3.6 个百分点;使用 RFPN、M-L 激活函数和 CIoU 后,虽然 RFPN 结构使

模型大小有小幅增大,但这些改进都提高了光伏板阴影的检测精度,且最终满足了算法的实时性。从消融实验来看,所提算法在不同尺度的光伏板阴影检测上的合理性和有效性得到了验证。

CRC-RetinaNet算法在光伏板阴影数据集上的光伏板检测平均准确度能够达到99.33%,光伏板阴影检测平均准确度能达到99.15%,整体mAP达到了99.24%,FPS达到了32.4;与RetinaNet算法相比,mAP提高了4.02个百分点,检测速度提升了一倍多,能够满足实时性的要求。

在密集的光伏板阴影数据集上的检测效果如图6所示,左边为原图,中间为RetinaNet算法检测结果图,

右边为CRC-RetinaNet算法检测结果图,其中框标签PVP为光伏板(红色框),PVP_shielding为遮挡光伏板(浅蓝色框),椭圆框为该区域有漏检或者误检(黄色椭圆框)。在[图6(a)、(b)、(c)、(d)、(e)]密集而重叠目标场景中,RetinaNet算法在[图6(a)、(d)、(e)]中存在漏检情况,在[图6(c)]中存在误检情况,而在CRC-RetinaNet算法检测结果中无漏检误检,且预测框的置信度普遍有不同程度的提高;在[图6(d)、(e)]小目标场景中,RetinaNet算法的漏检情况严重,且置信度较低,CRC-RetinaNet算法不存在漏检、误检等问题,且置信度高、预测框的位置准确。实验结果表明,CRC-RetinaNet算法适合光伏板阴影检测任务。




图6 检测效果图。(a) (b) (c) (d) (e)密集而重叠目标;(d)(e)小目标

Fig. 6 Detection results. (a) (b) (c) (d) (e) Dense and overlapping targets; (d) (e) small targets

4 结 论

将卷积神经网络模型引入光伏板状态检测中,提出了CRC-RetinaNet算法用于光伏板状态检测,解决了光伏板阴影检测中目标密集、目标框重叠等问题,为无人机巡视、监控视频监控等光伏板状态检测提供新的思路,并为光伏板阴影检测提供新的方法。

采用CSP特征提取网络、循环特征融合网络及CIoU损失函数后,CRC-RetinaNet算法提高了光伏板阴影检测模型的检测速度、准确度和鲁棒性。实验结

果表明,所提算法目标位置预测更加准确,检测准确率更高,光伏板检测准确率提高了2.14个百分点,光伏板遮挡检测准确率提高了5.62个百分点,总体mAP提升了4.02个百分点,单张图片检测时间由64.1 ms降到了30.9 ms。总体来说,所提算法与其他算法相比,具有较强的有效性。

所提算法对光伏板阴影有较好的效果,但是理论上讲该算法对积灰、破损等状态也有一定的适用性,但本实验组未进行研究,今后可在本实验组数据集上增加相关数据,进行进一步实验。

参 考 文 献

- [1] Zhu H L, Yu C, Lu L X, et al. Research on parameter distribution features of photovoltaic array under the cover and shadow shading conditions[J]. *International Journal of Photoenergy*, 2018, 2018: 9207917.
- [2] Hu Y H, Cao W P, Wu J D, et al. Thermography-based virtual MPPT scheme for improving PV energy efficiency under partial shading conditions[J]. *IEEE Transactions on Power Electronics*, 2014, 29(11): 5667-5672.
- [3] 唐莫, 朱永强, 郝嘉诚. 基于传感器最优布置的光伏阵列阴影诊断与定位[J]. *太阳能学报*, 2018, 39(2): 513-519.
Tang Q, Zhu Y Q, Hao J C. Shadow diagnosis and localization of PV array based on optimal sensor collocation[J]. *Acta Energetica Solaris Sinica*, 2018, 39(2): 513-519.
- [4] Madeti S R, Singh S N. Online fault detection and the economic analysis of grid-connected photovoltaic systems[J]. *Energy*, 2017, 134: 121-135.
- [5] Liu Y W, Zhu X R, Yang J. Fault diagnosis of PV array based on optimised BP neural network by improved adaptive genetic algorithm[J]. *The Journal of Engineering*, 2017, 2017(13): 1427-1431.
- [6] 段仲静, 李少波, 胡建军, 等. 深度学习目标检测方法及其主流框架综述[J]. *激光与光电子学进展*, 2020, 57(12): 120005.
Duan Z J, Li S B, Hu J J, et al. Review of deep learning based object detection methods and their mainstream frameworks[J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 120005.
- [7] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [8] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [9] Redmon J, Farhadi A. YOLOV3: an incremental improvement[EB/OL]. (2018-04-08)[2020-04-23]. <https://arxiv.org/abs/1804.02767>.
- [10] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2018-04-08)[2020-04-23]. <https://arxiv.org/abs/2004.10934>.
- [11] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multi-box detector[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9905: 21-37.
- [12] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(2): 318-327.
- [13] 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, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 10778-10787.
- [14] Zhao Q J, Sheng T, Wang Y T, et al. M2Det: a single-shot object detector based on multi-level feature pyramid network[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33: 9259-9266.
- [15] 尧佼, 于凤芹. 基于候选区域定位与HOG-CLBP特征组合的行人检测[J]. *激光与光电子学进展*, 2021, 58(2): 0210015.
Yao J, Yu F Q. Pedestrian detection based on combination of candidate region location and HOG-CLBP features[J]. *Laser & Optoelectronics Progress*, 2021, 58(2): 0210015.
- [16] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 580-587.
- [17] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.
- [18] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.
- [19] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1904-1916.
- [20] 史宝岱, 张秦, 李瑶, 等. 基于改进残差注意力网络的SAR图像目标识别[J]. *激光与光电子学进展*, 2021, 58(8): 0810008.
Shi B D, Zhang Q, Li Y, et al. SAR image target recognition based on improved residual attention network[J]. *Laser & Optoelectronics Progress*, 2021, 58(8): 0810008.
- [21] Wang C Y, Mark Liao H Y, Wu Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 14-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1571-1580.
- [22] Misra D. Mish: a self regularized non-monotonic neural activation function[EB/OL]. (2019-08-23)[2020-08-13]. <https://arxiv.org/abs/1908.08681>.
- [23] 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.
- [24] Gupta S, Agrawal A, Gopalakrishnan K, et al. Deep learning with limited numerical precision[C]//32nd International Conference on Machine Learning, ICML 2015, July 6-11, 2015, Lille, France. New York: ACM Press, 2015: 1737-1746.
- [25] Lee H, Grosse R, Ranganath R, et al. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations[C]//ICML '09: Proceedings of the 26th Annual International Conference on Machine Learning, June 14-18, 2009, Montreal, Quebec, Canada. New York: ACM Press, 2009: 609-616.