

细粒度特征增强与尺寸匹配的光伏缺陷检测

索大翔,李波*

(天津大学管理与经济学部,天津 300072)

摘要:针对光伏场站无人机巡检场景中,电池面板缺陷目标成像过小导致的漏检和误检问题,提出一种针对光伏电池板的高精度缺陷检测方法。根据无人机巡检中目标尺寸的分布特征,采用细粒度特征增强与尺寸匹配相结合的策略,提高光伏缺陷小目标检测精度。与传统样本数据增强、多尺度学习和特征增强等增强小目标策略不同,引入细节保留语义信息增强模块,在保留细粒度信息的同时,挖掘相关粗粒度语义细节。引入锚点-预测头匹配多尺度检测策略,确保锚点与特征图的尺寸匹配。本研究方法在 PVEL-AD 数据集上均值平均精度达到 59.4%,在 CARPK 数据集上均值平均精度达到 97.6%,对比主流目标检测模型,光伏缺陷目标检测性能显著提高。

关键词:小目标检测;实时目标检测;缺陷检测;特征增强;尺寸匹配

中图分类号:TP391 **文献标志码:**A

引用格式:索大翔,李波. 细粒度特征增强与尺寸匹配的光伏缺陷检测[J].山东大学学报(工学版),2025,55(4):9-17.

SUO Daxiang, LI Bo. Photovoltaic defect detection based on fine-grained feature enhancement and scale matching[J]. Journal of Shandong University (Engineering Science), 2025, 55(4):9-17.

Photovoltaic defect detection based on fine-grained feature enhancement and scale matching

SUO Daxiang, LI Bo*

(College of Management and Economics, Tianjin University, Tianjin 300072, China)

Abstract: A high-precision defect detection method for photovoltaic panels was proposed to address the issue of missed and false detections associated with small defect targets in unmanned aerial vehicle (UAV) inspections of photovoltaic power stations. Considering the distribution characteristics of target sizes identified during UAV inspections, a strategy that combines fine-grained feature enhancement with scale matching was introduced to enhance the accuracy of small target defect detection in photovoltaics. Distinguished from traditional small target enhancement strategies including data augmentation, multi-scale learning, and feature enhancement, a detail-preserving semantic enhancement module was incorporated to retain fine-grained details and to mine related coarse-grained semantic details. A multi-scale detection strategy featuring anchor-prediction head matching was introduced to ensure the compatibility of anchor sizes with feature maps. The method achieved an average mean precision of 59.4% on the PVEL-AD dataset and 97.6% on the CARPK dataset, significantly improving the performance of photovoltaic defect target detection compared to mainstream object detection models.

Keywords: small target detection; real-time object detection; defect detection; feature enhancement; scale matching

0 引言

光伏发电凭借清洁、可再生、环境友好以及可持续供应的优势,广泛应用于工业和日常生活,成为

可再生能源装机增长的主力军^[1]。光伏面板在制造、运输和使用的过程中易出现隐裂、断栅等问题,影响整个阵列使用寿命和性能。依托无人机进行智能化巡检已成为传统人工检查方法的高效替代方案,基于目标检测技术的光伏缺陷检测是实现无人机智能巡

收稿日期:2024-07-16

基金项目:国家社科基金资助项目(21&ZD102);国家自然科学基金资助项目(72132007)

第一作者简介:索大翔(1982—),男,辽宁鞍山人,博士研究生,主要研究方向为智能电网技术与智慧物流。E-mail:sduhit@163.com

*通信作者简介:李波(1967—),女,山西长治人,教授,博士生导师,博士,主要研究方向为供应链管理与优化。E-mail:libo0410@tju.edu.cn

检的关键^[2-3]。在实际应用中,无人机捕获光伏电池缺陷通常表现为小尺寸目标,具有分辨率低、可利用特征有限及易产生聚集效应等属性,难以准确识别和定位,小目标缺陷检测已经成为光伏缺陷检测领域亟待解决的关键问题之一^[4-6]。

针对无人机巡检场景下小目标缺陷检测问题,本研究提出一种跨层特征融合和锚点-预测头对齐相结合的检测方法。本研究设计了一个保留细节的语义信息增强模块(detail-preserving semantic enhancement, DPSE),利用扩张卷积获得具有大量语义信息和大感受野的高分辨率特征图。该模块可以有效解决小目标特征提取过程中细粒度信息丢失问题,通过以下方式增强融合的低层特征:(1)学习与细粒度特征相关的语义特征,以捕捉小目标关键属性。(2)通过精确的特征融合策略,减轻不同语义层次间的差异,减少融合过程中信息丢失。

多尺度目标检测方法的核心在于确保不同尺寸锚点与相应的检测头之间的正确对齐,本研究提出一种基于锚点-预测头匹配的多尺度检测方法,利用 k 均值聚类(k -means)算法确定的锚范围来选择最佳检测头,减轻了过细的锚点分区导致的过拟合问题。

本研究以实时目标检测(you only look once, YOLO)系列算法的YOLOv7^[7]作为基线,对大规模光伏缺陷数据集PVEL-AD^[4]进行验证。

1 相关工作

1.1 光伏缺陷目标检测

在光伏缺陷目标检测领域,基于机器学习的方法受到了广泛关注。文献[8]使用统计学习的方法,比较了支持向量机(support vector machine, SVM)、随机森林(random forest, RF)和人工神经网络(artificial neural networks, ANNs)三者的训练性能,为该领域奠定了基础。文献[9]使用卷积神经网络(convolutional neural network, CNN)对上述方法进行改进,结果表明CNN的性能优于SVM和RF。文献[10-11]比较了CNN和SVM在太阳能电池缺陷检测监督分类框架中的性能。文献[12]研究了CNN在不平衡数据集的情况下进行光伏电池缺陷检测的问题。

随着深度学习技术的发展,文献[13]基于生成对抗网络(generative adversarial networks, GANs)实现了一个深度学习光伏检测系统,该系统从少量现有图像生成高分辨率的电致发光图像

(electroluminescence, EL)数据集,在生成数据集上训练CNN分类器。文献[14]开发了一种用于缺陷检测的轻量级CNN分类系统,使用数据增强技术克服EL图像数据稀疏性问题。文献[15]开发了一种快速光伏缺陷诊断系统,使用EL图像多算法分类器进行训练,可检测多种缺陷类型。文献[16]提出一种区分多晶硅电池和单晶硅电池中4种缺陷类型的分割模型,该模型使用Deeplabv3和ResNet-50组合,在超过17 000张图像上进行训练。文献[17]提出一种基于互补注意网络(complementary attention network, CAN)的分类方法,以减轻噪声特征影响,相应增强缺陷部分特征表示。此前的研究中,鲜有方法关注到光伏缺陷中小目标检测难题,也缺乏相应的解决思路。

1.2 小目标检测

对无人机采集图像进行缺陷目标检测是一项极具挑战性的计算机视觉任务。目标尺寸较小、特征有限且分布密集,传统方法难以充分提取有效特征。目前,针对无人机采集图像场景中小目标检测的策略包括:数据增强技术直接对样本进行复制、粘贴或缩放以增加小目标样本数量^[7,18];多尺度特征融合方法通过整合深层和浅层特征,提高检测的能力^[19-21];上下文信息学习策略利用场景、目标以及目标内部的共存关系,提高对目标和场景的识别效果^[22-23];超分辨率技术直接生成带有详细信息的高分辨率图像^[24-25]。文献[26-27]还加入了对损失函数和注意力机制的改进。上述研究方法采用多种策略,通过捕捉小目标细粒度信息和语义信息,提高针对无人机图像的小目标检测性能。

现有研究方法在光伏缺陷目标检测和无人机图像目标检测领域取得了一定进展,针对无人机巡检场景中的小目标缺陷检测,现有算法仍面临挑战,如细粒度特征提取不足、特征融合冲突和不平衡的数据分布导致性能下降。本研究利用保留细节的语义信息增强模块和锚头匹配技术,有效解决了上述问题,提高了光伏缺陷小目标检测的准确性。

2 本研究方法

2.1 光伏缺陷目标特征分析

小目标检测是目标检测领域的关键挑战之一。现有通用算法在检测小目标时采用多层特征融合策略和固定尺寸检测头。使用多层特征融合策略进行下采样时易导致语义信息大量丢失,固定尺寸检测头无法兼顾不同数据集中的小尺寸目标,限制了通用检

测算法的小目标检测性能。本研究对大规模光伏缺陷数据集 PVEL-AD^[4] 进行了统计分析,表 1 为 36 543 幅图像中 37 380 个检测框的尺寸分布,结果表明小尺寸目标在数量上占据显著优势,揭示了通用算法处理光伏缺陷检测时面临的主要瓶颈。

表 1 光伏缺陷目标尺寸分布

Table 1 The distribution of photovoltaic defect target sizes

目标尺寸/像素	目标数量/个	目标数量比例/%
$[0, 32^2)$	26 513	70.9
$[32^2, 96^2)$	7 899	21.1
$[96^2, 200^2)$	2 261	6.0
$[200, +\infty)$	707	1.9

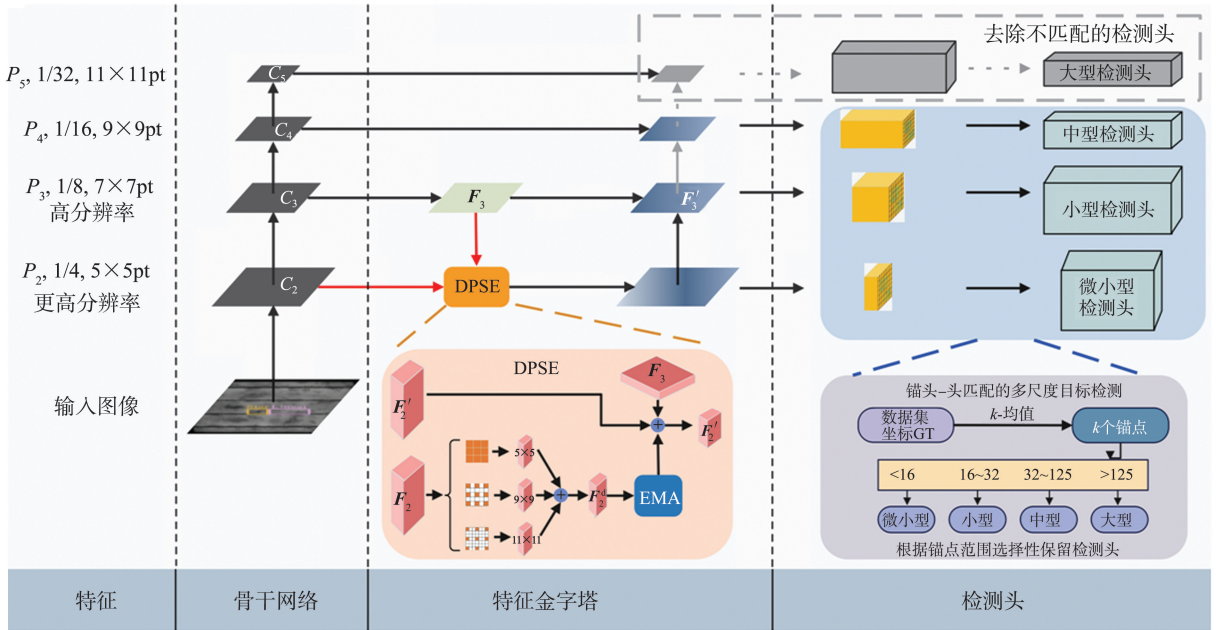


图 1 网络整体结构

Fig.1 The whole architecture of the network

2.3 细节保留语义信息增强模块

深度学习网络特征提取质量直接影响着目标检测性能,现有多尺度方法在提取特征过程中使用大量下采样操作,获得更大的语义信息感受野^[19]。对于小目标检测而言,大量下采样操作易丢失细粒度信息,在极端情况下会将目标缩减到单个像素,造成信息丢失和性能下降。为解决现有多尺度方法在下采样过程中丢失细粒度信息的问题,本研究设计了细节保留语义信息增强模块 (detail-preserving semantic enhancement, DPSE)。DPSE 模块通过保留小目标细粒度特征,捕获更丰富语义信息,增强模型对小目标的检测能力。

输入图像经步长为 2,卷积核为 3×3 的卷积进行两次下采样,得到包含丰富细粒度信息的 P_2 级别特征层 C_2 ,适用于小目标检测任务。重复下采样步

2.2 模型整体结构

为了克服上述挑战,本研究提出了一种基于跨层特征融合和锚-头对齐策略的检测方法,图 1 展示了本研究方法的模型整体结构,主要包含 3 个部分,分别是骨干网络,特征金字塔以及检测头。将图片输入骨干网络中提取图像的多尺度特征,生成一系列不同分辨率的特征图,包含从低级到高级的丰富信息;在细节保持信息增强模块中使用扩张卷积和高分辨率特征图学习细粒度语义信息,保留和增强细粒度特征;通过保留匹配的检测头,实现锚点与特征图的尺度匹配,使模型能准确定位和识别小目标,提高光伏缺陷小目标检测性能。

骤得到 P_3 、 P_4 、 P_5 级别特征图,感受野分别为 7 像素 \times 7 像素、9 像素 \times 9 像素和 11 像素 \times 11 像素,特征图逐步包含更多语义信息,有利于大目标检测。特征层 C_2 感受野较小,获取语义信息能力有限,不足以有效区分小目标与背景,学习与 P_2 级别细粒度信息相关的更大感受野可以增强小目标语义表达能力,本研究在 P_2 级别特征图中引入扩张卷积增大感受野。DPSE 模块通过高级特征的感受野来计算扩张卷积的扩张率。特征层 C_2 、 C_4 和 C_5 的感受野尺寸 (C_2 指骨干网络的特征层,其他类同) 分别为 5 像素 \times 5 像素、9 像素 \times 9 像素和 11 像素 \times 11 像素。为了在 C_2 上得到 9 像素 \times 9 像素和 11 像素 \times 11 像素大小的感受野,扩张卷积采用了 3×3 的卷积核,步长为 1,扩张率 d 分别为 2 和 3,计算公式为

$$d = (R_{i+1} - R_i) / S_i (k - 1), \quad (1)$$

式中, R_i 为当前感受野, R_{i+1} 为目标感受野, S_i 为卷积步长, k 为卷积核大小^[28]。

本模型利用扩张卷积获得具有不同感受野的高分辨率特征图, 基于细粒度信息的不同感受野语义信息, 公式为

$$F_{21}, F_{22}, F_{23} = \text{DilatedConv}(F_2, d), \quad (2)$$

式中 $\text{DilatedConv}(\cdot)$ 为不同扩张率 d 下的扩张卷积运算。对于高分辨率特征层 C_2 的特征图 F_2 使用扩张率 $d=2$ 的扩张卷积, 得到与 C_4 的特征图感受野相同的高分辨率特征图 F_{22} , 使用扩张率 $d=3$ 的扩张卷积, 得到与 C_4 的特征图感受野相同的高分辨率特征图 F_{23} 。为消除使用多个扩张卷积产生的潜在问题, 生成特征图 F_{21} 时使用标准卷积 ($d=1$) 保留局部信息。本模型直接使用扩张卷积和高分辨率特征图来学习与细粒度细节相关的语义信息, 减少了下采样过程中信息丢失, 解决了获得语义信息与细粒度信息之间相关性较弱的问题。

本模型使用一个可学习的权重机制将粗粒度特征融合到每个扩张率 d 中, 该过程为

$$F_2^d = \text{EMA}(\text{Fusion}(F_{21}, F_{22}, F_{23})), \quad (3)$$

式中: $\text{Fusion}(\cdot)$ 为可学习的加权融合; $\text{EMA}(\cdot)$ 为高效多尺度注意力机制 (efficient multi-scale attention, EMA), 作用是突出前景特征^[29]。对于 C_2 的特征图 F_2^d , 使用加权融合将增强特征图 F_2^d 与上采样的 C_3 的特征图 F_3 结合, 实现对特征图 F_2^d 的特征增强, 该过程为

$$F_2' := \text{Cat}(F_2^d, F_3), \quad (4)$$

式中, Cat 为向量拼接, “:=” 为赋值操作。

2.4 基于锚点-头 (anchor-head) 匹配的多尺度目标检测

本节进一步探讨锚点、检测头和特征图之间的关系, 及其对无人机光伏缺陷目标检测性能的影响。多尺度检测策略通常在不同尺度层采用不同尺寸锚点来识别目标。人工手动设计锚点难以同时适应检测小尺度目标和正常尺度目标, 导致尺度级别的不匹配问题。一种直观策略是引入附加微小检测头^[30], 利用低层细粒度特征捕捉小目标。

增加额外检测头使锚点划分过于细致, 误导多个检测头学习高度相似的特征, 产生过拟合风险。为克服这一挑战, 提出了一种基于锚点和预测头匹配的多尺度目标检测策略, 以实现锚点和特征图之间的尺度匹配。

本研究探究了检测头和锚点范围之间的最优对应关系, 作为锚点和检测头之间尺度级匹配的参

考。表 2 展示了在 PVEL-AD 数据集上使用小尺寸、中型目标和大目标检测头时, YOLOv7 生成的锚点与检测头最优锚点范围的比较结果。

表 2 生成锚点与当前检测头最优锚点范围对比
Table 2 Comparison of generated anchors with the optimal anchor scopes of the current head

检测头	最优锚点范围/像素	YOLOv7 生成的锚点/像素
Tiny Head	<16	Unused
Small Head	[16, 32)	[4, 6, 8, 14, 15, 11]
Medium Head	[32, 125]	[12, 16, 19, 36, 40, 28]
Large Head	>125	[36, 75, 76, 55, 72, 146]

结果表明, YOLOv7 生成的锚点与检测头不匹配, 导致模型性能受限。本研究设计了一种促进锚点与检测头相匹配的策略, 解决锚点与特征图尺度不匹配的问题。

以 PVEL-AD 数据集为例, 原始的 YOLOv7 采用了小型、中型和大型 3 种检测头。本研究利用 k -means 算法和数据集标签分别计算每个检测头上最匹配的锚点, 得到小型检测头锚点为 [4, 6, 8, 14, 15, 11], 中型检测头锚点为 [12, 16, 19, 36, 40, 28], 大型检测头锚点为 [36, 75, 76, 55, 72, 146]。锚点基于 PVEL-AD 数据集目标的实际尺寸分布生成, 确保生成锚点充分覆盖小尺寸目标。为得到当前数据集中目标大小的分布, 从每组锚点中分别取最小值和最大值成对, 即 (4, 15)、(12, 28)、(36, 146)。

将最小值和最大值与表 2 中最优检测头进行匹配, 结果分别对应微小型、小型和中型。根据匹配结果调整模型预测头, 增加微小型检测头, 去除大型检测头, 确保预测头处理的锚点范围与特征图的分辨率相适应。经匹配, 得到微小型检测头锚点聚类结果为 [4, 6, 8, 14, 15, 11], 小型检测头锚点聚类结果为 [12, 16, 19, 36, 40, 28], 中型检测头锚点聚类结果为 [36, 75, 76, 55, 72, 146], 实现了锚点与特征图的尺度级匹配。

本研究通过锚点与特征图之间的多尺度级匹配, 缓解了过拟合问题, 提高了小目标检测性能。算法 1 为上述过程具体步骤:

算法 1 锚点-头匹配算法

输入 数据集坐标 GT、当前检测头 CHead、锚点匹配范围 YHead。

参数 SHead 为选中的检测头。

输出 模型检测头对准程序。

(1) 使用 k -means 算法对数据集坐标 GT 进行聚类得到 k 个锚点;

- (2) 根据锚点和 YHead 进行尺度级别匹配,选出对应检测头 SHead;
- (3) if SHead 长度 \neq CHead 长度 then;
- (4) if SHead 长度 $>$ CHead 长度 then;
- (5) return 锚点划分过于粗糙,需添加匹配的检测头;
- (6) else;
- (7) return 锚点划分过于细致,需去掉不匹配的检测头;
- (8) end if;
- (9) else if SHead \neq CHead then;
- (10) return 添加匹配的检测头以替换不匹配的检测头;
- (11) end if.

2.5 训练和测试

本模型采用与 YOLOv7 一致的损失函数,即目标分类损失和目标框回归损失。其中,目标分类损失采用二值化交叉熵损失函数 (binary cross entropy, BCE)^[7] 以及焦点损失 (focal loss)^[31],目标框回归损失采用完全交并比 (complete intersection over union, CIoU) 回归损失^[32]。测试时,将图像尺寸调整到与训练尺寸一致,输入到网络中得到检测输出。

3 试验结果及分析

3.1 试验数据集以及试验环境

本研究采用河北工业大学与北京航空航天大学共同发布的 PVEL-AD 数据集作为评估数据集^[4]。该数据集共收录有超过 36 000 幅各类光伏电池异常缺陷检测照片,包括 1 类无异常图像和 12 个不同类别的异常缺陷图像,如裂纹、断栅、黑芯、未对准、粗线、划痕、碎片、断角及材质问题等。提供了超过 40 000 个真实标注框用于缺陷检测。为验证方法的完备性,本研究还在大规模无人机航拍数据集 CARPK 数据集^[33]进行了测试。CARPK 包括 989 张幅图像用于训练,459 幅图像用于测试。

试验采用 Pytorch1.10.0 训练框架,系统环境为 Windows10,计算设备为英伟达 GeForce MX230。使用 CUDA 11.3 进行 GPU 加速。模型训练轮次为 200 轮,批次大小为 16,优化器使用随机梯度下降法,初始学习率设定为 0.01^[34]。

3.2 性能评价指标

本研究使用准确率 (precision, P)、召回率 (recall, R)、均值平均精度 (mean average precision, P_{mA}) 作为指标来评价模型性能^[7,30]。其中,准确率

P 是模型正确识别为正样本的数量与被模型识别为正样本的数量之比,公式为

$$P = \frac{T_p}{T_p + F_p} \times 100\%, \quad (5)$$

式中, T_p 为真正样本正确识别成正样本的数量, F_p 为负样本识别为正样本的数量。

召回率 (Recall, R) 表示模型识别出的正样本占正样本总数的百分比,公式为

$$R = \frac{T_p}{T_p + F_N} \times 100, \quad (6)$$

式中 F_N 为真正样本识别为负样本的数量。

平均精度 (average precision, P_A) 表示不同召回率下准确率的平均值,可用 P - R 曲线围成的面积计算,模型的性能与 P_A 成正相关,公式为

$$P_A = \int_0^R P dR. \quad (7)$$

均值平均精度 P_{mA} 即各个类别 P_A 的平均值,公式为

$$P_{mA} = \frac{\sum_{i=1}^k P_{Ai}}{k}. \quad (8)$$

$P_{mA(0.50:0.95)}$ 表示交并比 (intersection over union, IoU) 阈值在 0.5~0.95 (步长 0.05) 条件下的平均准确率, $P_{mA(0.50)}$ 表示 IoU 阈值大于 0.5 条件下的平均 P_{mA} ^[7,30]。

3.3 试验结果分析

试验选取 FCOS、RetinaNet、YOLOv5 以及 YOLOv7 等目标检测模型进行对比,模型超参数和训练参数都设置为默认值,使用相同数据集进行训练。表 3 为 PVEL-AD 数据集上不同检测算法的性能比较,对比 YOLOv5 以及 YOLOv7 等主流目标检测模型,本研究方法获得了最优检测性能,检测指标 P 、 R 、 $P_{mA(0.50)}$ 及 $P_{mA(0.50:0.95)}$ 分别提高 2.8、4.8、2.6 及 2.5 个百分点。与 CascadeNet^[35] 等两阶段检测方法相比,本研究方法具有显著性能优势。

表 3 不同算法在 PVEL-AD 数据集的试验结果对比
Table 3 Comparison of experimental results of different algorithms on the PVEL-AD dataset 单位: %

算法	P	R	$P_{mA(0.50)}$	$P_{mA(0.50:0.95)}$
FCOS+RFLA	52.3	41.6	50.0	29.1
RetinaNet	56.7	44.1	53.9	30.8
GFL ^[36]	68.4	56.1	65.0	51.7
CascadeNet	60.9	49.2	60.1	38.8
YOLOv5	73.1	62.5	70.5	55.3
CZFCOS Det	72.5	63.1	73.8	55.6
YOLOv7	75.5	63.3	73.2	56.9
本研究方法	78.3	68.1	75.8	59.4

注:粗体数据表示最优性能。

表4为在CARPK数据集上的试验结果对比。试验结果表明,本研究方法实现了最优检测性能,各指标对比YOLOv7均有显著的性能提高。

表4 不同算法在CARPK数据集的试验结果对比
Table 4 Comparison of experimental results of different algorithms on the CARPK dataset 单位:%

算法	P	R	$P_{mA(0.50)}$	$P_{mA(0.50:0.95)}$
YOLOv5	—	—	62.3	95.3
QueryDet ^[37]	—	—	—	94.0
Car-Det	—	—	63.1	95.8
YOLOv7	97.6	94.4	65.8	97.5
本研究方法	97.9	94.5	68.8	97.6

注:粗体数据表示最优性能,“—”表示方法未提供指标。

3.4 消融试验与讨论

本研究在PVEL-AD数据集上进行了消融试验以验证不同模块的有效性。训练和测试的输入分辨率设置为640像素×640像素,试验分析了每个组件的有效性。表5为各核心组件对整体检测性能的影响:(1) DPSE模块的作用。根据表5所示,引入DPSE模块显著增强了检测性能,其中, $P_{mA(0.50)}$ 指标提高1.7个百分点, $P_{mA(0.50:0.95)}$ 指标提高1.6个百分点。这表明DPSE模块有效重用了移除大型检测头过程中丢失的粗粒度语义特征图信息,通过残差结构丰富了中等尺寸目标的特征表示,提高了检测精度。(2) 尺寸匹配的作用。无人机巡检图像以小尺寸目标居多,传统算法使用过多检测头,

锚点划分过于精细,与特征图尺寸不匹配,增加了检测头捕捉相似特征的风险,导致过拟合问题。本研究在YOLOv7的基础上,引入一个微小型检测头并去除大型检测头,实现了尺寸匹配的优化。试验结果表明,这一改进显著提高了检测性能, $P_{mA(0.50)}$ 指标提高1.1个百分点, $P_{mA(0.50:0.95)}$ 指标提高1.2个百分点。

表5 消融试验结果
Table 5 Result of ablation study

基础模型	DPSE模块	尺寸匹配	$P_{mA(0.50)}/\%$	$P_{mA(0.50:0.95)}/\%$
√	—	—	73.2	56.9
√	√	—	74.9(+1.7)	58.5(+1.6)
√	—	√	74.3(+1.1)	58.1(+1.2)
√	√	√	75.8(+2.6)	59.4(+2.5)

注:“—”表示移除对应模块。

DPSE模块结合尺寸匹配操作,进一步使 $P_{mA(0.50)}$ 提高2.6个百分点,两个模块协同实现了最佳检测性能。

图2为模型学习到的特征图可视化结果。可视化结果表明,相较于基线模型YOLOv7,本研究方法激活了更多的小目标,对微小和小尺寸目标具有更强的表达能力,充分关注到与场景任务密切相关的中小尺寸物体信息,有助于提高小目标的检测性能,印证了DPSE模块可以增强语义信息,减少小目标的区分难度并提高召回率。

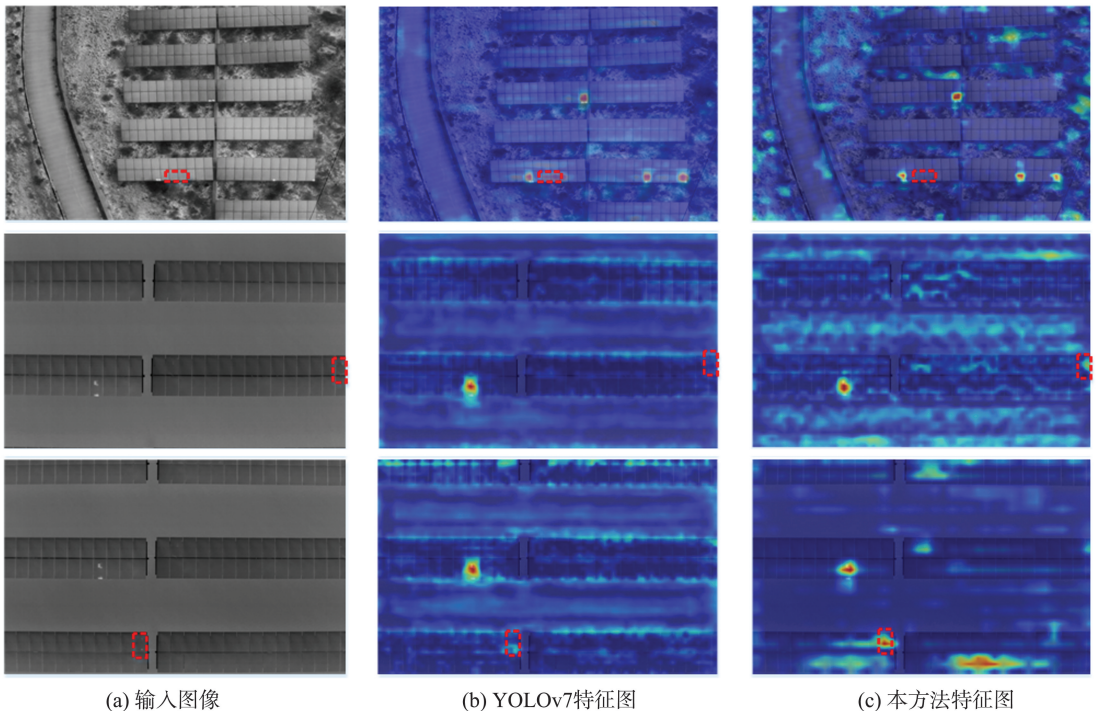


图2 特征图可视化对比
Fig.2 Comparison of feature maps


表6为模型参数量和计算复杂度对比分析。相比于基线模型YOLOv7,本研究方法的模型参数和计算量虽略有增加,但带来了显著的性能提高。

表6 模型计算复杂度对比
Table 6 Comparison of model complexity

算法	参数量	计算量 (GFLOPs)	$P_{mA(0.50)}$ / %	$P_{mA(0.50:0.95)}$ / %
YOLOv7	3.7×10^7	104.1	73.2	56.9
本研究方法	3.9×10^7	124.5	75.8	59.4

3.5 可视化结果

图3为本研究提出的细粒度特征增强与尺寸匹配的光伏缺陷目标检测方法的可视化检测效果。其中,图3(a)为某光伏场站无人机巡检图像缺陷目标检测结果,在光伏缺陷无人机巡检场景中,本研究方法实现了对密集分布的并发缺陷小目标的精确检测。图3(b)为山东省济南市某工程建设现场无人机航拍图像的微小目标检测效果,本研究方法实现了对包含大量微小目标的复杂场景的成功检测。



(a) 光伏缺陷目标检测效果



(b) 微小目标检测效果

图3 检测效果图

Fig.3 Prediction effect diagram

4 结论

本研究针对无人机巡检场景中光伏缺陷检测目标尺寸过小导致的漏检和误检问题,提出了一种先进的改进算法,区别于传统的样本数据增强、多尺度学习和特征增强等策略,引入了粗粒度特征融合模块DPSE,有效整合深层和浅层特征,增强了模型对小目标的特征表达能力。为更好匹配小目标和锚点,提出一种新的锚点-预测头匹配机

制,实现了锚点与特征图之间多尺度级匹配,提高了光伏缺陷小目标检测性能。在大规模光伏缺陷数据集PVEL-AD上试验结果表明,本研究方法相较于基线模型YOLOv7,准确率提高2.8个百分点,平均均值精度 $P_{mA(0.50)}$ 、 $P_{mA(0.50:0.95)}$ 分别提高2.6、2.5个百分点,显著优于基线模型,验证了算法的有效性。

参考文献:

- [1] 白宇皓. 碳达峰,碳中和背景下新能源发展趋势探讨[J]. 经济技术协作信息, 2021(35): 3.
BAI Yuhao. Discussion on the development trend of new energy under the background of carbon peak and carbon neutrality [J]. Economic Technical Cooperation Information, 2021(35): 3.
- [2] 曹阳, 孟茁. 基于无人机光伏巡检的视频图像传输系统设计[J]. 计算机与网络, 2020, 46(15): 62-65.
CAO Yang, MENG Zhuo. Design on video image transmission system based on uav photovoltaic inspection [J]. Computer & Network, 2020, 46(15): 62-65.
- [3] 李香凡, 唐志伟, 胡家龙, 等. 无人机光伏巡检的图像目标检测算法[J]. 电子世界, 2020, 11: 7-8.
LI Xiaingfan, TANG Zhiwei, HU Jialong, et al. Image target detection algorithm for uav photovoltaic inspection [J]. Electronics World, 2020, 11: 7-8.
- [4] SU B, ZHOU Z, CHEN H. PVEL-AD: a large-scale open-world dataset for photovoltaic cell anomaly detection [J]. IEEE Transactions on Industrial Informatics, 2022, 19(1): 404-413.
- [5] 刘颖, 刘红燕, 范九伦, 等. 基于深度学习的小目标检测研究与应用综述[J]. 电子学报, 2020, 48(3): 590-601.
LIU Ying, LIU Hongyan, FAN Jiulun, et al. A survey of research and application of small object detection based on deep learning [J]. Acta Electronica Sinica, 2020, 48(3): 590-601.
- [6] 刘洋, 战荫伟. 基于深度学习的小目标检测算法综述[J]. 计算机工程与应用, 2021, 57(2): 37-48.
LIU Yang, ZHAN Yinwei. Survey of small object detection algorithms based on deep learning [J]. Journal of Computer Engineering & Applications, 2021, 57(2): 37-48.
- [7] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C] // Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Vancouver, Canada: IEEE, 2023:

- 7464-7475.
- [8] FADA J S, HOSSAIN M A, BRAID J L, et al. Electroluminescent image processing and cell degradation type classification via computer vision and statistical learning methodologies[C]// Proceedings of IEEE 44th Photovoltaic Specialist Conference (PVSC). Washington, D.C., USA: IEEE, 2017: 3456-3461.
- [9] KARIMI A M, FADA J S, HOSSAIN M A, et al. Automated pipeline for photovoltaic module electroluminescence image processing and degradation feature classification[J]. IEEE Journal of Photovoltaics, 2019, 9(5): 1324-1335.
- [10] 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.
- [11] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10) [2024-07-15]. <https://arxiv.org/abs/1409.1556>
- [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). Rome, Italy: IEEE, 2018: 2035-2039.
- [13] TANG W, YANG Q, XIONG K, et al. Deep learning based automatic defect identification of photovoltaic module using electroluminescence images [J]. Solar Energy, 2020, 201: 453-460.
- [14] AKRAM M W, LI G, JIN Y, et al. CNN based automatic detection of photovoltaic cell defects in electroluminescence images [J/OL]. Energy, 2019, 189: 116319 [2024-05-20]. <https://doi.org/10.1016/j.energy.2019.116319>
- [15] CHEN X, KARIN T, JAIN A. Automated defect identification in electroluminescence images of solar modules[J]. Solar Energy, 2022, 242: 20-29.
- [16] FIORESI J, COLVIN D J, FROTA R, et al. Automated defect detection and localization in photovoltaic cells using semantic segmentation of electroluminescence images[J]. IEEE Journal of Photovoltaics, 2021, 12(1): 53-61.
- [17] SU B, CHEN H, CHEN P, et al. Deep learning-based solar-cell manufacturing defect detection with complementary attention network[J]. IEEE Transactions on Industrial informatics, 2020, 17(6): 4084-4095.
- [18] MEETHAL A, GRANGER E, PEDERSOLI M. Cascaded zoom-in detector for high resolution aerial images[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE, 2023: 2045-2054.
- [19] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Hawaii, USA: 2017: 2117-2125.
- [20] HONG M, LI S, YANG Y, et al. SSPNet: scale selection pyramid network for tiny person detection from uav images[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 1-5.
- [21] HE J Y, CHENG Z Q, LI C, et al. Damo-streamnet: optimizing streaming perception in autonomous driving [EB/OL]. (2023-05-20) [2024-07-15]. <https://arxiv.org/abs/2303.17144>
- [22] DU B, HUANG Y, CHEN J, et al. Adaptive sparse convolutional networks with global context enhancement for faster object detection on drone images [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE, 2023: 13435-13444.
- [23] SUN Y, WANG S, CHEN C, et al. Boundary-guided camouflaged object detection[C]// Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence. Vienna, Austria: IJCAI, 2022: 1335-1341.
- [24] NOH J, BAE W, LEE W, et al. Better to follow, follow to be better: towards precise supervision of feature super-resolution for small object detection[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. California, USA: IEEE, 2019: 9725-9734.
- [25] LIANG J, ZENG H, ZHANG L. Details or artifacts: a locally discriminative learning approach to realistic image super-resolution [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE, 2022: 5657-5666.
- [26] XU C, WANG J, YANG W, et al. RFLA: gaussian receptive field based label assignment for tiny object detection[C]// European conference on computer vision. Cham, Switzerland: Springer, 2022: 526-543.
- [27] LEI T, SUN R, WANG X, et al. CiT-Net: convolutional neural networks hand in hand with vision transformers for medical image segmentation [C]// Proceedings of the 32th International Joint Conference on Artificial Intelligence. Macao, China: IJCAI, 2023: 1017-1025.
- [28] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [EB/OL]. (2016-04-30) [2024-07-15]. <https://arxiv.org/abs/1511.07122>

- [29] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning [C]// ICASSP 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes, Greece; IEEE, 2023: 1-5.
- [30] ZHU X, LYU S, WANG X, et al. TPH-YOLOv5: improved yolov5 based on transformer prediction head for object detection on drone-captured scenarios [C]// Proceedings of the IEEE/CVF international conference on computer vision. Montreal, Canada; IEEE, 2021: 2778-2788.
- [31] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]// Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy; IEEE, 2017: 2980-2988.
- [32] ZHENG Z, WANG P, LIU W, et al. Distance-iou loss: faster and better learning for bounding box regression [C]// Proceedings of the AAAI conference on artificial intelligence. New York, USA; AAAI Press, 2020, 34 (7): 12993-13000.
- [33] NGUYEN D L, VO X T, PRIADANA A, et al. Car detector based on yolov5 for parking management [C]// Conference on Information Technology and its Applications. Cham, Switzerland; Springer, 2023: 102-113.
- [34] 周颖,颜毓泽,陈海永,等. 基于改进 YOLOv8 的光伏电池缺陷检测 [J]. 激光与光电子学进展, 2024, 61 (8): 1-17.
- ZHOU Ying, YAN Yuze, CHEN Haiyong, et al. Defect detection of photovoltaic cells based on improved yolov8 [J]. Laser & Optoelectronics Progress, 2024, 61 (8): 1-17.
- [35] ZHANG X, IZQUIERDO E, CHANDRAMOULI K. Dense and small object detection in uav vision based on cascade network [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops. Seoul, IEEE, 2019: 118-126.
- [36] LI X, WANG W, WU L, et al. Generalized focal loss: learning qualified and distributed bounding boxes for dense object detection [J]. Advances in Neural Information Processing Systems, 2020, 33: 21002-21012.
- [37] YANG C, HUANG Z, WANG N. Querydet: cascaded sparse query for accelerating high-resolution small object detection [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA; IEEE, 2022: 13668-13677.

(编辑:陈燕)

(上接第8页)

- [19] SAHITO F, PAN Z W, SAHITO F, et al. Transpose convolution based model for super-resolution image reconstruction [J]. Applied Intelligence, 2023, 53 (9): 10574-10584.
- [20] 陈满,金诚谦,莫恭武,等. 基于改进 U-Net 模型的小麦收获含杂率在线检测方法 [J]. 农业机械学报, 2023, 54 (2): 73-82.
- CHEN Man, JIN Chengqian, MO Gongwu, et al. Online detection method of impurity rate in wheat mechanized harvesting based on improved U-Net model [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54 (2): 73-82.
- [21] BOUSIAS ALEXAKIS E, ARMENAKIS C. Evaluation of UNet and UNet++ architectures in high resolution image change detection applications [J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020, XLIII-B3-2020: 1507-1514.
- [22] SARITURK B, BAYRAM B, DURAN Z D, et al. Feature extraction from satellite images using segnet and fully convolutional networks (FCN) [J]. International Journal of Engineering and Geosciences, 2020, 5 (3): 138-143.
- [23] YU L J, ZENG Z X, LIU A, et al. A lightweight complex-valued DeepLabv3+ for semantic segmentation of PolSAR image [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 930-943.

(编辑:熊小原)