

DOI:10.19651/j.cnki.emt.2210406

基于改进 Centernet 的变电设备红外检测方法^{*}

黄悦华 杨楚睿 陈晨 李晨 万旭东

(三峡大学电气与新能源学院 宜昌 443002)

摘要: 变电站红外图像中小目标众多并且环境复杂,导致现有检测算法精度较低,因此本文提出一种基于改进 Centernet 的变电设备红外检测方法。首先以 Centernet 作为基础模型,将 FPN 结构引入上采样网络以充分利用小目标特征信息,从而解决小目标难以被精确检测的问题;然后,为提升网络在复杂环境中检测的鲁棒性,通过在主干网络 resnet50 中嵌入注意力机制来提升网络对重要目标的关注;最后,采用 CIOU 损失替换中心点偏移损失和宽高损失的训练策略以加速网络收敛、提升训练效果。实验结果表明,本文方法在小目标检测和复杂环境检测中都能有较好的检测效果,检测精度相比改进前提升 3.1%,达到 92.7%,相比 Faster R-CNN 等现有方法精度更高,在变电设备红外检测中具有一定参考价值。

关键词: 变电设备红外图像;Centernet;特征金字塔;注意力机制;CIOU

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.6040

Infrared detection method of substation equipment based on improved Centernet

Huang Yuehua Yang Churui Chen Chen Li Chen Wan Xudong

(College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: There are many small targets in infrared images of substations with complex environment, resulting in low accuracy of existing detection algorithms. Therefore, this paper proposes an infrared image detection method for substation equipment based on improved Centernet. Firstly, taking Centernet as basic model, the FPN structure is introduced into the upsampling network to fully use the feature information of small targets, so as to solve the problem that small targets are difficult to be accurately detected; Then, in order to improve the detection robustness of the network in complex environment, an attention mechanism is embedded in the backbone network resnet50 to increase the attention of network to core targets; Finally, the training strategy of center point offset loss and width and height loss is replaced by CIOU loss to accelerate network convergence and improve training effect. The experimental results show that the method in this paper can have better detection effect in both small targets detection and complex environment detection, and the detection accuracy is improved by 3.1%, reaching 92.7%, which is more accurate than existing methods such as Faster R-CNN, and has certain reference value in infrared image detection of substation equipment.

Keywords: infrared images of substation equipment;Centernet;feature pyramid network;attention mechanism;CIOU

0 引言

红外热成像技术是利用光电技术将物体发射的热辐射转换为可见图像的技术,已广泛应用于变电设备状态分析、故障诊断中^[1]。而目前面对海量的红外图像,通常采用人工进行分析诊断,不仅效率低下且易造成误判^[2],近年来,采用计算机视觉技术对电气设备进行自动检测已成为研究

热点,而对电气设备进行精准定位、分类是后续热缺陷快速筛查与预警的前提与关键^[3]。

传统的检测算法通过特征提取的方式对待检测目标进行分割与检测^[4]。文献[5]通过图像分割与支持向量机(support vector machine,SVM)相结合的方法识别零值绝缘子;文献[6]通过粒子群优化算法、Niblack 局部阈值分割算法和 SVM 分类器对电气设备进行分类。上述传统方法

收稿日期:2022-06-21

*基金项目:国家自然科学基金(52007103)、湖北省科技重大专项(2020AEA012)资助

虽然具有一定的检测能力,但其精度易受环境影响,难以应用于变电站复杂场景中。

基于深度学习的目标检测技术具有速度快、精度高的优点,已经逐渐取代传统的检测算法^[7]。基于深度学习的目标检测算法可分为两阶段目标检测算法和端到端目标检测算法,两阶段检测算法主要包括 RCNN^[8]、Fast-RCNN^[9]、Faster-RCNN^[10]等,该类算法首先生成候选区域,再进行分类与定位。文献[11]在 Faster-RCNN 的基础上采用了迁移学习与类别修正,能够较为精准地识别部分红外电气设备;文献[12]改进了 Faster-RCNN 中的锚框生成方法和非极大值抑制,一定程度上提升了红外绝缘子的检测精度。上述两阶段算法虽然具有较高精度,但网络结构复杂导致推理速度较慢^[13]。端到端检测算法主要包括 SSD^[14]、YOLOv3^[15]等,该类算法无需生成候选区域,直接预测目标的种类与位置,相比两阶段检测算法具有更快的检测速度^[16]。文献[17]将 SSD 的主干网络进行替换并增加多个卷积层,在红外电气设备检测中提升了检测速度与精度。文献[18]在 YOLOv3 的基础上增加跨阶段局部模块、路径聚合网络等,并在红外电气设备数据集上验证了各改进方案的有效性。上述研究虽然在一定程度上提升了红外电气设备的检测效果,但所提方法依赖大量锚框,计算效率较低且易造成漏检^[19],并且未考虑实际拍摄过程中存在较多小目标以及环境复杂的问题,检测能力具有较大提升空间。Centernet^[20]是一种采用关键点检测的无锚框算法,相比上述基于锚框的算法具有更优秀的检测效率及准确率^[21],因此,本文选用 Centernet 作为基础模型,并考虑小目标与复杂环境对模型的影响,对其进行改进研究。

针对以上问题,本文提出一种改进 Centernet 的变电设备红外检测方法,主要贡献如下:1)为解决小目标检测能力差的问题,在 Centernet 的上采样网络引入特征金字塔(feature pyramid network,FPN)^[22]结构,充分保留小目标特征信息量;2)在主干网络 resnet50 中嵌入 SE(Squeeze-and-Excitation)^[23]注意力机制,提升网络在复杂环境中对待检测目标的关注,从而增强网络检测能力;3)将原损失函数中的中心点偏移损失和宽高损失替换为 CIOU^[24]损失,进而提升网络的收敛速度与检测效果。

1 变电站电气设备红外图像特点

变电站中拍摄的电气设备红外图像存在以下特点:

1)远距离目标小。如图 1(a)所示,在变电站中进行电气设备红外拍摄时,由于绝缘子本身体积较小以及拍摄距离较远,导致该目标在红外图像上所在区域的像素点较少,包含的特征信息十分有限,在经过目标检测网络多次特征提取后,该类小目标信息可能存在丢失,极易造成漏检。

2)环境复杂。如图 1(b)所示,红外图像左下角的待检测绝缘子与遮挡物颜色相近,导致其特征并不突出;另外,红外图像易受到不同天气的热辐射干扰,因而可能包含较多无

用的背景特征。当采用目标检测网络对其进行特征提取时,难以区分待检测目标特征与环境特征,导致检测精度受限。

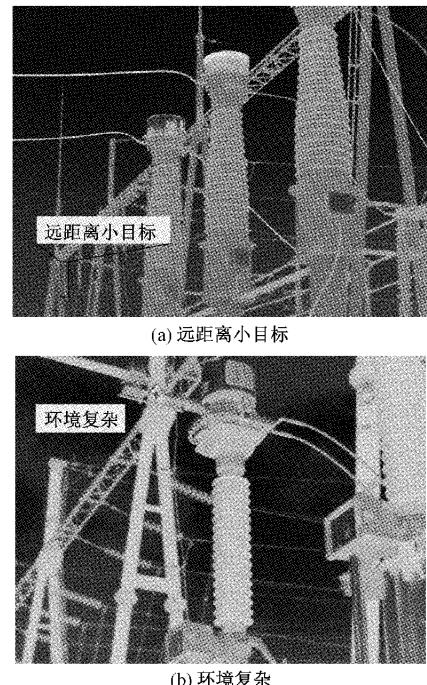


图 1 电气设备红外图像

因此,在变电站电气设备红外图像检测任务中,需增强对小目标的检测精度,并提升对重要目标特征的关注。

2 Centernet 网络结构

Centernet 是一种无锚框检测算法,通过物体的中心点来代替整个目标,无需提前设定锚框的超参数与非极大值抑制等复杂操作,相对于基于锚框的目标检测算法在检测速度与精度上更有优势,其网络结构如图 2 所示,其中包括输入层、主干网络、上采样网络和预测层。

输入层: 将原始图片采用短边补零的方式调整到 512×512 尺寸大小,并输入到主干特征提取网络。

主干网络: 原始 Centernet 将 Resnet50 作为特征提取主干网络,其中 Conv Block 和 Identity Block 的作用分别为加深网络的维度与深度。将输入图像经过多次 Conv Block 与 Identity Block 堆叠的下采样后,得到 $16 \times 16 \times 2048$ 的初步特征,将其输入到上采样网络。

上采样网络: 该网络将低分辨率的初步特征经过三次反卷积得到 $128 \times 128 \times 64$ 的高分辨率特征图,其中的每个特征点对应初始 512×512 特征图的一个区域。

预测层: 首先在热力图上预测每个热力点是否包含物体以及物体的种类;然后通过偏移量对中心点进行修正,对应于原始图像的精准中心点;最后回归目标的宽高。

3 基于改进 Centernet 的变电设备红外检测方法

Centernet 基础网络虽然具有较优秀的检测能力,但变

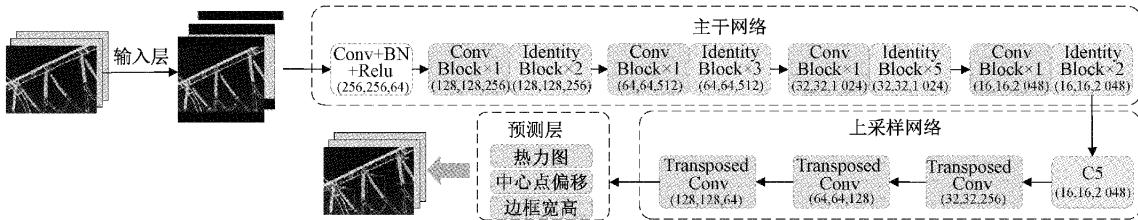


图2 原始Centernet网络结构

电站红外图像中小目标较多、环境复杂,难以实现高精度检测,因此本文以Centernet为基础模型架构,提出一种改进Centernet的变电设备红外检测方法,其网络结构如图3所示。首先,在上采样网络引入FPN结构,将每级生成的特征图信息充分保留,以增加小目标特征信息量,提升其检测效果;然后,在主干网络resnet50中嵌入具有特征判别能力的SE注意力模块,增强重要目标特征的注意力权重,抑制背景特征干扰;最后,针对原始Centernet收敛速度较慢以及目标框定位不准的问题,将原始中心点偏移损失与宽高损失替换为CIOU损失。

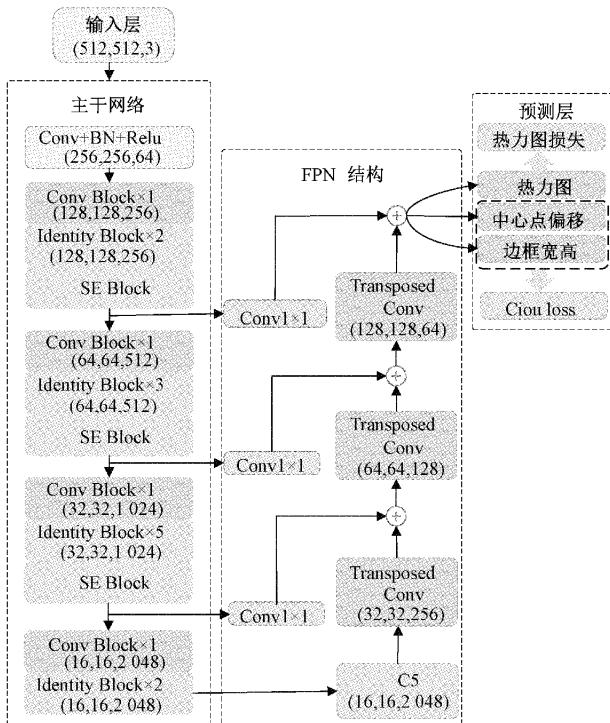


图3 本文网络结构

3.1 基于FPN结构的小目标检测优化

受电气设备种类和拍摄距离的影响,变电站图像中存在大量特征信息量少的小目标,原始Centernet对原始图像进行四次下采样后,仅保留最后一层 $16 \times 16 \times 2\,048$ 尺寸的特征图,导致小目标特征信息损失严重,难以对其精确检测。为解决该问题,本文将FPN结构引入至原始Centernet的上采样网络以充分融合浅层小目标信息,如图3中FPN结构所示,该结构充分保留Resnet50下采样

生成的 $128 \times 128 \times 256$ 、 $64 \times 64 \times 512$ 、 $32 \times 32 \times 1\,024$ 尺寸的特征图,通过多尺度特征融合使网络在提取丰富的语义信息的同时,保留足够的空间细节信息,使小目标定位更加精准。每级特征融合具体表现方式为:小尺寸特征图通过上采样以提升尺寸;Resnet50中大尺寸特征图通过 1×1 卷积调整通道数,然后通过向量相加操作将两者特征融合,最终得到 $128 \times 128 \times 64$ 的特征图。

3.2 基于SE注意力机制的复杂环境检测优化

由于变电站环境较为复杂,原始Centernet对图像数据进行特征提取时,同等的对待目标特征与环境特征,导致重要目标特征并不明显,最终影响检测效果。因此,本文在Centernet的主干网络resnet50中引入兼顾高性能与高效率的SE注意力机制,对重要目标的特征通道赋予更多注意力权重,从而使网络能关注更多的重要特征并且抑制背景特征,提升检测的鲁棒性。

SE注意力机制主要包括压缩与激励两个操作,其特征变化如图4所示。

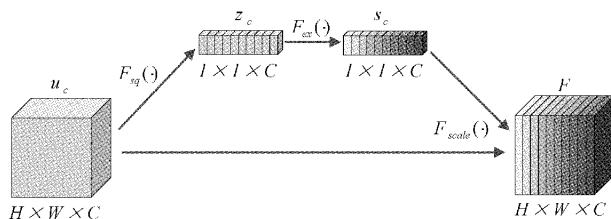


图4 SE注意力机制

压缩操作:采用全局平均池化将 $H \times W \times C$ 尺寸的特征图在空间维度上进行压缩,得到 $1 \times 1 \times C$ 尺寸的全局特征,如下:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (1)$$

式中: z_c 为平均池化层的输出特征; $F_{sq}(\cdot)$ 为平均池化操作; u_c 为输入特征图; H 、 W 为特征图的高和宽; i 、 j 为特征图尺寸变量。

激励操作:该操作包含两个全连接层和非线性激活函数,能加强不同特征通道之间的联系并减少计算量,并且对电气设备红外特征通道赋予不同的权重,如下:

$$s_c = F_{ex}(z_c, W_s) = \sigma(W_s \delta(W_s z_c)) \quad (2)$$

式中: s_c 为sigmoid函数输出的权重归一化向量; $F_{ex}(\cdot)$ 为激励操作; W_s 为权重变量; σ 和 δ 分别为Relu激活函数和

Sigmoid 激活函数; Wr 和 Wc 为全连接层权重。

最后将权重归一化向量与初始特征图相乘,完成 SE 注意力权重分配,得到 $H \times W \times C$ 的特征图,如下:

$$F = F_{scale}(u_c, s_c) = s_c \cdot u_c \quad (3)$$

式中: F 为已完成权重分配的特征图; $F_{scale}(\cdot)$ 为特征图赋权操作。

SE 注意力机制虽然能够判别不同特征通道的重要性来增强网络的特征提取能力,但如果在浅层主干网络中增加该模块,会使网络未充分提取特征就进行筛选判断,可能导致重要信息分辨错误,因此 SE 注意力模块在主干网络中嵌入位置如图 3 所示,以提取更多重要特征。

3.3 损失函数改进

原始 Centernet 算法预测目标框具体位置时,仅计算中心点偏置损失及边框损失,无法反应预测框与真实框的具体相交情况,在检测红外电气设备时边框定位会存在较大误差,而 CIOU 损失函数能够兼顾中心点偏移、边框相交情况、边框长宽比,从而弥补原始损失函数所带来的偏差。因此本文采用更全面的 CIOU 损失函数代替中心点偏置损失和边框损失进行训练,以提升模型整体性能,CIOU 损失函数如式(4)所示。

$$L_{ciou} = 1 - IOU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (4)$$

式中: IOU 为预测框与交并比; $\rho(\cdot)$ 为欧式距离计算; b 为真实框中心点; b^{gt} 为预测框中心点; c 为能同时包含预测框和真实框的最小框对角线距离,如图 5 所示,其中虚线框为预测框,实线框为真实框; α 和 v 分别为平衡参数和长宽比衡量参数,定义如下:

$$\alpha = \frac{v}{(1 - IOU) + v} \quad (5)$$

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

式中: w_{gt}, h_{gt} 为真实框的长、宽; w, h 分别为预测框的长、宽。

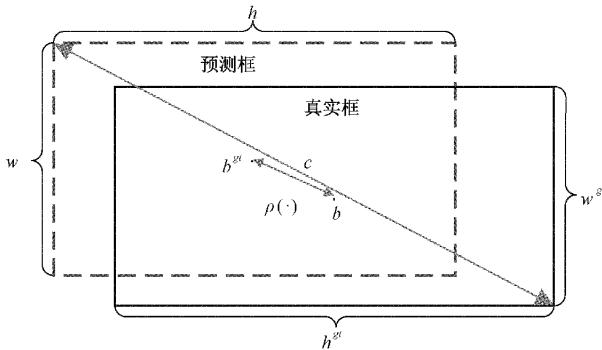


图 5 边框回归预测

因此,本文改进后的损失函数由热力图损失和 CIOU 损失构成,如下:

$$L = L_k + L_{ciou} \quad (7)$$

式中: L_k 为热力图损失,该损失在 focal loss 的基础上改进,用于均衡正负样本,自适应提升难训练样本的训练权重,减少易训练样本的训练权重,表达式如下:

$$L_k = \frac{-1}{N_0} \sum_{xyc} \begin{cases} (1 - \hat{Y}_{xyc})^\alpha \log(\hat{Y}_{xyc}), & Y_{xyc} = 1 \\ (1 - Y_{xyc})^\beta (\hat{Y}_{xyc})^\alpha \log(1 - \hat{Y}_{xyc}), & \text{其他} \end{cases} \quad (8)$$

式中: N_0 为真实关键点数量; α 和 β 为超参数,分别取值为 2、4; \hat{Y}_{xyc} 为预测值; Y_{xyc} 为真实标签值。

4 实验结果分析

4.1 实验准备

实验所使用的计算机 CPU 为 E5 2696V3, GPU 为 GTX1080Ti 11GB, 内存 64 GB, 深度学习框架为 pytorch1.4.0。

本文所采用数据集来自某国网公司提供的红外巡检图像。其中包括电流互感器、电压互感器、套管、绝缘子等 6 种电气设备共 1 265 张,为提升模型的泛化能力,将两个数据集分别进行 90°、180°、270° 旋转,使样本数量达到 5 060 张,借助 labeling 工具对数据集进行标记。训练集、验证集、测试集比例为 6 : 2 : 2。

4.2 实验评价指标

为了客观验证本文所提各改进方案的有效性以及凸显本文方法的优势,采用平均精度均值(mean average precision, mAP)、每秒处理帧数(frames per second, FPS)作为客观指标,计算如下:

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (9)$$

$$FPS = \frac{1}{t_{avg}} \quad (10)$$

式中: AP 为召回率(Recall)与精确率(Precision)关系曲线积分; N 为检测类别; t_{avg} 为处理一张图像的时间;Recall 与 Precision 分别表示为:

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

$$Precision = \frac{TP}{TP + FP} \quad (12)$$

式中: TP 为划分正例的个数; FN 为误检数; FP 为漏检数。

4.3 训练过程分析

为证明本文算法比原始 Centernet 算法在电气设备红外场景的检测优势,本节将两者采用相同数据集进行训练,对比 loss 迭代曲线与 mAP 迭代曲线。算法参数均设置如下:

图像在进入网络之前将其尺寸调整为 512×512,训练轮次(epoch)设置为 300,将训练前 100 轮设置为冻结训练,后 200 轮设置为解冻训练。批处理大小(batch size)在

冻结训练中设置为 128, 在解冻训练中设置为 16, 采用自适应矩估计(Adam)优化器训练。训练迭代图如图 6 所示, 其中图 6(a)为损失函数迭代曲线; 图 6(b)为 mAP 迭代曲线。实线为本文算法, 虚线为原始 Centernet 算法。

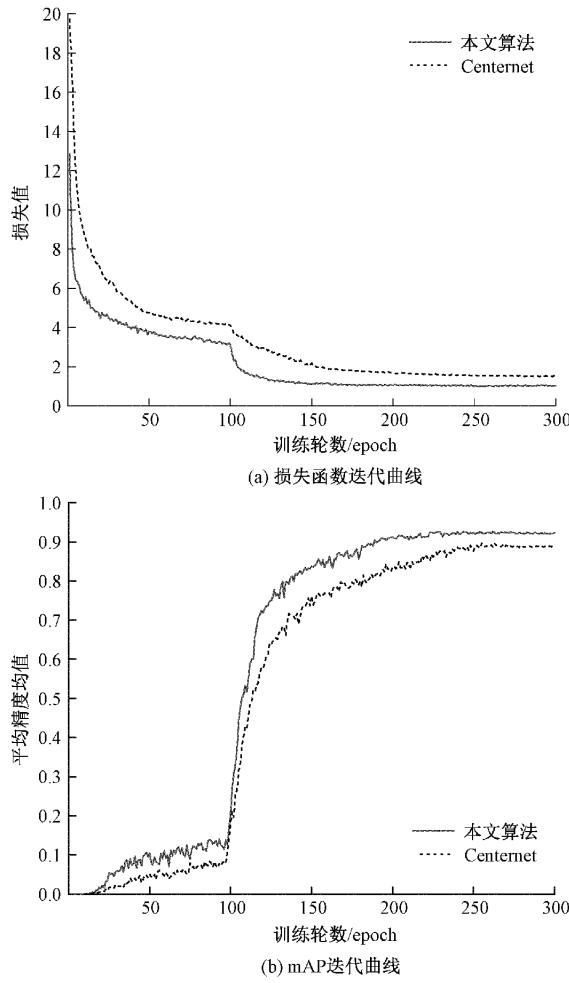


图 6 训练迭代图

由图 6(a)可知, 无论在冻结训练(0 到 100 轮)还是解冻训练(100~300 轮), 本文算法的损失函数下降斜率更大, 更快的趋于稳定, 表明本文算法在加入 CIOU 损失函数后, 加快了网络的收敛速度。并且本文算法最终损失值降至 1 左右, 而原始 Centernet 损失值在 1.5 左右, 表明本文算法在改进 FPN 结构、SE 注意力机制以及损失函数后, 使模型具有更强的学习训练能力。

由图 6(b)可知, 在红外电气设备数据集上, 两种算法均具有优秀的检测精度。本文算法在第 130 个 epoch 左右, mAP 值就达到 80%, 最终稳定在 92% 左右, 而 Centernet 算法在第 175 个 epoch 左右的 mAP 值才上升至 80%, 最终稳定至 89% 左右。因此, 本文算法在训练时无论在收敛速度上还是检测精度上都高于原始 Centernet。

采用 Centernet 与本文算法训练得到的最优权重分别对测试集进行预测, 各类红外电气设备检测的 mAP 值对

比结果如表 1 所示。

表 1 测试集检测结果对比

类别	mAP%(Centernet)	mAP%(本文算法)
电流互感器	94.4	95.4
绝缘子	84.1	89.5
套管	92.8	94.8
避雷器	90.1	93.2
电压互感器	88.2	91.7
静触头	87.8	91.4
平均	89.6	92.7

由表 1 可知, 本文算法对各类红外电气设备检测的 mAP 值比原始 Centernet 高 3.1%, 达到 92.7%。其中绝缘子提升效果最为明显, 由原始的 84.1% 提升至 89.5%, 分析其原因可能是原始算法丢失了较多小尺寸绝缘子的特征, 而本文算法采用 FPN 结构有效的提升了小目标的特征信息量, 从而明显的提升了绝缘子的精测精度。由此说明本文算法在变电站红外场景中具有更优异的检测性能。

4.4 消融实验

为验证文本所提各改进方案的有效性, 本节采用消融实验对各方案加入前后的效果, 如表 2 所示: 1) 改进 1 在原始 Centernet 的基础上引入 3.1 节所述 FPN 结构; 2) 改进 2 在改进 1 的基础上多增加 3.2 节嵌入的 SE 注意力模块; 3) 本文方法采用本文 3.3 节改进后的损失函数进行训练, L_k 为热力图损失, L_{cious} 为 CIOU 损失。

表 2 消融实验

方法	FPN	SE	$L_k + L_{cious}$	mAP%
原始 centernet	✗	✗	✗	89.6
改进 1	✓	✗	✗	91.1
改进 2	✓	✓	✗	92.3
本文方法	✓	✓	✓	92.7

从表 2 中可以看出, 改进 1 在原始 Centernet 的基础上添加了 FPN 结构, 提升了小目标特征信息量, mAP 值由 89.6% 上升至 91.1%, 验证了 FPN 结构在再融合多个尺度特征后, 能显著提升检测精度; 改进 2 在改进 1 的基础上新增了 SE 注意力机制, 使网络提取更多的有用特征, 排除背景干扰, mAP 值由 91.1% 提升至 92.3%, 证明了 SE 模块能够有效的关注重点目标, 提升网络精度; 本文方法将热力图损失与 CIOU 损失结合训练, mAP 值由改进 2 的 92.3% 达到 92.7%, 得益于 CIOU 损失函数的训练策略, 网络训练更加有效, 检测精度明显提升。

本文方法相比原始 Centernet 的 mAP 值提升 3.1%, 因此证明了本文各改进方案的有效性, 提升了在电气设备红外场景的检测效果。

4.5 不同算法检测效果对比

为进一步证明本文算法的优势,选取两阶段 Faster-RCNN 算法、端到端 YOLOv3 算法和原始 Centernet 算法作为对比算法,三者均采用相同数据集进行训练,并在测试集中选择三张具有代表性的红外图像进行检测效果对比,如图 7 所示,从上至下依次为场景一、场景二、场景三,

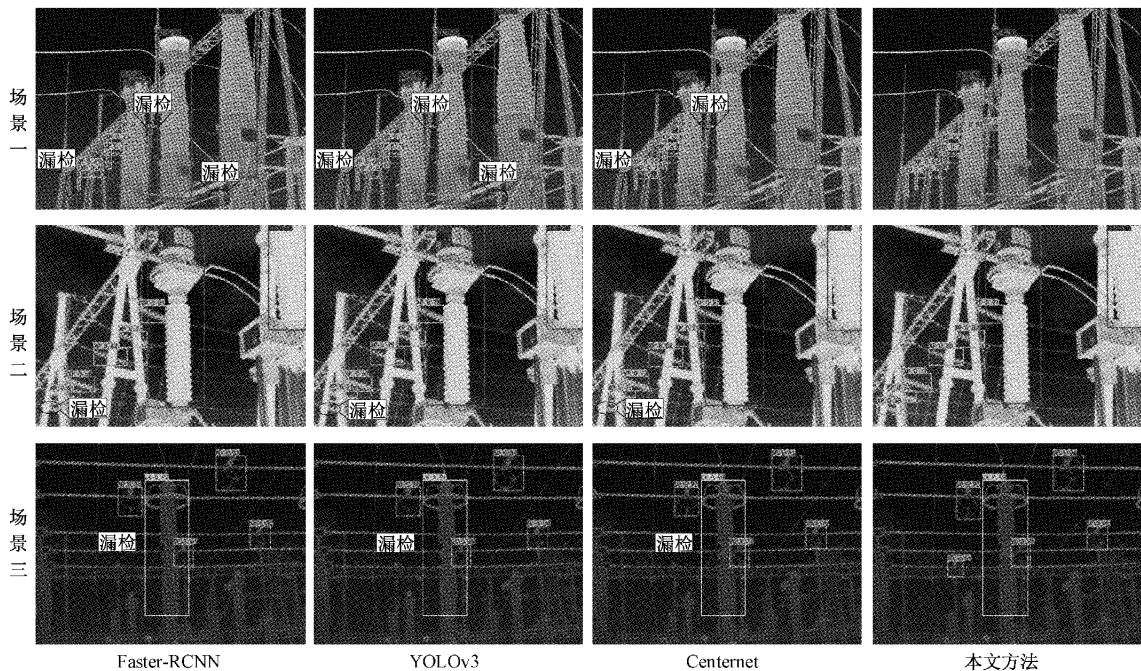


图 7 不同算法检测效果对比

在不同场景中采用不同算法的检测效果对比分析如下:

场景一: Faster-RCNN 与 YOLOv3 未能检测图像左下角绝缘子、中间遮挡绝缘子、右下角较小静触头, Centernet 未能检测左下角绝缘子和中间遮挡绝缘子, 而本文算法对该类目标均能有效检测, 表明本文在 Centernet 的基础上引入 FPN 结构后, 融合了更多小目标特征信息量, 对小目标检测更加精准。

场景二: 受背景的干扰, 3 种对比算法均未能检测左下角绝缘子, 而本文算法在主干网络中加入 SE 注意力机制后, 有效的将该目标权重提升, 使得网络能对其准确检测, 不受复杂天气环境所干扰。

场景三: 受大气环境及遮挡物干扰, 导致左下半部分的静触头特征并不明显, Faster-RCNN、YOLOv3、Centernet 均未能将其检测, 而本文算法加入 SE 注意力机制后, 有效的解决了该类目标漏检的情况。

表 3 为本文算法与 Faster-RCNN、YOLOv3、原始 Centernet 三种算法的检测精度与速度对比。

由表 3 可知, 本文算法的 mAP 值明显高于其他对比算法, 由于本文算法在 Centernet 的基础上增加网络复杂度, 检测速度稍慢于原始 Centernet, 但是仍快于 Faster-RCNN

从左至右依次为 Faster-RCNN、YOLOv3、Centernet、本文算法。其中场景一的图像左下角存在较小绝缘子, 中间存在遮挡绝缘子, 右下角存在较小静触头; 场景二受天气干扰严重, 并且图像左下角较小绝缘子部分遮挡; 场景三受大气干扰严重, 各电气设备颜色与环境颜色相近, 左下半部分静触头部分遮挡。

表 3 不同算法检测结果

算法	mAP%	FPS/(张/s)
Faster-RCNN	87.7	4
YOLOv3	83.3	35
Centernet	89.6	43
本文算法	92.7	38

与 YOLOv3。综上, 本文算法在电气设备红外场景中能兼顾检测精度与检测速度。

5 结 论

本文提出了一种基于改进 Centernet 的变电设备红外检测方法。通过引入 FPN 结构充分融合浅层的细节信息与深层的语义信息, 从而提升小目标的检测精度; 通过在主干网络 resnet50 中嵌入 SE 注意力机制以提升网络在复杂环境中对待检测目标的关注; 将中心点偏移损失与宽高损失替换为 CIOU 损失, 提升了网络的收敛速度与检测精度。

采用变电设备红外数据集对本文所提方法进行效果验证。实验结果表明, 本文所提方法在小目标检测和复杂环境检测中均具有优秀的检测效果, mAP 值明显优于现

有方法,达到 92.7%。

后续工作将针对电气设备热缺陷进行筛查与诊断,并对检测算法进行相应轻量化改进。

参考文献

- [1] 周可慧,廖志伟,陈琳韬,等. 基于双重背景分离及自适应网格的电压致热型设备红外图像状态分析[J]. 电力系统保护与控制,2019,47(24):123-130.
- [2] 徐小冰,袁婧,廖雁群,等. 基于 Faster RCNN 与 Mean-Shift 的电缆附件缺陷红外图像自动诊断方法[J]. 高电压技术,2020,46(9):3070-3080.
- [3] 苏海锋,赵岩,武泽君,等. 基于改进 RetinaNet 的电力设备红外目标精细化检测模型[J]. 红外技术,2021,43(11):1104-1111.
- [4] 张上,王恒涛,冉秀康. 基于 YOLOv5 的轻量化交通标志检测方法[J]. 电子测量技术,2022,45(8):129-135.
- [5] 范利,赵锐,谭孝元,等. 基于红外成像技术的零值绝缘子检测[J]. 高压电器,2018,54(2):97-102.
- [6] 李鑫,崔昊杨,许永鹏,等. 电力设备 IR 图像特征提取及故障诊断方法研究[J]. 激光与红外,2018,48(5):659-664.
- [7] 郝帅,马瑞泽,赵新生,等. 基于卷积块注意模型的 YOLOv3 输电线路故障检测方法[J]. 电网技术,2021,45(8):2979-2987.
- [8] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE, 2014: 580-587.
- [9] GIRSHICK R. Fast R-CNN [C]. Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE, 2015: 1440-1448.
- [10] 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.
- [11] 王好,陈秀新,袁和金. 基于改进 Faster RCNN 的变电站红外图像多目标识别[J]. 传感技术学报,2021,34(4):522-530.
- [12] ZHAO Z, ZHEN Z, ZHANG L, et al. Insulator detection method in inspection image based on improved faster R-CNN [J]. Energies, 2019, 12(7), 1204.
- [13] 夏浩宇,索双富,王洋,等. 基于 Keypoint RCNN 改进模型的物体抓取检测算法[J]. 仪器仪表学报,2021,42(4):236-246.
- [14] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multi-box detector[C]. Proceedings of the 14th European Conference. Netherlands: Springer, 2016: 21-37.
- [15] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL]. [2018-09-30]. <https://arxiv.org/abs/1804.02767>.
- [16] 崔江波,侯兴松. 基于注意力机制的 YOLOv4 输电线路故障检测算法[J]. 国外电子测量技术,2021,40(7):24-29.
- [17] 王旭红,李浩,樊绍胜,等. 基于改进 SSD 的电力设备红外图像异常自动检测方法[J]. 电工技术学报,2020,35(S1):302-310.
- [18] 郑含博,李金恒,刘洋,等. 基于改进 YOLOv3 的电力设备红外目标检测模型[J]. 电工技术学报,2021,36(7):1389-1398.
- [19] 伏轩仪,张銮景,梁文科,等. 锚点机制在目标检测领域的发展综述[J]. 计算机科学与探索,2022,16(4):791-805.
- [20] ZHOU X Y, WANG D Q, KRAHENBUHL P. Objects as points [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Long Beach, 2019: 7263-7271.
- [21] 万伟彤,李长峰,朱华波,等. 轻量化 CenterNet 网络的二维条码定位算法[J/OL]. 电子测量与仪器学报:1-9 [2022-06-21]. <http://kns.cnki.net/kcms/detail/11.2488.tn.20220526.1954.042.html>.
- [22] 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, 2017: 2117-2125.
- [23] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [24] 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, 2020, 34(7): 12993-13000.

作者简介

黄悦华,博士生导师,教授,主要研究方向为新能源微电网、电网运行、电机及其控制、检测技术与自动化装置等。
E-mail:hyh@ctgu.edu.cn

杨楚睿(通信作者),硕士研究生,主要研究方向为电气设备在线监测和图像处理。
E-mail:838527172@qq.com。