

基于多尺度特征图的变电站设备缺陷递进检测

张可^{1,2}, 黄文礼^{1,2}, 侯仕杰^{1,2†}, 代北敏³, 陈思宝³

(1. 安徽南瑞继远电网技术有限公司, 安徽 合肥 230088; 2. 国网电力科学研究院有限公司(南瑞集团有限公司), 江苏 南京 211000; 3. 安徽大学计算机科学与技术学院, 安徽 合肥 230601)

摘要:针对现有变电站设备缺陷检测中目标尺度差异大、背景复杂等问题,提出了一种基于多尺度特征图的变电站设备缺陷递进检测方法。首先通过深度残差网络提取变电站设备缺陷图像的原始特征图,利用多尺度特征聚合方法构建多尺度特征图;其次对缺陷目标进行两阶段的递进检测,第一阶段对缺陷目标进行前景和背景的二分类与坐标回归,第二阶段对前景目标的具体缺陷类别进行判断和进一步坐标回归。本文方法同时将第一阶段的类别结果作为语义信息对特征图添加空间注意力机制,能够对不同尺度的特征图的特征值进行自适应加权,增强前景区域的特征响应,同时抑制背景区域,从而增强了缺陷检测方法的鲁棒性和泛化能力。在真实变电站设备缺陷图像数据集上的实验结果表明所提方法具有良好的检测性能。

关键词:缺陷检测;目标检测;递进检测;变电站设备;多尺度特征图

中图分类号:

文献标识码:A

Substation Equipment Defect Progressive Detection Based on Multi-scale Feature Map

ZHANG Ke^{1,2}, HUANG Wenli^{1,2}, HOU Shijie^{1,2†}, DAI Beimin³, CHEN Sibao³

(1. Anhui NARI Jiyuan Power Grid Technology Co., Ltd., Hefei, Anhui 230088, China;
2. State Grid Electric Power Research Institute(NARI Group Corporation), Nanjing, Jiangsu 211000, China;
3. School of CSE, Anhui University, Hefei, Anhui 230601, China)

Abstract: Aiming at the problem of poor robustness of existing detection methods when object scale is variant and background is complex, this paper proposes a progressive detection method for substation equipment defects based on multi-scale feature maps. Firstly, original feature maps of substation equipment defect images are extracted by deep residual network, and multi-scale feature maps of substation equipment images are constructed by multi-scale feature aggregation method. Secondly, the detection process goes through two stages. The first stage is the classification of foreground and background of defect objects and coordinate regression. The second stage determines the specific category of foreground objects and further performs coordinate regression. The first stage category results are used as semantic information to add a spatial attention mechanism on the feature map, which can adaptively weight the feature values of feature maps of different scales to enhance the feature response of the foreground area, while suppressing the background area, thereby enhancing the robustness and generalization ability of the proposed method. Experimental results on real substation equipment defect image data set show that the proposed method has better detection performance.

Key words: defect detection; object detection; progressive detection; substation equipment; multi-scale feature map

变电站日常安全检查直接关系到电网的安全运行,随着智慧电力不断建设^[1],基于计算机视觉的变电站设备缺陷自动检测的研究正逐步深入^[2-4]。

针对变电站设备的缺陷检测不同于常规的目标检测问题,尤其是对变电站设备的非正常状态、异物、破损等缺陷的检测。首先,图片拍摄角度和距离在不同的检测点有较大差异,导致图片中的缺陷大小有明显差异,且缺陷本身也有较大差异;其次,变电站的背景信息相对于自然场景图片较为复杂,充斥着各种电力设施;最后,出于电力安全因素,往往要求在保证缺陷检测准确率的基础上尽可能少地出现缺陷漏检的情况。这些都给变电站设备缺陷自动检测带来了较大困难。

目前的变电站设备缺陷检测方法主要有传统方法和基于深度神经网络方法两大类。传统方法主要利用图像处理技术^[5-7],设计各种特征算子以提取特征(如尺度不变特征变换^[8]和加速稳健特征^[9]等),以及设计各种分类模型^[10-15]。而深度神经网络方法则并不显性地设计特征算子。LF-Net^[16]通过孪生网络(Siamese Network)^[17]来训练整个神经网络。Wang等^[18]联合应用孪生网络^[19]和Deepcompare^[20]学习图像间非线性距离矩阵,实现图像间的特征匹配。樊玮等^[21]使用VGG16作为网络的基本模型,采用孪生网络结构,分别从参考图像和查询图像中提取不同网络层的深度特征拼接后送入一个编码层,检测出变化区域。更多的方法^[22]考虑到更深更复杂的深度模型结构以及更好地设计损失函数。LIFT^[23]尝试通过可微运算方式将检测器、方向估计器和描述器三个部分组合起来,训练一个端到端的网络。Super-Point^[24]训练一个由共享的特征编码器和两个解码器组成全卷积网络,分别用于特征检测和描述,最后联合两个可学习的编码器实现图像目标检测。在这些方法中,传统方法需要人工提取特征,泛化

能力弱,正逐渐被深度学习方法替代。而目前深度学习方法在应用于变电站设备缺陷检测时,受变电站复杂背景以及缺陷目标尺度差异的影响较大,难以取得理想的效果。

为了提升变电站设备缺陷自动检测的性能,本文主要工作如下:首先,构建多尺度特征图,随着网络层数的递增,高层特征图主要表达的是高层语义特征。底层特征图分辨率更高,具有更多的细节信息,小目标在其中的响应更加明显。高层特征图分辨率较小,具有更大的感受野,大目标的响应更加明显。通过提取融合不同尺度上的特征图,能充分描述图像底层的视觉特征和高层的语义特征,同时由于高层图中背景区域的特征响应较小,所以在融合过程中能够在一定程度上抑制底层特征图中冗余的背景区域的特征响应,克服检测噪声。这对复杂的变电站设备缺陷存在的不同尺度问题较为有效。其次,在多尺度特征图基础上进行由粗到细的递进检测,同时添加空间注意力机制,降低模型训练与检测难度,提升模型鲁棒性与泛化能力。最后,本文设计了对应的局部和全局损失函数,其中局部损失函数为第一阶段和第二阶段各自的损失函数,全局损失函数为两者的加权和,通过全局损失函数实现对网络的端到端训练,训练效率高且模型各部分参数更加协调。

1 多尺度特征图递进检测网络

本文提出的用于变电站设备缺陷视觉检测的网络框架借鉴了ResNet^[25]的残差学习思想,重新构建了多尺度特征提取网络,通过变电站设备缺陷图像^[26]的多尺度特征提取,将底层小尺度特征和高层大尺度特征进行特征融合,提高网络模型的表达能力。所提多尺度特征图递进检测网络结构如图1所示。

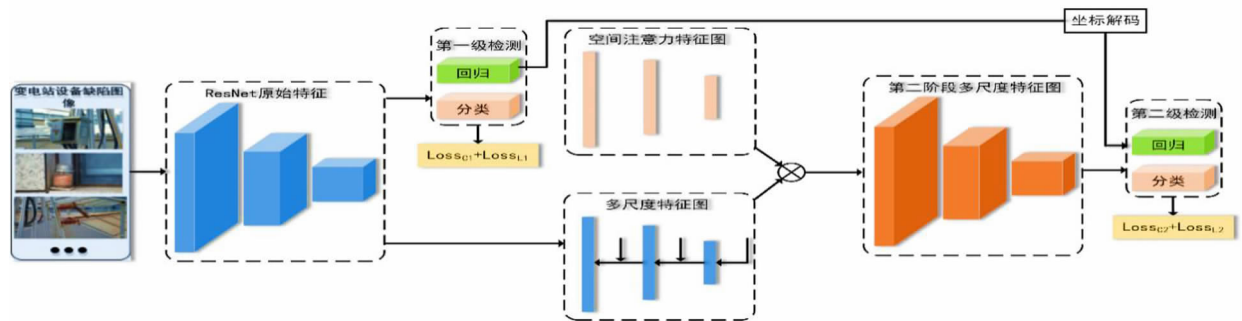


图1 多尺度特征图递进检测网络

该多尺度特征图递进检测网络首先基于 ResNet 网络提取原始特征图,用于第一阶段的检测,使用卷积的方式获取二分类的特征分类结果与初始坐标回归结果。其次对 ResNet 原始特征图进行重新构建,通过反向连接构建新的多尺度特征图,增强特征图的鲁棒性,并且添加空间注意力机制,提升模型的泛化能力。最后,在新的多尺度特征图上进行第二阶段的检测,并复用第一阶段的检测结果,实现递进式的精确缺陷目标分类与定位。

1.1 深度特征提取与多尺度特征图构建

本文采取深度残差网络 ResNet 来提取深度特征。其主要思想是在网络中增加直连通道,并保留传统网络层一定比例的输出,允许原始输入特征直接传到后面的层中。ResNet 中的残差单元可以表示为:

$$y_l = h(x_l) + F(x_l, W_l), x_{l+1} = f(y_l) \quad (1)$$

式中, x_l 和 x_{l+1} 分别表示第 l 个残差单元的输入和输出, F 是残差函数, $h(x_l)$ 表示学习到的残差特征, W_l 表示卷积网络每层特征权值,而 $h(x_l) = x_l$ 表示恒等映射, $f(\cdot)$ 是 ReLU 激活函数。浅层 l 到深层 L 的学习特征为:

$$x_L = x_l + \sum_{i=l}^L F(x_i, W_i) \quad (2)$$

本文所提的多尺度特征图网络结构如图 2 所示。对于 ResNet,使用 Conv1, Conv2_x, Conv3_x, Conv4_x 和 Conv5_x 的每个阶段最后残差块的特征激活输出 x_{l+1} , 对应的特征图表示为 $\{C_1, C_2, C_3, C_4, C_5\}$ 。本文的方法在构建特征图的过程中同时保留低层次和高层次特征,在不同尺度上映射对应的特征响应图。首先,对卷积层 C 进行 3×3 卷积得到特征图,将顶层特征图进行上采样与上层特征图相加得到多尺度特征图 Q,对每个尺度图上进行 1×1 卷积操作,进行特征图通道压缩,使得每个尺度的特征图通道保持一致,并减少参数量,生成最终的多尺度空间上的特征图 P。本文方法与文献[30]FPN 的区别在于,先使用 3×3 的卷积层对特征图进行通道数修正,经过上采样与特征图相加之后,再进行 1×1 卷积,最后获得多尺度特征图,并融合空间注意力机制,使得多尺度特征包含的信息更加丰富。

1.2 递进目标检测

第一阶段目标分类与回归在原始 ResNet 的输出特征图 $\{C_1, C_2, C_3, C_4, C_5\}$ 上进行,使用共享的 3×3 分类卷积层与回归卷积层 $\{CN1, LN1\}$, 获得每个特征图上对应的分类与回归结果。其中

CN1 是输出通道数为 2 的卷积层,用于预测目标属于前景和背景的概率, LN1 是输出通道数为 4 的卷积层,用于预测目标的坐标偏移量。




图 2 多尺度特征图

对分类结果进行 softmax 运算,此时 2 个通道分别对应物体属于前景和背景的概率。之后单独取出前景概率分布图 $\{P_1, P_2, P_3, P_4, P_5\}$ 。同时基于图 2 中的操作和原始特征图 $\{C_1, C_2, C_3, C_4, C_5\}$ 进行深度多尺度特征图构建,获得 $\{D_1, D_2, D_3, D_4, D_5\}$ 。将对应尺度的特征响应图与概率分布图进行点乘操作,获得用于第二阶段的多尺度特征响应图 $\{E_1, E_2, E_3, E_4, E_5\}$ 。以 E_1 为例,则:

$$P_1 = \text{soft max} (CN1(C_1)) \quad (3)$$

$$E_1 = \sum_i P_i \cdot D_i \quad (4)$$

这里 \cdot 表示点乘,表示特征图 D_1 的第 i 个通道。

与第一阶段的检测过程类似,第二阶段检测基于特征响应图 $\{E_1, E_2, E_3, E_4, E_5\}$, 通过共享的 3×3 卷积层 $\{CN2, LN2\}$ 进行分类与检测。第二阶段的检测结果需要建立在第一阶段检测结果的基础上。具体来说,对于分类过程,在第一阶段中被判为背景类的目标将不再参与第二阶段的分类损失计算,而被判为前景类的物体将进行具体的多类别分类。对于检测过程,初始坐标修正为第一阶段坐标回归进行解码后的结果,以此重新计算与真实坐标之间的回归损失。

通过对变电站设备缺陷图像的第一阶段检测后,可以获得原始不同尺度特征图所对应的分类结果响应图,分类结果特征图是一个双通道的特征图,其大小与被卷积的特征响应图相同,反映了特征响应图中不同区域属于前景或背景的概率。通过 softmax 运算进行得分归一化,可以获得特征图每个特征点属于前景的概率 P 。为了更好地利用第一阶段检测中的分类信息,本文采用空间注意力的思想,将 P 与构建出的深度多尺度特征响应图 D 进行通道点乘操作,增强 D 中正样本所属区域的

特征响应,同时抑制负样本所属区域的特征响应。

2 损失函数设计

两阶段的检测网络以递进和全卷积的方式实现目标分类与回归,以第二阶段的结果为最终结果。检测网络将一张待检测图像作为网络输入,通过 ResNet 网络获得第一阶段的特征图,通过第一阶段检测网络进行第一阶段的检测。之后通过空间注意力机制和多尺度特征图构建第二阶段的特征图,并对第一阶段的检测结果进行解码,在此基础上进行第二阶段的检测。因此,本文同时使用第一阶段的检测损失函数 $Loss_{s1}$ 和第二阶段的检测损失函数 $Loss_{s2}$ 。

第一阶段损失函数由前景和背景的二分类损失 $loss_{c1}$ 和坐标回归损失 $loss_{l1}$ 构成:

$$Loss_{s1} = loss_{c1} + loss_{l1} \quad (5)$$

式中, $loss_{c1}$ 为二分类交叉熵损失函数:

$$loss_{c1} = \frac{1}{N} \sum_i y_i \log(y_i') + (1 - y_i) \log(1 - y_i') \quad (6)$$

式中, i 表示第 i 个待检测候选区域, y_i 为真实类别标签, y_i' 为预测类别标签, N_1 为参与第一阶段检测的候选区域数目。 $loss_{l1}$ 为 smoothL1 损失函数,本文使用了四点参数化计算的方式,分别回归中心点的相对偏移与长宽的自然对数值:

$$\begin{aligned} t_x &= (x - x_a) / w_a, t_y = (y - y_a) / h_a \\ t_w &= \log(w / w_a), t_h = \log(h / h_a) \\ t_x^* &= (x^* - x_a) / w_a, t_y^* = (y^* - y_a) / h_a \\ t_w^* &= \log(w^* / w_a), t_h^* = \log(h^* / h_a) \end{aligned} \quad (7)$$

式中, x, x_a, x^* 分别表示预测信息、候选区域信息和真实坐标信息中的中心点横坐标; y, y_a, y^* 分别表示预测信息、候选区域信息和真实坐标信息中的中心点纵坐标; w, w_a, w^* 分别表示预测信息、候选区域信息和真实坐标信息中的宽; h, h_a, h^* 分别表示预测信息、候选区域信息和真实坐标信息中的高; t 表示预测横坐标相对于候选框横坐标的偏移距离, t_x 和 t_y 分别代表预测横坐标和纵坐标, t^* 表示真实框相对于候选框的偏移距离, t_x^* 和 t_y^* 分别代表真实横坐标和纵坐标。然后定义坐标回归损失 $loss_{l1}$ 如下:

$$loss_{l1} = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases} \quad (8)$$

式中, x 表示真实平移缩放参数与预测平移缩放参数的差值,例如 $t_x - t_x^*$ 。

第二阶段的检测损失函数 $Loss_{s2}$ 同样由两部分构成,分别为多分类的交叉熵损失 $loss_{c2}$ 和坐标

回归损失 $loss_{l2}$:

$$Loss_{s2} = loss_{c2} + loss_{l2} \quad (9)$$

所使用的计算方法与第一阶段损失函数基本类似,因此不再赘述。不同的是,在计算多分类损失时,在第一阶段中被判定为背景类的目标不再参与此时的损失计算,能够有效缓解正负样本之间的不平衡问题,降低训练难度。在计算坐标回归损失时,基于第一阶段的坐标回归结果和式(7)进行解码操作,获得此时的目标坐标,在此基础上进行新一轮的坐标回归,从而获得更精确的结果。

最终网络框架训练时所使用的端到端损失 $Loss_{total}$ 为两个阶段损失的加权和:

$$Loss_{total} = \lambda_1 Loss_{s1} + \lambda_2 Loss_{s2} \quad (10)$$

其中 λ_1, λ_2 均为大于 0 且小于等于 1 的调和系数,本实验中均设为 1。

3 完整检测框架

本文所提的基于多尺度特征图的变电站设备缺陷递进检测的完整框架主要包括三个部分:一是图像深度特征提取;二是多尺度特征图构建;三是缺陷目标递进检测分类。完整的检测框架如图 3 所示。

本文采用的多级递进检测包含两个阶段:第一阶段检测对物体进行二分类判断(前景或背景);第二阶段检测仅对第一级检测中判定为前景的目标进行具体的多分类判定。本文所提出的两阶段检测与 Faster-RCNN 不同,其中不包含对每个样本的单独特征提取与池化操作,而是直接通过卷积层获得完整的特征图,从而加快检测速度。两阶段检测都包含坐标回归过程,且第二阶段回归建立在第一阶段回归的基础上。通过第一阶段检测能够过滤掉候选区域中大部分简单背景样本,从而有效平衡后续检测中的正负样本数量,降低训练难度。

第一阶段检测使用 ResNet 所抽取的不同分辨率特征图作为输入,对候选目标区域进行二分类判别和坐标回归。在第二阶段检测中,考虑到变电站内设备缺陷图片的多样性与拍摄位置的不同,相同或者不同的缺陷目标在图片中会呈现多种尺度。为了解决此问题,本文利用 ResNet 所抽取到的原始不同分辨率的特征图,通过特征聚合方法构建变电站设备缺陷图像多尺度特征图,实现有效的多尺度目标检测。通过第一阶段检测的输出结果,可以获得每个候选目标区域的分类结果 C_1 以及前景目标的回归坐标 L_1 。对 C_1 进行分析,可以获得每个候选区域属于前景或者背景。对于背景区域,不再对其进行判别和坐标回归。对于前景区域,在当前

特征图上进行第二次类别检测 C_2 与坐标回归 L_2 。相比于第一阶段检测,第二阶段检测同样也是使用卷积方式实现,不同的是此次分类是针对前景类别的多分类,用于具体判断前景区域属于哪一种缺陷类别。坐标回归过程建立在第一阶段检测的基础上,先通过坐标解码获得第一次检测中的坐标结果。在此基础上,进行二次坐标回归,提升回归精度。

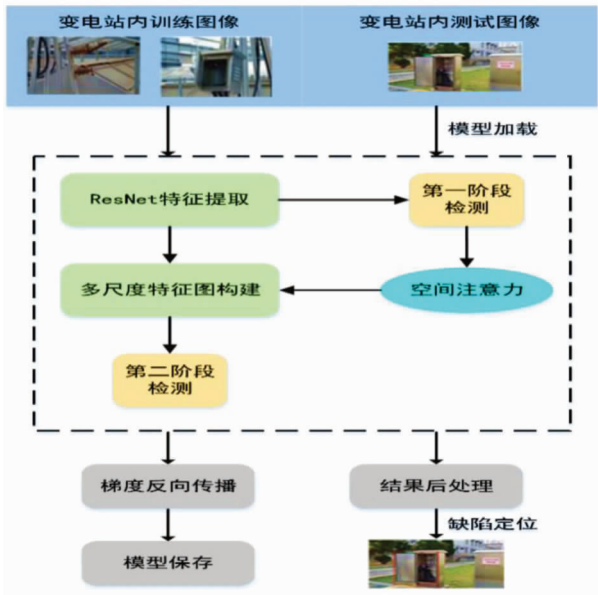


图3 基于多尺度特征图变电站设备缺陷递进检测框架图

4 实验结果及分析

4.1 数据集

本文针对变电站设备缺陷检测任务的需求,采集了真实变电站场景的正常设备图像与缺陷设备图像数据集并进行标注,包含绝缘子、表针、闸刀等6类设备,每类采集了1000张图像。图像采集背景为不同时间点同一位置。拍摄角度存在小角度偏移,图像数据也包含光照变化、遮挡、形变等情况。图4显示了真实场景下变电站设备6类正常图像示例。图5显示了真实场景下变电站设备6类缺陷图像示例。

为了达到较好的测试效果,对数据集进行了镜像操作,扩充了数据集,总计12000个图像样本。本文采用4/5的图像数据作为训练集,剩下1/5的数据作为测试集。

4.2 网络训练分析

本文的实验环境为搭载Ubuntu系统与4张NVIDIA 1080Ti显卡的服务器,网络backbone为ResNet101,使用Adam优化策略进行参数更新。图6显示了网络第二阶段绝缘子图像的特征响应

图示例。由图6所示结果可见,网络对于绝缘子附近区域的响应度更高,从而印证网络提取特征的有效性,构建的多尺度特征响应图使得绝缘子特征更加明显,并能一定程度上抑制杂草等背景的干扰。

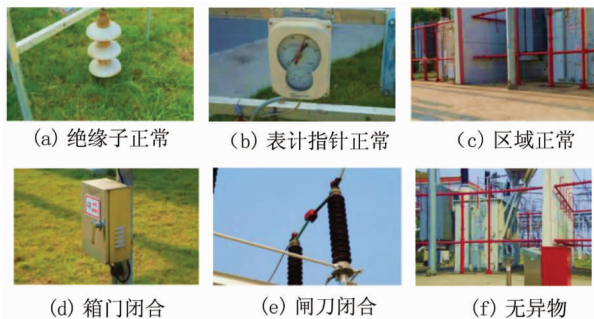




图4 真实场景下变电站设备6类正常图像示例



图5 真实场景下变电站设备6类缺陷图像示例



(a) 绝缘子特征激活映射图



(b) 绝缘子特征图

图6 多尺度特征响应图示例

图7显示了整个训练过程中的损失变化曲线图,损失呈不断下降的趋势,在第50个轮次后基本趋于稳定,模型收敛。最终在变电站数据集上的mAP为72.9%。

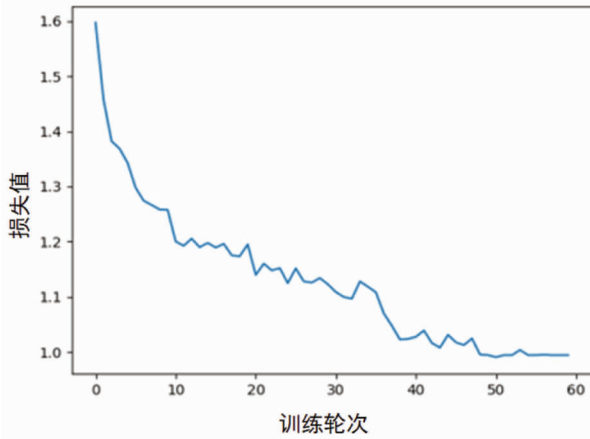


图 7 训练损失变化曲线图

4.3 定量结果分析

定量实验结果分析中,本文采用的评价指标是均值平均精度(mean Average Precision, mAP)。mAP 是目标检测中衡量识别精度的指标,C 个类别物体检测中,每一个类别都可以根据召回率(Recall)和查准率(Precision)绘制一条 Precision-Recall 曲线(PR 曲线),该曲线下的面积即为 AP。mAP 是多个类别 AP 的平均值。表 1 展示了本文算法对比单尺度特征进行缺陷检测的结果。单尺度特征图直接使用 ResNet 网络的 Conv5 层输出。考虑时效性,本文主要对比单尺度 ResNet34、ResNet50 和 ResNet101。从表 1 可以看出,基于残差网络多尺度融合的特征图具有更高的准确性。

表 1 单尺度和多尺度 mAP 对比

网络	mAP
ResNet34	70.6%
ResNet50	71.1%
ResNet101	71.8%
多尺度融合	72.9%

为了验证文中所提出的空间注意力机制和两阶段递进检测的有效性,本文分别进行了消融实验。实验结果如表 2 和表 3 所示。

从表 2 和表 3 可以看出,空间注意力机制与两阶段递进检测分别对检测结果有不同程度的提升。其原因在于空间注意力机制能增强前景目标区域的特征,并且抑制背景区域的噪声影响。在使用 ResNet50 和 ResNet101 作为特征提取网络时,使用空间注意力机制时 mAP 分别提升了 0.3% 和 1.2%。而两阶段递进检测的作用在于通过第一阶段的二分类检测,有效地过滤掉大量的简单背景样本,从而平衡参与第二阶段分类损失计算的正负样

本数量,避免因简单样本过多导致的梯度累积,降低训练难度,从而达到更好的训练效果。

表 2 有无空间注意力机制 mAP 对比

网络	空间注意力机制	mAP
ResNet50	无	71.1%
ResNet50	有	71.4%
ResNet101	无	71.7%
ResNet101	有	72.9%

表 3 有无两阶段递进检测 mAP 对比

网络	两阶段递进检测	mAP
ResNet50	无	71.2%
ResNet50	有	71.4%
ResNet101	无	71.6%
ResNet101	有	72.9%

本文针对不同单阶段检测方法和双阶段检测方法进行对比实验,并记录其在不同类别的缺陷目标上的检测精度。从表 4 中可以看出,在所建立的训练集上本文的算法相比 SSD 和 YOLO 的 mAP 精度分别提高了 7% 和 6%,表明了本方法比单阶段检测方法更加有效。同时本文较双阶段检测方法 Faster-RCNN(FRCNN)提高了 3 个百分点,说明在复杂数据集上结合了多尺度学习思想的深度神经网络性能更优异,证明了本文设计的变电站设备缺陷递进检测方法的有效性。

表 4 各种检测算法在变电站数据集上的 AP 值

类别	SSD ^[27]	YOLO ^[28]	FRCNN ^[29]	本文算法
绝缘子	0.74	0.72	0.77	0.82
表计	0.57	0.60	0.65	0.64
工装	0.75	0.78	0.83	0.87
箱门闭合	0.68	0.72	0.68	0.71
闸刀闭合	0.59	0.61	0.64	0.66
异物	0.63	0.62	0.66	0.69
mAP	0.66	0.67	0.70	0.73

最后,为了验证文中所提出方法的先进性与泛化能力,将本文算法与一些常用目标检测方法在公开的文献[27]VOC2007 数据集上和变电站数据集上分别进行了检测精度的比较,结果如表 5 所示。虽然受限于模型参数数量和网络复杂度,在公开数据集上的本文方法的效果未取得最好,但是在特定的变电站数据集中,本文所提出的方法取得了最好的检

测精度, mAP 为 72.9%, 可以看出文中所提方法的有效性。

表 5 与其他常用目标检测算法的 mAP 对比

方法	不同数据集上的 mAP	
	VOC2007	变电站数据集
SSD ^[27]	77.1%	66.0%
YOLO ^[28]	78.6%	67.3%
Faster-RCNN ^[29]	73.2%	70.1%
FPN ^[30]	75.6%	71.0%
Mask-RCNN ^[31]	78.2%	70.9%
R-FCN ^[32]	80.5%	71.4%
Cascade-RCNN ^[33]	80.7%	71.3%
ADFPNet300 ^[34]	81.1%	71.7%
本文算法	80.5%	72.9%

4.4 定性结果分析

为验证本文所提算法在应对变电站内复杂的外部环境下的设备缺陷检测效果, 图 8 显示了一些检测结果示例。可以看出所提方法在复杂背景及存在角度偏移的场景中能够准确地检测出变电站设备缺陷所在位置。当同一设备处于不同状态下时, 能够屏蔽树木、草地等噪声影响。对同一场景中光照及人员走动造成的目标尺度变化等情况同样能准确地检测出缺陷位置。

图 9 展示了本文算法与其他算法在变电站数据集上的部分检测效果对比示例。在对变电站内绝缘子缺陷检测时, Faster-RCNN 检测到了部分缺陷, SSD 和 YOLO 方法受背景草地干扰给出错

误的检测结果, 表明这些方法容易受到复杂环境的干扰, 鲁棒性较差。对比表计指针变化和变电站内异物的实验结果可以看到, 对于相机拍摄的小角度偏移所带来的影响, 本文算法相比于 Faster-RCNN 更精确, 且 SSD 和 YOLO 受背景细微变化和角度影响检测出错误区域。不难发现 SSD 和 YOLO 检测到正确目标的同时也受树木、阴影等干扰出现误检。通过对比, 本文算法由于充分利用了深度网络多尺度特征, 并设计自适应的空间注意力机制与递进检测, 对噪声及小角度偏移不敏感, 鲁棒性好, 误检率和漏检率更低。

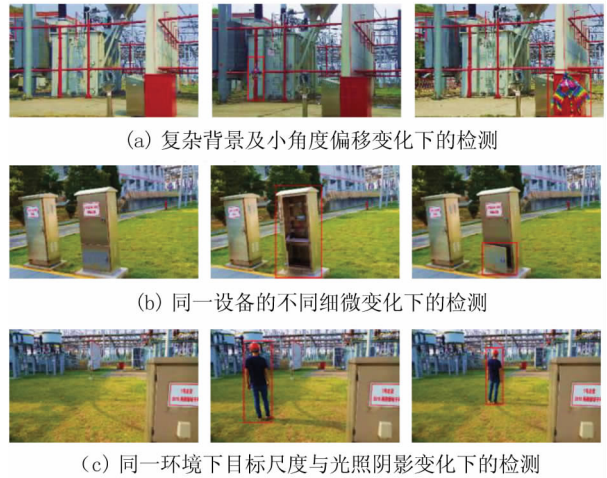


图 8 复杂情况下缺陷检测结果示例

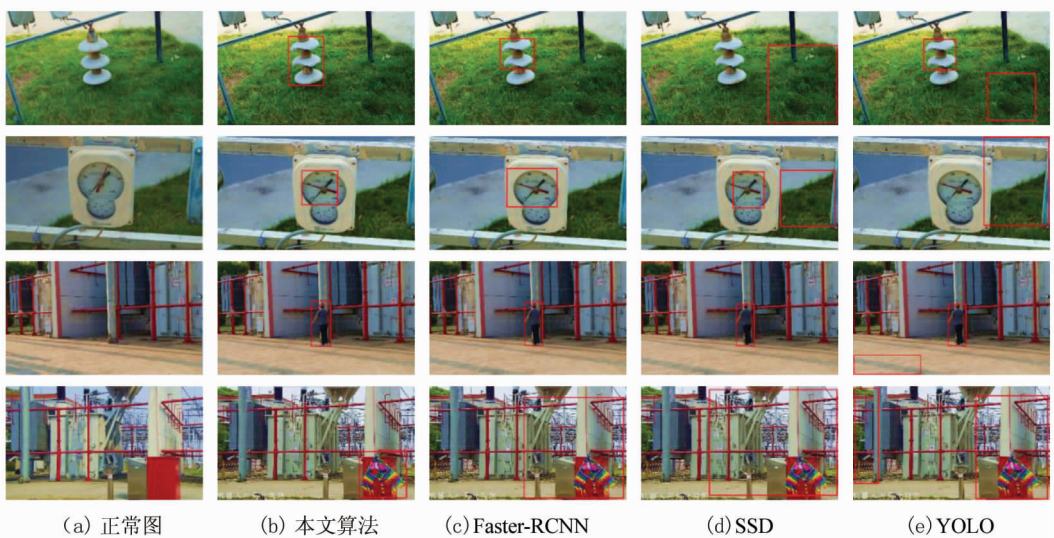


图 9 不同缺陷检测方法的效果示例

5 结论

提出了一种基于多尺度特征图的变电站设备

缺陷递进检测方法。首先通过深度残差网络的卷积层提取变电站设备缺陷图像的原始特征图, 利用多尺度特征聚合方法构建变电站图像多尺度特征图。然后检测过程经过两个阶段, 第一阶段对物体

进行前景和背景的二分类与坐标回归,第二阶段判断前景物体的具体类别并进一步进行坐标回归。同时将第一阶段的类别结果作为语义信息对特征图添加空间注意力机制,增强了图像缺陷检测方法的鲁棒性和泛化能力。在真实变电站设备缺陷数据集上的实验结果表明,所提方法优于多数经典目标检测方法,提高了变电站设备缺陷自动检测的准确率。

本文方法不足之处在于未能更充分利用第一阶段的坐标回归结果,仅将其作为第二阶段坐标回归的初始值。未来可以参照可变性卷积的思想,利用第一阶段的坐标对后续卷积过程中的采样区域直接进行调整,通过获得更加准确的感受野来提升检测性能。

参考文献

- [1] 郑玉平,王丹,万灿,等.面向新型城镇的能源互联网关键技术及应用[J].电力系统自动化,2019,43(14):2-16.
- [2] 熊小萍,许爽,蒙登越,等.基于Faster R-CNN的输电线路缺陷识别模型研究[J].自动化与仪器仪表,2020(3):1-6.
- [3] 刘召,张黎明,耿美晓,等.基于改进的Faster R-CNN高压线缆目标检测方法[J].智能系统学报,2019,14(4):627-634.
- [4] 赵小鱼,徐正飞,付渊.一种适用于智能变电站巡检机器人的异物检测算法研究[J].现代电子技术,2015,38(10):124-127.
- [5] RUBLEE E, RABAUD V, KONOLIGE K, et al. ORB: an efficient alternative to SIFT or SURF[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2011: 2564-2571.
- [6] 闻新,谢天夏,闫钧华,等.改进结构相似度的红外两波段图像目标配准[J].仪器仪表学报,2017,38(12):236-244.
- [7] 贾迪,杨宁华,孙劲光.像对匹配的模板选择与匹配[J].中国图象图形学报,2017,11:1512-1520.
- [8] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [9] BAY H, ESS A, TUYTELAARS T, et al. Speeded-up robust features (SURF)[J]. Computer Vision & Image Understanding, 2008, 110(3): 346-359.
- [10] 楚瀛,李帅奇.基于联合特征的变电站设备图像识别[J].电力科学与技术学报. 2018, 33(1): 102-107.
- [11] 李大湘,吴倩,李娜.基于SIFT与PMK的鞋印图像比对算法[J].现代计算机,2016(4):64-67.
- [12] 曲长文,李智,周强,等.基于CCA差异图融合的SAR图像变化检测算法[J].火力与指挥控制,2018,43(12):1-4.
- [13] 刘晓伟,孟岩,龚浩,等.基于多特征融合的SAR图像输电走廊变化检测[J].电力科学与技术学报,2012(4):59-65.
- [14] 金立军,胡娟,闫书佳.基于图像的高压输电线路间隔棒故障诊断方法[J].高电压技术,2013,39(5):1040-1045.
- [15] 崔巨勇,曹云东,王文杰.基于分水岭与Krawtchou不变矩相结合的改进方法在变电站巡检图像处理中的应用[J].中国电机工程学报,2015,35(6):1329-1335.
- [16] ONO Y, TRULLS E, FUA P, et al. LF-Net: learning local features from images[C]//Neural Information Processing Systems, 2018: 6237-6247.
- [17] XUFENG H, THOMAS L, YANGQING J, et al. Matchnet: unifying feature and metric learning for patch-based matching[C]// IEEE Conference on Computer Vision & Pattern Recognition, 2015: 3279-3286.
- [18] WANG L, QIAO Y, TANG X. Action recognition with trajectory-pooled deep-convolutional descriptors[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2015: 4305-4314.
- [19] WANG J, CHEN K, YANG S, et al. Region proposal by guided anchoring[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 2965-2974.
- [20] SERGEY Z, NIKOS K. Learning to compare image patches via convolutional neural networks[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2015: 4353-4361.
- [21] 樊玮,周末,黄睿.多尺度深度特征融合的变化检测[J].中国图象图形学报,2020,25(4):669-678.
- [22] BALNTAS V, RIBA E, PONS D, et al. Learning local feature descriptors with triplets and shallow convolutional neural networks[C]// British Machine Vision Conference, 2016: 119.1-119.11.
- [23] YI K M, TRULLS E, LEPETIT V, et al. LIFT: learned invariant feature transform[C]//European Conference on Computer Vision, 2016: 1-15.
- [24] DETONE D, MALISIEWICZ T, RABINOVICH A. SuperPoint: self-supervised interest point detection and description[C]//2018 IEEE Conference on Computer Vision and Pattern Recognition. Workshops, 2018: 337-349.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [26] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]// IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [27] LIU W, ANGELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//European Conference on Computer Vision, 2016: 21-37.
- [28] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[J]// IEEE Conference on Computer Vision and Pattern Recognition, 2017:6517-6525.
- [29] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]//IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6):1137-1149.
- [30] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936-944.
- [31] HE K, GKIOXARI G, PIOTR DOLLAR, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 386-397.
- [32] DAI J, LI Y, HE K, et al. R-FCN: object detection via region-based fully convolutional networks[C]// NIPS, 2016: 379-387.
- [33] Z. CAI and N. VASCONCELOS, Cascade R-CNN: delving into high quality object detection[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 6154-6162.
- [34] PAN H, CHEN G, JIANG J. Adaptively dense feature pyramid network for object detection[J]. IEEE Access, 2019, 7: 81132-81144.