

DOI: 10.13382/j.jemi.B2104058

基于改进 Cascade R-CNN 的输电线路多目标检测*

李 鑫¹ 刘帅男¹ 杨 桢¹ 王珂珂²

(1. 辽宁工程技术大学 电气与控制工程学院 葫芦岛 125105; 2. 南京电子技术研究所 南京 210039)

摘 要:针对无人机巡检图像中小目标难以检测、障碍物遮挡目标、正负样本不平衡等问题,提出基于改进 Cascade R-CNN 的输电线路多目标检测方法。改进了 Cascade R-CNN 的特征提取网络,基于 ResNet101 基础网络结构,设计 6 层新型特征金字塔网络(FPN)与之融合,提高了对小目标、重叠目标的检测能力;引入了高斯形式的软非极大值抑制(Soft-NMS)方法,降低了受遮挡影响的目标的漏检率;利用 Focal 损失改进损失函数,缓解了正负样本不平衡对检测精度的影响。训练过程中,基于添加噪声、亮度变换、尺度放缩等数据增强方法扩充数据集,提升了训练模型的泛化性能。实验结果表明,改进的模型在复杂背景下能够对 3 种瓷质绝缘子、瓷质绝缘子缺陷、相间棒、防震锤以及鸟窝同时检测,平均精度均值(mAP)达到 94.1%,为输电线路的智能巡检提供了一种新思路。

关键词: 输电线路多目标检测; Cascade R-CNN; 深度学习; 特征融合

中图分类号: TM75; TN06 **文献标识码:** A **国家标准学科分类代码:** 470.40

Multi-target detection of transmission lines based on improved cascade R-CNN

Li Xin¹ Liu Shuainan¹ Yang Zhen¹ Wang Keke²

(1. Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125100, China;

2. Nanjing Institute of Electronic Technology, Nanjing 210039, China)

Abstract: Aiming at the problems of difficulty in detecting small targets in UAV inspection images, obstacles blocking targets and imbalance between positive and negative samples, a multi-target detection method based on improved Cascade R-CNN was proposed for transmission lines. The feature extraction network of the Cascade R-CNN was improved. Based on the basic network structure of ResNet101, a new 6-layer feature pyramid network structure was designed to achieve feature fusion, improving the detection ability of small targets and overlapping targets. The Gaussian Soft-NMS method was introduced to reduce the missed detection rate of the target with occlusion. The Focal loss was used to improve the loss function, alleviating the impact of imbalance between positive and negative samples on detection accuracy. During the training process, the data set was expanded based on data enhancement methods such as adding noise, brightness transformation and scaling, which improved the generalization performance of the training model. Experimental results show that the improved model can simultaneously detect three types of porcelain insulators, porcelain insulator defects, interphase rods, anti-vibration hammers and bird's nests under complex backgrounds. The average accuracy (mAP) reaches 94.1%, which provides a new idea for the intelligent inspection of transmission lines.

Keywords: multi-objective identification of transmission lines; Cascade R-CNN; deep learning; feature fusion

收稿日期: 2021-03-12 Received Date: 2021-03-12

* 基金项目: 辽宁省教育厅科学研究经费项目(LJ2019JL013, LJ2020JCL020, LJ2019QL011)、辽宁工程技术大学学科创新团队(LNTU20TD-29)项目资助

0 引言

输电线路巡检是电力系统监控的关键环节,对保障电网安全稳定运行以及用户用电可靠性起着至关重要的作用^[1-2]。绝缘子、防震锤、相间棒、鸟窝等是输电线路巡检的主要目标,其中绝缘子串缺失不仅造成电网解裂,也会导致大规模断电,防震锤、相间棒故障容易引起线路跳闸、停电或烧伤导线等严重事故,鸟窝极易造成线路短路及触电事故^[3]。传统人工巡检费时费力、效率低,针对高压架空线路距离长、容量大、环境复杂,无人机巡检搭载图片或视频采集设备能够自由飞行与悬停,有利于更加高效、快捷地采集输电线路设备运行状态,从而方便工作人员及时准确发现输电线路目标故障,并迅速采取措施避免损失^[4]。对于无人机巡检产生的大量巡检图像,人工识别方法因工作量大效率不高,而且人员一时疏忽极易造成漏检与误检,近年来基于深度学习的图像目标检测受到人们的广泛关注,而且具有很好的应用前景^[5-6]。

基于深度学习的单阶段目标检测算法以 SSD^[7]、YOLO^[8]、RetinaNet^[9] 为代表,两阶段目标检测算法以 Faster R-CNN^[10]、Mask R-CNN^[11]、SPP-Net^[12] 为代表。目前将目标检测算法引入到输电线路目标缺陷检测方面的研究已有很多,Miao 等^[13] 利用 SSD 算法在森林场景和建筑物场景下检测绝缘子,实验验证了该算法的快速性和有效性。颜宏文等^[14] 通过改进 YOLOv3 的损失函数以及训练策略可端到端地相对快速实现绝缘子串的定位与状态识别。但单阶段目标检测算法往往以牺牲检测精度为代价来提高检测速度,对于输电线路小目标定位能力不高。在实际检测中,巡检图像小目标很容易引起正负样本不平衡,从而影响检测精度。而两阶段目标检测算法一定程度上可以缓解此现象。顾超越等^[15] 提出了一种改进的 Faster R-CNN 算法对输电线路销钉缺陷检测,实验证明了 Faster R-CNN 对小目标识别效果较好。在 Faster R-CNN 基础上,引入级联形式的多阈值检测器,形成了一种新算法即 Cascade R-CNN^[16]。现在对基于 Cascade R-CNN 的输电线路目标检测研究相对较少,文献[17]利用 Cascade R-CNN 对小目标检测,相比于 Faster R-CNN, Cascade R-CNN 表现出对待检测目标的强大定位能力。考虑本文需对防震锤、相间棒等小目标进行检测,选择检测性能更佳的 Cascade R-CNN 作为核心算法。

对于输电线路尺寸大小不一的多目标检测,检测效果会受到特征提取能力的约束。相比于 AlexNet^[18]、VGGNet^[19]、GoogLeNet^[20] 特征提取网络,深度残差网络(residual network, ResNet)作为深度学习的前端更具优势,可以有效解决训练过程中的梯度弥散问题^[21]。ResNet 作为特征提取网络的前端,利用特征金字塔网络

(feature pyramid networks, FPN)^[22] 将高分辨率的低层特征图和高语义信息的高层特征图进行融合,在融合后的特征层上进行单独预测,特征提取效果较理想。文献[23]设计了旨在加强底层特征的 PinFPN,但测试准确率最高为 72.5%,依然存在很大的进步空间。可见,如何构建有效且精确的特征提取网络是亟需解决的问题。

针对上述问题,本文提出了一种改进的 Cascade R-CNN 算法。本文主要贡献如下:1) 为了提高对不同尺寸目标的特征提取能力,构建了 6 层 FPN 新结构,与 ResNet101 相结合构成复合特征提取网络来获取更具辨识力的特征;2) 利用高斯形式的软非极大值抑制(soft-non maximum suppression, Soft-NMS)方法来提高具有遮挡情况的目标检出率;3) 采取具有平衡正负样本能力的 Focal 损失改进损失函数,提升检测精度;4) 对训练集进行亮度变换、尺度放缩以及添加噪声等操作扩充样本,以满足深度学习对样本数量的训练要求。

1 基于 Cascade R-CNN 算法的目标检测原理

1.1 主体结构

Cascade R-CNN 网络结构如图 1 所示,包括 3 个主要部分,卷积神经网络、区域建议网络(region proposal network, RPN)以及基于感兴趣区域的(region-of-interest, ROI)多分类器 Softmax1、Softmax2、Softmax3 与回归器 B1、B2、B3。卷积层对经过预处理的输入图像进行目标特征自动提取,RPN 根据特征映射关系生成一系列可能存在目标的候选框,经 ROI 池化层作用缩小特征图至某一固定尺寸,再通过全连接层得到低维特征向量,最后送入级联形式的检测器。Cascade R-CNN 算法在每个阶段设置逐级升高的交并比(intersection over union, IoU)阈值对正样本即目标与负样本即背景进行分类以及边界框回归,改善了传统单一低阈值网络误检概率大与单一高阈值网络正负样本数量不平衡的情况。除第一个检测模型外, Cascade R-CNN 采用前一个检测模型的输出结果作为后一个检测模型的输入,且随着级联阶段增加, IoU 阈值呈现逐渐离散上升的趋势,这样每一级网络输出的分类与定位准确度都会逐级提升,用作下一个更高精度的网络的输入,因此 Cascade R-CNN 致力于实现高质量的目标检测。

1.2 级联网络

Cascade R-CNN 具有独特的级联结构,为输电线路目标检测提供了强大的定位能力。级联阶段 IoU 阈值依次设置为[0.5, 0.6, 0.7],意味着采用 3 个级联阶段来分

类与回归边框。将锚框送入 IoU 阈值为 0.5 的检测网络,若此时锚框与目标框之间的 $IoU>0.5$,意味着锚框中包含着检测目标,引入回归损失微调边框位置,同时生成初次分类评分,接着得到回归器修正后的新区域,经过筛选的候选框再次送入 IoU 阈值为 0.6 的检测网络,若此时 $IoU>0.6$,判定目标被正确检出,同时根据损失函数进行第 2 次边框回归与确定第 2 次分类得分。依照此规律,得到目标最终分类得分以及位置坐标。

2 基于改进 Cascade R-CNN 的输电线路多目标检测

本文提出的基于改进 Cascade R-CNN 的输电线路多目标检测方法,包括训练模式和测试模式两部分。利用训练集所得的权重信息对测试集进行检测,根据测试集




图 1 Cascade R-CNN 结构

Fig. 1 The structure of Cascade R-CNN

所得结果评估本文检测算法,改进的 Cascade R-CNN 检测模型如图 2 所示。




图 2 基于改进 Cascade R-CNN 的输电线路多目标识别模型

Fig. 2 A multi-objective identification model for transmission lines based on Cascade R-CNN

首先,将无人机采集的图片经降采样处理调整为合适尺寸的训练集图像,然后输入到基于 ResNet101 和 6 层 FPN 的特征提取网络,在 256×256 、 128×128 、 64×64 、 32×32 、 16×16 、 8×8 六个尺度下进行特征预测,获得一定数量的锚框,其中每个锚框包括 13 个参数,前 4 个为锚框的位置参数,其余为 9 类(8 类检测目标与背景)目标的置信度,最后将带有置信度的锚框送入级联分类器与回归器,通过高斯形式的非极大值抑制方法获取置信度最高的锚框,实现输电线路的多目标分类、异物与缺陷的定位。

2.1 多尺度融合的特征提取网络

利用 FPN 与 ResNet101 网络结构结合,可以解决不同尺寸大小的图片输入同一个检测模型的问题。以 ResNet101 网络为特征提取网络的主干,包括 5 个阶段,

选择第 2~5 阶段残差模块输出的特征图即 C_2 、 C_3 、 C_4 、 C_5 进行特征融合, C_2 、 C_3 、 C_4 、 C_5 输出特征图尺寸分别为 $256\times 256\times 256$ 、 $128\times 128\times 512$ 、 $64\times 64\times 1024$ 、 $32\times 32\times 2048$ 。显然,基于 ResNet101 网络的特征提取过程,图片尺寸不断减小而通道数不断增加。随着特征图底层的丢失,图片分辨率逐级下降,导致检测模型无法对输电线路小目标进行有效识别与定位。而在 FPN 网络作用下,金字塔层 P_2 、 P_3 、 P_4 、 P_5 在结构方面增加自下而上带有反向侧边连接的支路与 C_2 、 C_3 、 C_4 、 C_5 相连;内容方面, P_2 、 P_3 、 P_4 、 P_5 与 C_2 、 C_3 、 C_4 、 C_5 的图片尺寸呈现一一对应的关系,使用 1×1 卷积固定特征图的通道数为 256,通过 3×3 卷积操作来减弱特征图的混叠效应。改进的特征提取网络结构如图 3 所示,融合后的各金字塔层 $P_2\sim P_7$ 的计算公式如下所示:

$$\begin{aligned}
P_5 &= \text{Conv}_{1 \times 1}(C_5) \\
P_4 &= \text{Conv}_{3 \times 3}[\text{Conv}_{1 \times 1}(C_4) + F_{up}(P_5)] \\
P_3 &= \text{Conv}_{3 \times 3}[\text{Conv}_{1 \times 1}(C_3) + F_{up}(P_4)] \\
P_2 &= \text{Conv}_{3 \times 3}[F_{1 \times 1}(C_2) + F_{up}(P_3)] \\
P_6 &= \text{Conv}_{3 \times 3}[F_{down}(P_5)] \\
P_7 &= \text{Conv}_{3 \times 3}[F_{down}(P_6)]
\end{aligned} \quad (1)$$

具体过程为 C_5 通过 $\text{Conv}_{1 \times 1}$ (1×1 卷积操作) 得到 P_5 , 特征图大小为 $32 \times 32 \times 256$, 然后 P_5 通过步幅为 2 的近邻插值上采样提升图片分辨率, 与 C_4 相加融合形成 P_4 , 特征图大小为 $64 \times 64 \times 256$, 按照此规律依次形成 P_3 、

P_2 , 特征图大小分别为 $128 \times 128 \times 256$ 、 $256 \times 256 \times 256$ 。 P_5 进行 $\text{Conv}_{3 \times 3}$ (3×3 卷积操作) 并通过下采样形成 P_6 , 接着 P_7 由 P_6 经过 3×3 卷积操作以及下采样构成, P_6 、 P_7 特征图大小分别为 $16 \times 16 \times 256$ 、 $8 \times 8 \times 256$ 。由于浅层具有高分辨率的特征, P_2 、 P_3 、 P_4 、 P_5 与浅层融合, 能够有效查找照片远景的小目标。随着网络的不断深入, 小目标信息将由于卷积和轮询而消失。相比大多数融合网络采取的 4 层金字塔结构, 本文根据深层特征图的高语义信息, 在 4 层金字塔结构基础上设计 P_6 和 P_7 两层金字塔有助于更加精确检测绝缘子、鸟窝等大目标。




图 3 多尺度融合的特征提取网络结构

Fig. 3 Feature extraction network structure of multi-scale fusion

2.2 非极大值抑制的优化

根据 IoU 阈值过滤掉属于背景以及不符合条件的锚框并对锚框边框回归后, 各检测目标会生成大量带有置信度的候选框且存在重叠的情形。因此需采用非极大值抑制方法删除冗余检测框, 只保留置信度值最高的锚框。传统的 NMS 方法很容易将遮挡严重的目标直接过滤, 导致漏检概率增加。

为了解决上述问题, 本文选择 Soft-NMS 方法对遮挡严重的锚框进行识别, 引入高斯函数, 如果某锚框与得分最大的锚框的 $IoU > 0.6$, 将其置为较低得分, 而不是直接清零, 从而降低检测模型对存在遮挡情况目标的漏检可能性。高斯函数形式的 Soft-NMS 如下所示:

$$s_i = s_i e^{-iou(B, b_i)^2 / \sigma} \quad (2)$$

式中: B 代表当前得分最高框; b_i 为待检测框; σ 为常数, 一般为 0.5; s_i 代表 b_i 的置信度得分, 如果 B 和 b_i 的重叠度越大, 则 s_i 越低。

2.3 损失函数的改进

在 RPN 训练过程中, 以各个不同尺度的特征图的像素点为中心会产生一定数量的锚框, 该锚框数量远远大于巡检图像目标的数量, 从而导致负样本数目增多。另外, 对于图像中小尺度目标, 背景所占比例超于小目标的

比例, 也会造成正负样本数量不平衡。因此, 本文采用 Focal 损失改进整体损失函数, 缓解正样本数量小于负样本对检测精度造成的影响。

改进的 Cascade R-CNN 总体损失函数如下:

$$L(p_i, p_i^*, b_i, b_i^*) = L_{Focal}(p_i, p_i^*) + L_{cls}(p_i, p_i^*) + \lambda [p_i^* \geq 1] L_{loc}(b_i, b_i^*) \quad (3)$$

$$L_{Focal} = \begin{cases} -\alpha(1-p_i)^\gamma \log p_i, & p_i^* = 1 \\ -(1-\alpha)(p_i)^\gamma \log p_i, & p_i^* = 0 \end{cases} \quad (4)$$

$$L_{loc}(b_i, b_i^*) = R(b_i - b_i^*) \quad (5)$$

式中: i 代表锚框的序号, L_{Focal} 代表 Focal 损失, L_{cls} 代表分类损失, 使用 Softmax 函数计算, L_{loc} 代表定位损失, p_i 代表锚框为正样本的概率, p_i^* 代表锚框的类别, $b_i = (b_x, b_y, b_w, b_h)$ 代表锚框参数向量, $b_i^* = (b_x^*, b_y^*, b_w^*, b_h^*)$ 代表标记框参数向量, R 为 $smooth_{L1}$ 函数, λ 代表权衡系数, 通常取 1。

$$p_i = \frac{e^{a_j}}{\sum_{k=1}^m e^{a_k}} \quad (6)$$

$$p_i^* = \begin{cases} 1, & IoU(x, g) > u \\ 0, & \text{其他} \end{cases} \quad (7)$$

式中: a_j 代表 Softmax 输出向量的第 j 个值, $j=1, 2, \dots, m$, m 代表类别数, 本文 m 值为 8, 代表 8 分类问题。 x 代表

锚框, g 代表真实边界框, u 代表 IoU 阈值, 在级联阶段依次设置为 $[0.5, 0.6, 0.7]$ 。

对边框的中心坐标 x, y 以及框的宽度 w , 框的高度 h 进行归一化处理, 如下所示:

$$\begin{cases} \partial_x = (g_x - b_x)/b_w \\ \partial_y = (g_y - b_y)/b_h \\ \partial_w = \log(g_w/b_w) \\ \partial_h = \log(g_h/b_h) \end{cases} \quad (8)$$

回归损失 L_{loc} 最终形式如下所示:

$$smooth_{L1}(b_i - b_i^*) = \begin{cases} 0.5(b_i - b_i^*)^2, & |b_i - b_i^*| < 1 \\ |b_i - b_i^*| - 0.5, & \text{其他} \end{cases} \quad (9)$$

3 实验及结果分析

3.1 数据集建立与处理

本次实验环境配置如下: GPU 型号为 NVIDIA RTX2080Ti, 共 4 块; CPU 型号为 Intel Xeon Gold 6230, 共 2 块。采用 PyTorch 深度学习框架、Ubuntu18.04 系统、Python3.6 版本、配置 CUDA10.0 实现网络。

本实验采用的原始图像为某供电局近几年无人机航拍巡检样本, 共 2 300 张。为扩充样本, 本文对数据集图像添加高斯噪声、乘性噪声以及椒盐噪声, 采取亮度变换、尺度放缩、图片质量调整、增强滤波以及运动模糊处理方式模拟无人机真实拍摄环境, 体现不同分辨率、不同天气、不同光照、不同时间段以及无人机抖动所拍摄图片的真实性。

本文考虑到原始的鸟窝图片以及绝缘子缺陷图片稀少而其他类别图片数量相对多以及场景多样, 基于泊松融合技术^[24]将剪切的鸟窝与绝缘子缺陷与其他背景随机融合, 丰富鸟窝和绝缘子缺陷训练背景; 采用形态学中的开、闭运算清除噪声干扰, 增强图像连续性。既改善了正常与缺陷绝缘子数量的平衡性, 又模拟了检测目标被障碍物遮挡的情况, 增加了样本的多样性。部分图像合成结果如图 4 所示。

经上述数据增强处理, 数据集图像最终扩充到 18 620 张。按照 9 : 1 的比例随机划分训练集与测试集, 实验过程中保证训练集与测试集相互独立。训练集包括 16 720 张图像, 其中绝缘子共 48 537 个, 绝缘子缺陷共 21 101 个, 防震锤共 11 880 个, 相间棒共 29 880 个, 鸟窝共 4 752 个, 测试集包括 1 900 张图像, 其中绝缘子共 3 870 个, 绝缘子缺陷共 2 526 个, 防震锤共 1 656 个, 相间棒共 3 210 个, 鸟窝共 421 个。根据 COCO 格式制作数据集, 标签标注工具为 labelme, 将 3 种不同形状的瓷质绝缘子、绝缘子掉串缺陷分别视为同一种目标类型, 记为




图 4 图片扩充结果

Fig. 4 Image expansion results

INSULATOR、INSULATOR_DEFECT, 相间棒标签记为 SPACE, 防震锤标签记为 SHOCK_HAMMER, 鸟窝标签记为 BIRDHOUSE, 输电线路多目标标注如图 5 所示。每个目标扩充前后具体数量如表 1 所示。



图 5 输电线路目标的标注

Fig. 5 Targeting of transmission lines

表 1 多目标名称及数量

Table 1 Multiple target name and quantity

标签	类型	扩充前样本	扩充后样本
		数量	数量
INSULATOR	绝缘子	9 785	48 537
INSULATOR_DEFECT	绝缘子缺陷	456	23 657
SHOCK_HAMMER	防震锤	3 306	15 186
SPACE	相间棒	9 930	29 880
BIRDHOUSE	鸟窝	499	5 251

3.2 模型训练

本次实验采用 PyTorch 实现 4 路 GPU 分布式训练。

采用 Adam 优化参数作为基础迭代器,初始学习率为 0.04,迭代 1 000 次后学习率为 0.002,momentum 动量因子为 0.9,weight_decay 权重衰减因子为 0.000 1,total_epochs 为 254,P₂、P₃、P₄、P₅、P₆、P₇ 的锚步分别是 10、15、22、33、50、77。

本实验以损失函数(loss)值作为评判算法收敛效果的依据, Loss 值越低,表明算法的收敛效果越好。通过大量测试,确定最优迭代次数为 34 500,6 种不同算法的 Loss 曲线训练结果如图 6 所示,图 6 中 Cascade R-CNN+(ResNet101)表示基于 ResNet101 和 5 层 FPN 特征提取

网络的 Cascade R-CNN 检测模型,Ours 表示基于 ResNet101 和 6 层 FPN 特征提取网络的 Cascade R-CNN 检测模型。在相同的配置环境下对训练集进行训练,当迭代 34500 次后,Faster R-CNN(ResNet50)、Faster R-CNN(ResNet101)、Cascade R-CNN(ResNet50)、Cascade R-CNN(ResNet101)、Cascade R-CNN+(ResNet101)、本文的 Loss 依次为 0.049 1、0.041 99、0.024 29、0.011 9、0.020 6、0.017 11。可见,本文采用的算法模型 Loss 值略高于 Cascade R-CNN(ResNet101)网络,但均明显低于其余网络模型,说明本文所采用的算法收敛效果较好。




图 6 不同算法的 Loss 曲线对比
Fig. 6 Comparison of Loss curves of different algorithms

3.3 评价指标

本文采用目标检测算法中常用的平均精确率 (average precision, AP) 以及所有类别 AP 值的平均值 (mean average precision, mAP) 来评估模型的性能。计算公式如下:

Precision = TP / (TP + FP) (10)

AP = (sum of Precision) / n (11)

mAP = (sum of AP) / N (12)

式中: TP 是被正确划分为正例的个数; FP 是被错误划分为正例的个数; n 是样本总数; N 是类别数。以召回率为横轴,查准率为纵轴,可以得到一条曲线,在该曲线下的面积即为 AP 值。

3.4 不同数据集检测结果与分析

为比较扩充数据集前后检测效果,以 Cascade R-CNN 为主体网络,分别将 ResNet50 和 ResNet101 作为特征提取网络对输电线路多目标进行检测。随机选取原始 2 000 张样本作为扩充前训练集,扩充前与扩充后测试集均与 3.1 节相同,参数设置与 3.2 节的实验参数相同,采用 AP 指标评价模型,扩充前后数据集测试结果如表 2 所示。

表 2 扩充前后数据集测试结果对比
Table 2 Comparison of test results before and after data set expansion

标签	扩充前测试结果		扩充后测试结果	
	ResNet50	ResNet101	ResNet50	ResNet101
INSULATOR	0.799	0.826	0.879	0.912
INSULATOR_DEFECT	0.504	0.551	0.870	0.879
SHOCK_HAMMER	0.862	0.878	0.856	0.895
SPACE	0.802	0.818	0.860	0.889
BIRDHOUSE	0.576	0.621	0.841	0.907

由表 2 中 AP 数据可知,采用扩充后的数据集进行训练,各目标的检测结果均有明显提升,尤其是原始样本数量较少的绝缘子缺陷与鸟窝,原因是若采用扩充前数据集训练模型,因图像泛化性能低导致检测效果不理想。说明本文采用的数据扩充方式在一定程度上提升了算法的识别性能,也表明利用人工合成方式扩充稀缺的图像样本在目标检测过程中是可行的,弱化了模型的过拟合现象,提升了模型的泛化性能。另外通过对比 ResNet50 与 ResNet101 网络对各类目标的检测准确率,在一定程度上验证了 ResNet101 作为特征提取网络比 ResNet50 更具优势。

3.5 不同特征提取网络检测结果与分析

为确保小目标能够有效检测和定位,本文设计了两种 FPN 网络,分别是 5 层($P_2、P_3、P_4、P_5、P_6$)和 6 层($P_2、P_3、P_4、P_5、P_6、P_7$),同 ResNet50、ResNet101 网络进行对比实验,测试结果如表 3 所示。根据 COCO 数据集的格式来定义本文的 AP Small、AP Medium、AP Large,分别代表模型识别小目标、中目标、大目标的平均精确率。通过比较 AP 值,可得出 ResNet101 检测效果优于 ResNet50;单个 ResNet 网络检测效果不如 ResNet 与 FPN 复合网

络;对比 5 层 FPN 结构,6 层 FPN 检测准确率更高。无论对大目标识别,还是对中小目标检测,ResNet101 和 6 层 FPN 融合的网络表现最佳,其 AP 值均最高,对小目标检测的平均精确率达到 93.6%。说明 ResNet101 网络和 6 层 FPN 融合网络相对有效提取目标特征,达到较高的检测精度。

表 3 不同特征提取网络检测结果对比
Table 3 Comparison of detection results of different feature extraction networks

网络模型	AP	AP	AP
	Small	Medium	Large
ResNet50	0.865	0.516	0.685
ResNet101	0.875	0.531	0.700
ResNet50+6 层 FPN	0.921	0.953	0.988
ResNet101+5 层 FPN	0.915	0.942	0.979
ResNet101+6 层 FPN	0.936	0.958	0.99

3.6 多目标检测结果与分析

为测试本文提出的多目标检测算法的有效性,利用扩充后数据集的训练权重对测试集巡检图像进行检测,随机选择了 6 张图展示检测结果,如图 7 所示,八类输电线路目标检测准确率如表 4 所示。




图 7 多目标检测效果
Fig. 7 The detection effect of multiple targets

表 4 本文算法检测结果

Table 4 Test results of this algorithm

标签	标记数	检出数	检出率	AP
INSULATOR	3 870	3 706	0.958	0.956
INSULATOR_DEFECT	2 526	2 443	0.967	0.963
SHOCK_HAMMER	1 656	1 498	0.905	0.901
SPACE	3 210	3 018	0.940	0.938
BIRDHOUSE	421	405	0.962	0.947
mAP				0.941

通过图 7 可以看出,虽然远景目标小,瓷质绝缘子和杆塔、大地、树木颜色相近,鸟窝、防震锤、相间棒以及绝缘子均存在一定的遮挡及重叠现象,同时还会受到天气变化、无人机抖动拍摄的影响,但本文所检测的目标均被同时检测,克服了目标种类的多样性以及特征不易提取的难题。由表 4 数据可知,各类别的 AP 值均在 90% 以

上,并且 mAP 值达到 0.941。说明本文研究的算法可以在远景、近景、天气多变等复杂场景下很好地完成输电线路多目标检测任务。

6 种不同算法检测效果对比如表 5 所示。由表 5 数据可得,本文所研究的算法检测结果 mAP 值最高,提升了 2.5%~11.5%,说明此算法的目标检测精确率优于其他算法。本文考虑目标定位主要在对目标识别的基础上来进行,因此重点研究航拍巡检图像各目标的检测精度,为下一阶段更深层次的故障定位提供了基础,例如防震锤、相间棒的故障定位。

表 5 不同算法对比结果

Table 5 Comparison of different algorithms

类别	Loss	mAP
本文	0.017 11	0.941
Faster R-CNN(ResNet50)	0.049 10	0.796
Faster R-CNN(ResNet101)	0.041 99	0.826
Cascade R-CNN(ResNet50)	0.024 29	0.865
Cascade R-CNN(ResNet101)	0.011 90	0.882
Cascade R-CNN+(ResNet101)	0.020 60	0.916

4 结 论

本文研究了一种基于深度学习的输电线路多目标检测算法,得出如下结论,与只有 FPN 或者 ResNet 非组合形式网络进行对比,将 6 层 FPN 网络和 ResNet101 网络融合提取特征效果显著,对于远景小目标的特征提取有一定的贡献,目标检测准确率得到很大提升。Cascade R-CNN 算法致力于实现高质量的目标检测,具有较强的深度学习能力,同时和 ResNet101 网络、6 层 FPN 网络相结合,平均精确率达到 94.1%,说明本文提出的算法有效缓解了远景目标模糊、小目标漏检以及目标重叠等情况,抗背景干扰能力较强,较好地实现端到端的识别。对扩充后的数据集进行检测,各目标检测结果的精确度显著上升,扩充前各目标检测精确度范围在 0.512~0.878 之间,扩充后精确度在 0.832~0.914 之间,有效地提升了训练所得的模型泛化性,弱化了模型的过拟合现象。

综上所述,本文所提出的深度学习目标检测算法在较复杂的背景下具有优良的鲁棒性,具有很高的工程应用价值。


参考文献

[1] 宋立业,王诗翱,刘昕明. 基于改进胶囊网络的电力线巡线异物检测[J]. 电子测量与仪器学报, 2020, 34(12): 49-56.
SONG L Y, WANG SH A, LIU X M. Foreign body detection in power line inspection based on improved capsule network[J]. Journal of Electronic Measurement

and Instrumentation, 2020, 34(12): 49-56.
[2] 李辉,周航,董燕,等. 面向输电线路的异常目标检测方法[J]. 计算机与现代化, 2020(8):8-13,20.
LI H, ZHOU H, DONG Y, et al. Abnormal target detection method for transmission line[J]. Computer and Modernization, 2020(8):8-13,20.
[3] 陈瑞. 基于航拍图像的输电线路关键部件故障识别方法[D]. 保定:华北电力大学, 2019.
CHEN R. Fault identification method of key components of transmission line based on aerial image[D]. Baoding: North China Electric Power University, 2019.
[4] 刘跃波,马立新. 电力巡检无人机避障技术研究[J]. 电子测量技术, 2019, 42(13): 1-5.
LIU Y B, MA L X. Research on UAV obstacle avoidance technology in electric power inspection[J]. Electronic Measurement Technology, 2019, 42(13): 1-5.
[5] 张姝,王昊天,董晓肿,等. 基于深度学习的输电线路螺栓检测技术[J/OL]. 电网技术:1-8 [2020-11-02]. <https://doi-org-443.e2.buaa.edu.cn/10.13335/j.1000-3673.pst.2020.1336>.
ZHANG SH, WANG H T, DONG X CH, et al. Transmission line bolt detection technology based on deep learning[J/OL]. POWER SYSTEM TECHNOLOGY:1-8[2020-11-02]. <https://doi-org-443.e2.buaa.edu.cn/10.13335/j.1000-3673.pst.2020.1336>.
[6] 吕志宁. 输电线路常见故障分析与检测方法综述[J]. 自动化与仪器仪表, 2020(1): 161-164,168.
LV ZH N. Summary of common fault analysis and detection methods for transmission lines[J]. Automation and Instrumentation, 2020(1): 161-164,168.
[7] YANG J, WANG, L. Feature fusion and enhancement for single shot multibox detector[C]. Proceedings of the 2019 Chinese Automation Congress, 2019: 2766-2770.
[8] REDMON J, FRAHADI A. YOLOv3: An incremental improvement [EB/OL]. [2018-09-30]. <https://arxiv.org/abs/1804.02767>.
[9] ZHAO T, LIU J, DUAN Z. UAV Target detection based on RetinaNet [C]. Proceedings of the 31st Chinese Control and Decision Conference, 2019: 3342-3346.
[10] MA L, XU C, ZUO G, et al. Detection method of insulator based on Faster R-CNN[C]. IEEE 7th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems, 2017: 1410-1414.
[11] JIANG A, YAN N, WANG F. Visible image recognition of power transformer equipment based on mask R-CNN[C]. IEEE Sustainable Power and Energy Conference, 2019: 657-661.

- [12] BAI R, CAO H, YU Y, et al. Insulator fault recognition based on spatial pyramid pooling networks with transfer learning (Match2018) [C]. 3rd International Conference on Advanced Robotics and Mechatronics, 2018: 824-828.
- [13] MIAO X, LIU X, CHEN J, et al. Insulator detection in aerial images for transmission line inspection using single shot multibox detector[J]. IEEE Access, 2019, 7(1): 9945-9956.
- [14] 颜宏文, 陈金鑫. 基于改进 YOLOv3 的绝缘子串定位与状态识别方法[J]. 高电压技术, 2020, 46(2): 423-432.
- YAN H W, CHEN J X. Insulator string location and state identification method based on improved YOLOv3[J]. High Voltage Engineering, 2020, 46(2): 423-432.
- [15] 顾超越, 李喆, 史晋涛, 等. 基于改进 Faster-RCNN 的无人机巡检架空线路销钉缺陷检测[J]. 高电压技术, 2020, 46(9): 3089-3096.
- GU Ch Y, LI ZH, SHI J T, et al. Defects detection of overhead line pin based on improved Faster-RCNN for UAV inspection[J]. High Voltage Engineering, 2020, 46(9): 3089-3096.
- [16] CAI Z, VASCONCELOS N. Cascade R-CNN: High quality object detection and instance segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, IEEE, 2019, 8828(c): 1-1.
- [17] 刘英杰, 杨风暴, 胡鹏. 基于 Cascade R-CNN 的并行特征金字塔网络无人机航拍图像目标检测算法[J]. 激光与光电子学进展, 2020, 57(20): 302-309.
- LIU Y J, YANG F B, HU P. Parallel feature pyramid network UAV aerial image target detection algorithm based on cascade R-CNN[J]. Laser and Optoelectronics Progress, 2020, 57(20): 302-309.
- [18] LI Y, PU Y, XU D, et al. Image aesthetic quality evaluation using convolution neural network embedded learning[J]. Optoelectronics Letters, 2017, 13(6): 471-475.
- [19] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. 3rd International Conference on Learning Representations, 2015: 1-14.
- [20] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [J]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, IEEE, 2015: 1-9.
- [21] HE K M, ZHANG X, REN S Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [22] ZHAO Y, HAN R, RAO Y. A new feature pyramid network for object detection[C]. Proceedings of the 2019 International Conference on Virtual Reality and Intelligent Systems, 2019: 428-431.
- [23] 李雪峰, 刘海莹, 刘高华, 等. 基于深度学习的输电线路销钉缺陷检测[J/OL]. 电网技术: 1-9[2020-11-09]. <https://doi.org/10.13335/j.1000-3673.pst.2020.1028>.
- LI X F, LIU H Y, LIU G H, et al. Defect detection of transmission line pin based on deep learning [J/OL]. Power System Technology: 1-9[2020-11-09]. <https://doi.org/10.13335/j.1000-3673.pst.2020.1028>.
- [24] 史晋涛, 李喆, 顾超越, 等. 基于样本扩充的 Faster R-CNN 电网异物监测技术[J]. 电网技术, 2020, 44(1): 44-51.
- SHI J T, LI ZH, GU CH Y, et al. Foreign body monitoring technology in Faster R-CNN grid based on sample expansion[J]. Power System Technology, 2020, 44(1): 44-51.

作者简介



李鑫, 2003 年于辽宁工程技术大学获得学士学位, 2006 年于辽宁工程技术大学获得硕士学位, 2016 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为人工智能、智能电网理论与技术。

E-mail: lixinyz@126.com

Li Xin received her B. Sc. degree from Liaoning Technical University in 2003, M. Sc. degree from Liaoning Technical University in 2006, and Ph. D. degree from Liaoning Technical University in 2016. Now she is an associate professor in Liaoning Technical University. Her main research interests include deep learning and the smart grid theory and technology.



刘帅男, 2019 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为智能电网理论与技术以及深度学习。

E-mail: liu620627@163.com

Liu Shuainan received her B. Sc. degree from Liaoning Technical University in 2019. Now she is a M. Sc. candidate at Liaoning Technical University. Her main research interests include deep learning and the smart grid theory and technology.