

基于改进 YOLOX 的输电线路典型部件及缺陷轻量检测方法

王凌云^{1,2}, 万旭东^{1,2}, 刘兰兰³, 黄力^{1,2}

(1. 三峡大学 电气与新能源学院, 湖北 宜昌 443002; 2. 三峡大学 湖北省输电线路工程技术研究中心, 湖北 宜昌 443002;
3. 带电巡检与智能作业技术国网公司实验室, 湖南 长沙 421000)

摘要:针对输电线路部件及缺陷检测中模型体积大、实时性差的问题,以及因背景复杂、样本不平衡导致易误检、漏检的问题,提出一种基于改进 YOLOX 的输电线路典型部件及缺陷轻量检测方法。首先引入 Ghostnet 替换原有主干网络,实现模型轻量化。其次为解决输电线路图像背景复杂导致易漏检、误检的问题,将坐标注意力模块嵌入特征融合网络和 CSPLayer 结构,加强对复杂背景中目标区域的关注。最后针对输电线路部件及缺陷样本不平衡以及不同目标检测难度差异大的问题,引入变焦损失函数,降低正负样本不平衡带来的影响,提升对难分类目标的训练强度以减少误检和漏检。实验结果表明,所提方法在输电线路部件及缺陷检测中的平均精度均值提高 2.67%,模型尺寸减少 33.01%,推理速度为 19.61 ms/张,能够满足无人机轻量化、高精度的电力实时巡检要求。

关键词:输电线路缺陷检测; Ghostnet; 坐标注意力机制; 变焦损失; 实时检测

DOI:10.15938/j.emc.2025.09.010

中图分类号: TM75; TP391

文献标志码: A

文章编号: 1007-449X(2025)09-0106-10

Light weight detection method for typical components and defects of transmission lines based on improved YOLOX

WANG Lingyun^{1,2}, WAN Xudong^{1,2}, LIU Lanlan³, HUNAG Li^{1,2}

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China; 2. Hubei Provincial Engineering Technology Research Center for Power Transmission Line, China Three Gorges University, Yichang 443002, China;
3. Live Inspection and Intelligent Operation Technology State Grid Corporation Laboratory, Changsha 421000, China;)

Abstract: Aiming at the problems of large model size and poor real-time performance in the detection of transmission line components and defects, as well as the problems of frequent false detection and missed detection due to complex background and imbalanced samples, a light weight detection method for typical transmission line components and defects based on improved YOLOX was proposed. Firstly, Ghostnet was introduced to replace the original backbone network to achieve model lightweighting. Secondly, in order to solve the problem of frequent missed detection and false detection caused by the complex background of the transmission line image, the coordinate attention module was embedded into both of the feature fusion network and CSPLayer structure to enhance the focus on the target area in complex background. Finally,

收稿日期: 2025-04-26

基金项目: 国家自然科学基金(51907104); 湖北省输电线路工程技术研究中心开放课题(2019KXL05)

作者简介: 王凌云(1981—), 男, 博士, 教授, 博士生导师, 研究方向为输电线路智能检测;

万旭东(1998—), 男, 硕士研究生, 研究方向为输电线路智能检测;

刘兰兰(1987—), 女, 博士, 高级工程师, 研究方向为智能输电运检;

黄力(1980—), 男, 博士, 副教授, 研究方向为输电线路智能检测。

通信作者: 万旭东

to address the problems of the imbalance samples of transmission line components and defects and the great differences in detection difficulty of different targets, the Varifocal loss function was introduced to reduce the impact caused by the imbalance of positive and negative samples, and improve the training intensity of difficult-to-classify targets to reduce false detection and missed detection. The experimental result shows that the average accuracy of the proposed method in the detection of transmission line components and defects is increased by 2.67%, the model size is reduced by 33.01%, and the reasoning speed is 19.61 ms/piece, which can satisfy the requirements of UAV lightweight and high-precision power real-time inspection.

Keywords: transmission line defect detection; Ghostnet; coordinate attention; varifocal loss; real-time detection

0 引言

电力部件的状态影响着电网稳定运行,需定期对其进行巡检以排除存在的安全隐患^[1]。随着我国电网规模不断扩大,电力巡检的范围及难度逐渐提升,现阶段人工巡检方式难以达到要求。因此,采用无人机对输电线路部件及其缺陷进行自动化检测具有重大意义^[2]。

目前,输电线路部件检测方法主要分为传统机器学习检测方法以及基于深度学习卷积神经网络的检测方法。传统机器学习检测方法首先分析具体部件目标的图形特征,然后构造机器学习分类器进行分类,姜云土等^[3]通过分析形状、颜色、纹理三种特征实现了对绝缘子的检测,一定程度降低了背景的影响。宋伟等^[4]通过形态学分析和色彩分析实现了部件锈蚀检测。上述传统机器学习检测方法虽然能够实现部件的检测,但大多仅适用于简单背景下单类目标的检测,且检测精度和速度并不理想。

随着人工智能的不断发展,基于深度学习卷积神经网络的电力目标检测方法以其更优秀的检测性能及泛化能力逐渐取代了传统的机器学习检测方法^[5-8]。基于深度卷积神经网络的检测模型主要分为基于区域建议的模型以及端到端模型两种。基于区域建议的模型以区域卷积神经网络(region convolutional neural network, R-CNN)及其系列模型 Fast R-CNN、Faster R-CNN、Cascade R-CNN 为代表^[9-12]。侯春萍等^[13]采用级联 Faster R-CNN 识别复杂背景下的绝缘子自爆缺陷,但模型检测速度慢且仍需人工筛选。赵振兵等^[14]在 Cascade R-CNN 的金字塔结构中引入空洞卷积,提高了典型金具的检测精度,但所检测的缺陷种类单一,难以应用于工程实际。上述基于区域建议的模型普遍检测速度慢,难以应

用于输电线路实时检测中。相比,端到端模型具有检测速度快的优点,代表算法包括单射多框检测器(single shot multi-box detector, SSD)、YOLO(You Only Look Once)、YOLOv3、YOLOX 等^[15-18]。石鑫等^[19]针对样本不平衡问题,采用自适应裁剪扩充了金具数据集,但仍存在精度不高的问题。杨剑锋等^[20]采用改进 YOLOv3 对输电线路异物入侵进行检测,取得了较高精度,但模型推理速度有待提升。郝帅等^[21]在输电线路故障检测中将视觉注意力卷积块模型融合到 YOLOv3 中,提升了原模型检测精度,但检测速度仍不理想。

上述方法多存在检测模型体积大、速度慢、复杂背景下精度不高的问题,导致模型在无人机等嵌入式设备的高精度实时巡检任务中无法适用,并且未能从根本上解决电力目标检测任务中样本不平衡及不同样本检测难度不同带来的模型训练不充分问题。为此,本文以目前检测性能最为平衡的 YOLOX 网络为基础模型,提出一种改进的输电线路典型部件及缺陷轻量检测方法,主要创新点和贡献如下:

1) 为有效降低计算量及占用资源,将 YOLOX 的主干网络改为 Ghostnet 网络,并根据 YOLOX 的结构特征对其进行调整,减少模型参数量,提高推理速度,形成轻量化模型。

2) 将坐标注意力模块嵌入特征融合网络进行改进,对主干网络传入的特征信息在空间与通道上聚焦,提升复杂背景下线路部件及缺陷目标的检测能力,弥补因替换轻量网络带来的特征提取能力下降问题,同时缓解网络深度带来的位置信息丢失问题。

3) 在损失函数中引入变焦损失,提高难分类样本损失权重,将训练指向高质量缺陷目标,同时,不

对称对待正负样本以解决电力部件及缺陷样本的不平衡问题,提升电力目标检测精度。

1 基于改进 YOLOX 的电力部件及缺陷检测原理

1.1 电力部件及缺陷检测框架

本文提出的基于改进 YOLOX 的输电线路典型部件及缺陷轻量检测方法框架如图 1 所示。




图 1 本文算法流程

Fig. 1 Flow of algorithm

1.2 YOLOX 网络概述

YOLOX 网络是新一代实时目标检测模型,其基于经典模型 YOLOv3 在解耦头、数据增强、无锚框处理、高级标签分配等方面进行改进,从而使其在检测性能上相比其他 YOLO 模型拥有更多优势。YOLOX 网络结构主要包含 4 个部分,分别为输入端、主干网络、特征融合网络(Neck)及预测网络。其中,输入端将对图片进行 Mosaic 数据增强^[21],图片尺寸归一化等处理;主干网络为 CSPDarknet53^[23],用于提取输入图像的特征,输出三种不同尺寸的特征层;特征融合网络采用 FPN + PAN 结构^[24-25],将主干网络输出特征进一步提取、融合;预测网络将特征融合网络的输出进行预测、非极大值抑制及解码等操作得到最终结果。

1.3 基于 GHOSTNET 改进的主干网络

YOLOX 的主干网络中包含大量传统卷积层,其运算复杂,不利于输电线路中无人机等嵌入式设备的轻量部署。因此,本文在主干网络中引入 Ghostnet^[26]以降低模型参量。

Ghost 卷积是 Ghostnet 网络的核心,图 2(a)和图 2(b)分别展示了传统卷积层与 Ghost 卷积。传统卷积层直接通过卷积获得输出,而 Ghost 卷积首先使用卷积生成少量特征图,再通过廉价的线性操作对其扩充得到冗余特征图,最后将两部分特征图

检测方法具体流程如下:1)使用无人机对输电线路进行巡检采集电力巡检图像,使用色彩反转、尺寸变换等方式对金具图像进行扩充;2)将得到的图像使用 labeling 工具进行标注并划分为训练集、验证集和测试集;3)搭建改进的 YOLOX 检测模型,将训练集和验证集图像输入模型进行训练得到训练权重;4)将得到的最优权重载入模型,对测试集图像进行预测,验证所提方法的有效性。

进行拼接,从而以更低的计算量得到了与传统卷积层相同数量的特征图。




图 2 传统卷积操作与 Ghost 卷积

Fig. 2 Traditional convolution operation and ghost module

设输入特征层的尺寸为 $H \times W \times C$, 输出特征层尺寸为 $H' \times W' \times C'$, 则传统卷积层运算量为

$$c_{\text{conv}} = H' \times W' \times C \times k \times k \times C'. \quad (1)$$

设 Ghost 卷积中第一部分操作的卷积核尺寸为 k , 第二次操作的卷积核尺寸为 k' , 中间生成 r 个特征图作为过渡, 则 Ghost 卷积计算量为

$$c_{\text{Ghost module}} = H' \times W' \times \frac{C'}{r} \times k \times k \times C + H' \times W' \times (r-1) \times \frac{C'}{r} \times k' \times k' \quad (2)$$

由于 Ghost 卷积中两部分操作卷积核尺寸相近且有 $C' \gg r$, 故有

$$\frac{c_{\text{conv}}}{c_{\text{Ghost module}}} \approx \frac{S \times C}{C + S - 1} \approx r_0 \quad (3)$$

由式(3)可知传统卷积运算量约为 Ghost 卷积运算量的 r 倍, 因此使用 Ghost 卷积替代传统卷积能够有效降低卷积运算量, 同时提高模型推理速度。

本文使用调整后的 Ghostnet 作为 YOLOX 的骨干网络以适应原网络输出尺寸, 如图3所示, 该网络主要由步长为1和2的 Ghost Bottleneck 构成, 部分 Ghost Bottleneck 结构中增加了挤压与激发模块 (squeeze and excitation, SE) 用于特征层权重的调整^[27], 从而更加有效地提取图像特征。




图3 改进的骨干网络结构图

Fig.3 Improved backbone network structure diagram

1.4 嵌入坐标注意力的特征融合网络

由于引入 Ghostnet 后, 骨干网络提取能力有轻微降低, 对输电线路部件及缺陷的检测不利, 为弥补该问题, 同时增强模型对复杂背景下目标区域的关注, 引入轻量化的坐标注意力 (coordinate attention, CA) 机制改进特征融合网络^[28], 帮助模型聚焦目标区域。坐标注意力能够在获得特征层通道维度特征信息的同时, 从高度和宽度两个空间维度获取位置信息, 使模型更加精确地关注复杂背景下电力目标所在区域, 充分利用嵌入式设备有限计算资源, 提取输电线路图像中更有效的特征。

坐标注意力模块主要由坐标信息嵌入和坐标注意力生成两个特征编码操作构成, 如图4所示, 具体如下:

1) 坐标信息嵌入: 对于一个 $C \times H \times W$ 的输入特征层, 其各点坐标为 (h, i) , 分别沿宽度以及高度方向通过自适应平均池化聚合位置特征, 得到特征层 $z_c^h(h)$ 和 $z_c^w(w)$:

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i); \quad (4)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (5)$$

2) 坐标注意力生成: 将 $z_c^h(h)$ 和 $z_c^w(w)$ 进行拼接, 使用 1×1 卷积函数 $F^{1 \times 1}$ 变换, 经过非线性函数 $\text{h-swish}(\delta)$ 激活, 得到包含宽度与高度信息的特征层:

$$f = \delta(F^{1 \times 1}(\text{Concat}[z_c^h, z_c^w])) \quad (6)$$

接着, 将 f 分别沿高度和宽度分解得到特征层 f^h 和 f^w , 分别使用 1×1 的卷积和 sigmoid 函数将 f^h 和 f^w 展开为高度与宽度方向上的注意力权重向量 g^h 和 g^w :

$$g^h = \text{sigmoid}(F_h^{1 \times 1}(f^h)); \quad (7)$$

$$g^w = \text{sigmoid}(F_w^{1 \times 1}(f^w)) \quad (8)$$

最后, 将原特征层分别沿宽度和高度与注意力权重向量 g^h 、 g^w 相乘, 得到添加坐标注意力后的特征层:

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (9)$$

其中: x_c 为输入特征层; g_c^h 、 g_c^w 为注意力权重; y_c 为输出特征层。




图4 坐标注意力结构

Fig.4 Coordinate attention structure

图5展示了使用坐标注意力改进的特征融合网络 CA-Neck。首先, 在原 CSPLayer 中的多个残差单

元的主干部分嵌入坐标注意力机制跳跃连接,构建 CA-CSPLayer,避免 CSPLayer 中多个残差单元后线路部件及缺陷目标位置信息的丢失,同时缓解因网络加深带来的梯度消失问题;其次,将坐标注意力模块嵌入特征融合网络的三个输入分支上,当主干网络对特征初步提取后,特征融合网络将通过坐标注意力机制获取特征层中每个点的位置信息,将其与通道信息进行加权融合,显著加强复杂背景中线路部件及缺陷目标位置信息的全局表征。同时,坐标注意力是一种轻量模块,因此将其嵌入后对整个模型的运算复杂度影响可以忽略不计。




图5 改进的特征融合结构

Fig. 5 Improved CA-Neck structure

1.5 嵌入坐标注意力的特征融合网络

损失函数在目标检测任务中用于衡量模型的训练效果。如式(10)所示,YOLOX 损失函数由真实框与预测框的位置损失 L_{Reg} 、类别损失 L_{Cls} 以及置信度损失 L_{Obj} 三部分组成:

$$\text{Loss} = L_{\text{Reg}} + L_{\text{Cls}} + L_{\text{Obj}} \quad (10)$$

其中,类别损失 L_{Cls} 和 L_{Obj} 使用二元交叉熵损失函数进行计算。在输电线路部件及缺陷目标检测中,图像中的部件及缺陷目标为正样本,图像的背景为负样本,显然存在正样本占比远低于负样本的不平衡问题;同时,由于航拍图像背景复杂且缺陷部件与正常部件之间存在相似性,导致一些复杂背景下的目标以及形态相似的目标难以检测。因此,引入变焦损失(Varifocal Loss)^[29] 替换原损失函数中的二元交叉熵损失^[30],缓解正负样本不平衡及高质量样本不平衡问题,将训练重点指向难分类的高质量正样本。

变焦损失基于焦点损失(Focal Loss)^[31] 进行改

进,焦点损失针对高质量样本不平衡问题,使模型更多地训练难以分类的目标:

$$FL(p_1, y) = \begin{cases} -\alpha(1-p_1)^\gamma \log(p_1), & y = 1; \\ -(1-\alpha)p_1^\gamma \log(1-p_1), & y \neq 1. \end{cases} \quad (11)$$

其中: $y=1$ 表示正样本; $y \neq 1$ 表示负样本; p_1 为预测样本为1的概率; α 为平衡正负样本的损失权重; γ 为用以解决样本分类难易比例不均衡的平衡因子; α 和 γ 为可调参数。

变焦损失在焦点损失基础上,不同对待正负样本的损失,根据计算交并比(intersection over union, IOU) 分类得分与定位质量得分 (IOU-Aware Cls_Score, IACS) 两个指标同时对正负样本以及高质量样本进行平衡,定义为

$$VFL(p_2, q) = \begin{cases} -q[q \log(p_2) + (1-q) \log(1-p_2)], & q > 0; \\ -\alpha p_2^\gamma \log(1-p_2), & q = 0. \end{cases} \quad (12)$$

其中: p_2 是预测的 IACS 得分; q 是目标 IOU 分类得分。对于训练中的正样本,将 q 设置为生成的预测框和真实框之间的 IOU,而对于训练中的负样本来说,所有类别的训练目标 q 均为 0。变焦损失通过设置 p_2^γ 在不降低正样本权重的情况下,有效降低负样本损失的权重,同时,通过 IOU 分类得分 q 增加高 IOU 正样本的损失权重,从而加强对难分类正样本的训练强度,使得训练更具针对性,降低线路部件及缺陷中难分类目标的检测性能。

2 实验结果及分析

本文提出的检测方法在 Python3.6 环境下进行实验,具体参数如下:深度学习模型框架为 Pytorch1.2,服务器 GPU 为 NVIDIA GTX 1080Ti,显存 11GB。

2.1 数据集的构建与图像预处理

实验使用某地区电网公司无人机巡检获取的输电线路巡检图像,筛选其中包含绝缘子,均压环, U 型挂环等 6 类输电线路典型部件及缺陷目标的图像制作数据集进行实验,使用 labeling 工具对其进行标注。本文数据集制作方法如下:首先对采集到的图像进行筛选初步得到 1 633 张图像,为提升模型训练效果,对图像进行随机长宽压缩、镜像、颜色反转操作得到 3 266 张图像,按照 9:1:1 将其划分为训练集、验证集以及测试集。

2.2 模型训练

在训练中,统一设置输入的图像尺寸为 640×640 方便网络对其处理,采用随机梯度下降法进行参数优化,动量参数为 0.9,每批次训练的 Batch 设置为 16。训练中采用迁移学习策略^[32-33],先使用预训练权重初始化并冻结主干网络参数,学习率设置为 0.01,训练 100 轮,随后解冻主干网络参数训练直至模型收敛,学习率设置为 0.001。为保证模型对比的有效性,所有模型均按上述参数设置进行训练。

图 6 展示了改进前后 YOLOX 模型训练中的损失值变化,从图中可以看出,无论在冻结训练还是解冻训练阶段,改进模型的收敛速度都要更快。两种模型最终在 275 轮附近趋于收敛,取损失最低的权重作为最终的检测模型进行实验。




图 6 损失值随训练轮次的变化

Fig. 6 Change of loss value with training epoch

2.3 评价指标

本文使用平均精度均值 (mean Average Precision, mAP)、推理时间、模型大小、参数量对模型进行衡量,其中,模型大小和参数量在空间上反应了模型结构大小及复杂程度,推理时间直接反应了模型应用时的检测速度,mAP 计算方式如下:

$$p_3 = \frac{TP}{TP + FP}; \quad (13)$$

$$r_e = \frac{TP}{TP + FN}; \quad (14)$$

$$AP = \int_0^1 p(r) dr; \quad (15)$$

$$mAP = \frac{\sum AP}{N}. \quad (16)$$

式中: p_3 为准确率; r_e 为召回率; N 为类别总数; TP 、 FP 、 FN 分别表示正确检测个数、误检个数及漏检个数。

2.4 改进方法的检测结果及对比实验

使用所提方法对 YOLOX 模型进行改进前后的检测结果如表 1 所示,从表中可以看出,对大部分电力目标来说,改进后模型的检测精度相比于改进前有一定提升,改进后检测方法对所有类型的电力目标的平均精度均值 mAP 提升到了 93.29%。

表 1 改进前后不同电力部件及缺陷目标的 AP 值对比

Table 1 Comparison of AP values of different power components and defect targets before and after improvement

典型部件及缺陷目标	AP/%		
	YOLOX	改进的 YOLOX	变化
均压环	98.82	99.19	+0.37
提包式悬垂线夹	85.09	89.89	+4.8
绝缘子	99.16	99.11	-0.05
绝缘子缺失	99.45	99.89	+0.44
鸟巢	98.90	99.62	+0.72
螺栓锈蚀	63.00	69.89	+6.89
U 型挂环锈蚀	88.03	90.39	+2.27
DB 调整板锈蚀	92.49	98.59	+6.01
mAP	90.62	93.29	+2.67

为验证所提改进的有效性,设计了 6 组实验进行对比,实验结果如表 2 所示。

表 2 采用不同改进的对比实验

Table 2 Comparative experiments with different improvements

组别	实验模型	mAP/%	模型大小/M	参数量
1	YOLOX	90.62	34.21	8 968 255
2	YOLOX + G	89.59	22.69	6 045 891
3	YOLOX + CA	92.17	34.40	9 019 007
4	YOLOX + VFL	93.67	34.21	8 968 255
5	YOLOX + CA + VFL	93.83	34.40	9 019 007
6	YOLOX + G + CA + VFL	93.29	22.89	6 196 643

其中,YOLOX + G、YOLOX + CA 和 YOLOX + VFL 分别表示仅采用 Ghostnet、坐标注意力和焦点损失函数其中一项改进的 YOLOX 模型,YOLOX + CA + VFL 表示同时采用坐标注意力改进和焦点损失函数改进的 YOLOX 模型,YOLOX + G + CA + VFL 表示同时采用三种改进的模型。对比 1、2 两组实验可知,引入 Ghostnet 主干网络后,模型大小和运算量相比原模型分别下降了 33.67% 和 32.59%,模型复

杂程度明显下降。对比实验 1、3 可知,使用坐标注意力机制改进特征融合网络后,模型在参数量几乎不变的情况下精度提升了 1.55%,坐标注意力机制能够从水平、垂直和通道三个维度对电力目标区域进行聚焦关注,减少无用信息的干扰,同时缓解深度网络对于电力目标位置信息的丢失。实验 4 模型在实验 1 模型的基础上引入了变焦损失,模型精度提高到 93.67%,说明在电力部件目标样本数严重不平衡的情况下,变焦损失能够有效降低正负样本不平衡带来的影响,同时使得模型对难分类样本进行有针对性的训练,提升分类困难样本的检测精度。实验 5 同时采用坐标注意力和变焦损失,精度进一步提升,mAP 达到 93.83%。实验 6 在实验 5 基础上引入 Ghostnet,在牺牲少量模型精度的情况下,大幅降低了参数量,模型大小仅为原来的 66.6%。

为进一步将本文方法进行更加直观地分析,选

取电力巡检中的 4 种典型航拍场景进行可视化,实验结果如图 7 所示。其中,每个场景中包含了原图、YOLOX 模型检测结果以及改进 YOLOX 模型的检测结果,具体实验结果与分析如下:

实验场景 1 为复杂背景下包含绝缘子缺陷的场景,实验场景 2 为目标存在部分遮挡的情况,可以看出改进前后两种方法均能分别准确识别出绝缘子、绝缘子缺失位置以及杆塔上鸟巢的位置,但改进后的模型预测框更加贴合缺失部位,而原模型预测范围则并不精确。场景 1 中原模型绝缘子预测框的下方有部分区域未进入预测框,而改进模型的预测框将绝缘子区域完整包括在内,预测结果更加准确,并且,场景 2 中改进模型相比原模型的预测框更加贴近鸟巢的位置。改进方法通过添加坐标注意力机制,使得模型能够更加关注目标坐标信息,因此,增强了对目标位置的定位效果。




图7 模型改进前后检测结果

Fig.7 Detection results before and after model improvement

实验场景3同时包括了复杂场景下存在部分遮挡目标以及远景目标的情况,可以看出两种方法均能有效识别大部分目标,但原模型并未识别出右下角一处遮挡情况较为严重的屏蔽环,改进方法对其进行了有效的识别。

实验场景4包括了多目标存在大面积重叠同时背景也较为复杂的情况,可以看出改进模型的预测框相对更加贴合目标。此外,原模型将耐张线夹的金属部件误识别为U型挂环,并且有一处U型挂环出现了漏检,但改进方法得益于加入的变焦损失函数,平衡了正负样本,强化了对难分类样本的训练,使得对遮挡目标、小目标、复杂目标的检测精度更高,因而避免了此处原模型出现的误检、漏检的情况。

2.5 改进方法的检测结果及对比实验

为客观评价所提改进算法的检测性能,将不同现有主流检测模型采用相同数据集,使用相同实验平台进行对比实验,实验结果如表3所示。

表3 不同模型的检测性能对比

Table 3 Comparison of detection performance of different models

实验模型	mAP/%	模型大小/M	推理时间/ms
SSD	83.84	99.76	51.86
YOLOv3	86.46	236.32	55.66
YOLOX	90.62	34.21	23.56
Faster R-CNN	88.49	522.91	168.86
Cascade R-CNN	88.89	169.00	139.34
本文方法	93.29	22.89	19.61

表3展示了本文方法与现有模型的检测性能对比。表中检测模型可分为两类,一类是端到端的检测方法:SSD、YOLOv3、YOLOX,此类方法由卷积神经网络直接输出预测结果,检测速度快,另一类是基于区域的检测方法:Faster R-CNN与Cascade R-CNN,该类方法在检测过程中先进行候选区域的生成,然后使用卷积神经网络对候选区域进行筛选,在速度上略逊一筹,但在精度上占优。与基于区域的方法纵向比较可知,本文方法的mAP分别比Faster R-CNN和Cascade R-CNN高出4.80%和4.40%。与端到端检测方法进行横向对比可知,本文方法的mAP比SSD、YOLOv3、YOLOX分别高出9.45%、6.83%和2.67%。此外,在所有对比模型中,本文方法的模型大小仅为22.89 M,远低于高精度的两

阶段检测模型,且本文方法的推理时间最短,检测速度在单阶段检测方法中也具有优势。因此,所提方法在模型大小、检测精度及实时性上都要优于对比模型,具有一定的应用价值。

3 结 论

本文提出一种基于改进YOLOX的输电线路典型部件及缺陷轻量检测方法。通过采用Ghostnet改进主干网络形成轻量化模型,在特征融合网络中嵌入轻量的坐标注意力机制,增强复杂及遮挡背景下目标的位置信息,引入变焦损失函数改变类别和位置损失函数的计算权重,平衡正负样本及高低质量样本,加强模型对难分类样本的训练。本文使用某电网公司无人机巡检图像进行预处理后制作了电力部件及缺陷数据集,使用所提改进方法在该数据集上进行实验。结果表明,在不同实验场景下,改进方法检测更加精确,平均精度均值达到了93.29%,且模型大小仅为22.89 M,单张图片检测速度仅为19.61 s,检测速度和精度相比现有模型具有明显优势,具有体积小、实时性好、精度高的特点,在电力智能化巡检中具有一定的应用价值。

参 考 文 献:

- [1] NGUYEN V N, JENSSEN R, ROVERSO D. Automatic autonomous vision-based power line inspection: a review of current status and the potential role of deep learning[J]. International Journal of Electrical Power & Energy Systems, 2018, 99: 107.
- [2] 刘志颖, 缪希仁, 陈静, 等. 电力架空线路巡检可见光图像智能处理研究综述[J]. 电网技术, 2020, 44(3): 1057. LIU Zhiying, MIAO Xiren, CHEN Jing, et al. Review of visible image intelligent processing for transmission line inspection[J]. Power System Technology, 2020, 44(3): 1057.
- [3] 姜云土, 韩军, 丁建, 等. 基于多特征融合的玻璃绝缘子识别及自爆缺陷的诊断[J]. 中国电力, 2017, 50(5): 52. JIANG Yuntu, HAN Jun, DING Jian, et al. The identification and diagnosis of self-blast defects of glass insulators based on multi-feature fusion[J]. Electric Power, 2017, 50(5): 52.
- [4] 宋伟, 左丹, 邓邦飞, 等. 高压输电线防震锤锈蚀缺陷检测[J]. 仪器仪表学报, 2016, 37(S1): 113. SONG Wei, ZUO Dan, DENG Bangfei, et al. Corrosion defect detection of earthquake hammer for high voltage transmission line[J]. Chinese Journal of Scientific Instrument, 2016, 37(S1): 113.
- [5] 赵振兵, 蒋志钢, 李延旭, 等. 输电线路部件视觉缺陷检测综述[J]. 中国图象图形学报, 2021, 26(11): 2545. ZHAO Zhenbing, JIANG Zhigang, LI Yanxu, et al. Overview of visual defect detection of transmission line components[J]. Journal of Image and Graphics, 2021, 26(11): 2545.

- [6] 姜香菊, 王瑞彤, 马彦鸿. 基于轻量级改进 RT-DETR 边缘部署算法的绝缘子缺陷检测[J]. 电工技术学报, 2025, 40(3): 842.
- JIANG Xiangju, WANG Ruitong, MA Yanhong. Insulator defect detection based on lightweight improved RT-DETR edge deployment algorithm[J]. Transactions of China Electrotechnical Society, 2025, 40(3): 842.
- [7] 陈永, 安卓奥博, 周建宇. 基于扩散模型检测的高铁接触网绝缘子缺陷语义描述方法[J]. 电工技术学报, 2025, 40(13): 4100.
- CHEN Yong, AN Zhuoabo, ZHOU Jianyu. Semantic description method of high-speed railway contact net insulator defects based on diffusion model detection[J]. Transactions of China Electrotechnical Society, 2025, 40(13): 4100.
- [8] 郑含博, 胡钧浩, 李金恒, 等. 基于改进实例分割与深度神经网络温度拟合的电力设备热故障诊断研究[J]. 电机与控制学报, 2025, 29(2): 116.
- ZHENG Hanbo, HU Junhao, LI Jinheng, et al. Thermal fault diagnosis of power equipment through improved instance segmentation and deep neural network temperature fitting[J]. Electric Machines and Control, 2025, 29(2): 116.
- [9] GIRSHICK R, DONAHUE J, DARRELL T. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 23 – 28, 2014, Columbus, Ohio, USA. 2014: 580 – 587.
- [10] GIRSHICK R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7 – 13, 2015, Santiago, Chile. 2015: 1440 – 1448.
- [11] REN Shaoqing, HE Kaiming, GIRSHICK R. 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.
- [12] CAI Z W, VASCONCELOS N. Cascade R-CNN: delving into high quality object detection [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18 – 22, 2018, Salt Lake City, Utah, USA. 2018: 6154 – 6162.
- [13] 侯春萍, 章衡光, 张巍, 等. 输电线路绝缘子自爆缺陷识别方法[J]. 电力系统及其自动化学报, 2019, 31(6): 1.
- HOU Chunping, ZHANG Hengguang, ZHANG Wei, et al. Recognition method for faults of insulators on transmission lines[J]. Proceedings of the CSU-EPSA, 2019, 31(6): 1.
- [14] 赵振兵, 熊静, 李冰, 等. 基于改进 Cascade R-CNN 的典型金具及其部分缺陷检测方法[J]. 高电压技术, 2022, 48(3): 1060.
- ZHAO Zhenbing, XIONG Jing, LI Bing, et al. Typical fittings and its partial defect detection method based on improved cascade R-CNN[J]. High Voltage Engineering, 2022, 48(3): 1060.
- [15] LIU Wei, ANGUELOV D, ERHAN D. SSD: Single shot multi-box detector [C]//14th European Conference on Computer Vision (ECCV), October 8 – 16, 2016, Amsterdam, Netherlands. 2016: 21 – 37.
- [16] REDMON J, DIVVALA S, GIRSHICK R. You only look once: Unified, real-time object detection [C]//2016 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 27 – 30, 2016, Las Vegas, Nevada, USA. 2016: 779 – 788.
- [17] REDMON J, FARHADI A. YOLOv3: An incremental improvement [EB/OL]. (2018 – 09 – 30). <https://arxiv.org/abs/1804.02767>.
- [18] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding yolo series in 2021 [EB/OL]. (2021 – 7 – 18). <https://arxiv.org/abs/2107.08430>.
- [19] 石鑫, 化晨冰, 张凯, 等. 基于 SSD 深度神经网络的航拍图像电力目标检测[J]. 数据采集与处理, 2022, 37(1): 207.
- SHI Xin, HUA Chenbing, ZHANG Kai, et al. Power target detection in aerial images based on SSD deep neural network[J]. Journal of Data Acquisition and Processing, 2022, 37(1): 207.
- [20] 杨剑锋, 秦钟, 庞小龙, 等. 基于深度神经网络的输电线路异物入侵监测和识别方法[J]. 电力系统保护与控制, 2021, 49(4): 37.
- YANG Jianfeng, QIN Zhong, PANG Xiaolong, et al. Foreign body intrusion monitoring and recognition method based on dense-YOLOv3 deep learning network[J]. Power System Protection and Control, 2021, 49(4): 37.
- [21] 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.
- HAO Shuai, MA Ruize, ZHAO Xinsheng, et al. Fault detection of YOLOv3 transmission line based on convolutional block attention model[J]. Power System Technology, 2021, 45(8): 2979.
- [22] ZHANG H, CISSE M, DAUPHIN Y N, et al. mixup: Beyond empirical risk minimization [EB/OL]. (2017 – 10 – 25) <https://arxiv.org/abs/1710.09412>
- [23] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [J]. arXiv preprint arXiv:2004.10934, 2020.
- [24] LIN T Y, Dollár P, GIRSHICK R. Feature pyramid networks for object detection [C]//2017 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), July 21 – 26, 2017, Honolulu, Hawaii, USA. 2017: 2117 – 2125.
- [25] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18 – 22, 2018, Salt Lake City, Utah, USA. 2018: 8759 – 8768.
- [26] HAN K, WANG Y, TIAN Q. Ghostnet: more features from cheap operations [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 14 – 19, 2020, Seattle, Washington, USA. 2020: 1580 – 1589.
- [27] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF conference on computer vision and pattern rec-

- ognition (CVPR), June 18 – 22, 2018, Salt Lake City, Utah, USA. 2018: 7132 – 7141.
- [28] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 19 – 25, 2021, Nashville, Tennessee, USA. 2021: 13713 – 13722.
- [29] ZHANG H, WANG Y, DAYOUB F. Varifocalnet: An iou-aware dense object detector [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 19 – 25, 2021, Nashville, Tennessee, USA. 2021: 8514 – 8523.
- [30] BAO T, JIAO H, GAO S, et al. Back propagation optimization of convolutional neural network based on the left and the right hands Identification [C]// 2021 IEEE International Conference on Computer Science, Artificial Intelligence and Electronic Engineering (CSAIEE), March 26 – 28, 2021, Kunming, China. 2021: 182 – 186.
- [31] LIN T Y, GOYAL P, GIRSHICK R. Focal loss for dense object detection [C]// Proceedings of the IEEE international conference on computer vision (ECCV), October 22 – 29, 2017, Venice, Italy. 2017: 2980 – 2988.
- [32] OQUAB M, BOTTOU L, LAPTEV I, et al. Learning and transferring mid-level image representations using convolutional neural networks [C]//2014 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 23 – 28, 2014, Columbus, Ohio, USA. 2014: 1717 – 1724.
- [33] 李东东, 赵阳, 赵耀. 一种变工况下风电机组行星齿轮箱的故障诊断方法[J]. 电机与控制学报, 2023, 27(1): 33.
- LI Dongdong, ZHAO Yang, ZHAO Yao. Fault diagnosis method for wind turbine planetary gearbox under variable working conditions [J]. Electric Machines and Control, 2023, 27(1): 33.

(编辑:刘素菊)