

融合 BiFPN 和注意力机制的电力设备 异常检测算法

邹琬¹, 杨玥坪², 廖文龙², 刘睿², 王振宇², 孙璐³, 唐浩³

(1. 国网四川省电力公司, 四川成都 610041; 2. 国网四川省电力公司电力科学研究院, 四川成都 610041; 3. 西南交通大学信息科学与技术学院, 四川成都 611756)

摘要:为提高电力设备异常检测的精度,提出以融合双向加权特征金字塔网络(BiFPN)和三重注意力(TA)机制改进 Yolov5s 的电力设备异常检测方法。首先,融合 BiFPN 是在特征融合结构中加入跨尺度连接线以保留更多深层的语义信息,可以有效促进目标的分类识别和位置精确定位;然后,加入采用三支结构的注意力机制能够更好地提取空间交互注意力和通道空间交互注意力,抑制无用的特征信息;最后,通过采用 Soft NMS 来取代传统的 NMS 算法可以有效减少目标的遗漏,并提升检测的准确性。实验数据显示,改进后的 YOLOv5s 网络模型相较于原始 YOLOv5s 模型,精确率从 88.3% 提升至 90%,召回率从 89% 提升至 93%,mAP@0.5 值从 88.7% 提升至 92.8%,有效地提高了检测精度。

关键词:YOLOv5s 模型;深度学习;注意力机制;目标检测

中图分类号:TP 183 文献标志码:A 文章编号:1003-6954(2025)01-0063-09

DOI:10.16527/j.issn.1003-6954.20250109

An Anomaly Detection Algorithm for Power Equipment Integrating BiFPN and Attention Mechanism

ZOU Wan¹, YANG Yueping², LIAO Wenlong², LIU Rui², WANG Zhenyu², SUN Lu³, TANG Hao³

(1. State Grid Sichuan Electric Power Company, Chengdu 610041, Sichuan, China;

2. State Grid Sichuan Electric Power Research Institute, Chengdu 610041, Sichuan,

China; 3. School of Information Science and Technology, Southwest Jiaotong

University, Chengdu 611756, Sichuan, China)

Abstract:In order to improve the accuracy of anomaly detection of power equipment, an improved Yolov5s anomaly detection method for power equipment by combining bidirectional weighted feature pyramid network (BiFPN) and triplet attention (TA) mechanism is proposed. In the integrated BiFPN, the cross-scale connection lines are added into the feature fusion structure to retain more deep semantic information, which can effectively promote the classification and accurate location of the target. The addition of three-branch structure of TA mechanism can better extract the spatial interactive attention and channel spatial interactive attention, and suppress the useless feature information. Finally, using Soft NMS to replace the traditional NMS algorithm can effectively reduce the omission of the target and improve the accuracy of detection. Experimental data show that compared with the original YOLOv5s model, the accuracy rate of the improved YOLOv5s network model has been increased from 88.3% to 90%, the recall rate has been increased from 89% to 93%, and the mAP@0.5 value has been increased from 88.7% to 92.8%, which effectively improves the detection accuracy.

Key words:YOLOv5s model; deep learning; attention mechanism; object detection

0 引言

为了保障输电系统的稳定性和安全性,对电力

基金项目:国网四川省电力公司科技项目“基于异常事件驱动的变电站智能巡检技术研究”(521997230014)

设备的异常进行检测已成为电力系统巡检工作中的一项重要任务。当前,深度学习目标检测模型主要分为两类:一类是没有候选框的单阶段(one-stage)检测模型,这种方法可以直接对图像中的目标进行预测和分类,而不需要事先生成候选框。常见的 one-stage 模型包括单次多框检测器(single shot

multibox detector, SSD)、YOLOv4 等改进模型。另一类是基于候选区域的两阶段(two-stage)检测算法,这种方法首先通过算法生成一些候选框,然后再对这些候选区域进行分类和位置修正。区域卷积神经网络(region-based convolutional neural networks, R-CNN)、更快区域卷积神经网络(faster R-CNN)等模型是 two-stage 方法的代表。目前,针对变电站设备异常检测方面已有大量研究。文献[1]为进一步提高电力设备异常检测方法对设备信息的利用率,通过时间序列自回归模型和自组织映射神经网络将连续的电力设备数据离散为单个序列,计算状态变量在时间轴上的转移概率,通过状态转移概率和聚类算法快速检测数据异常。文献[2]针对绝缘子缺陷目标区域小的问题,提出了卷积块中嵌入协同注意力(coordinate attention, CA)^[3]和多特征融合的改进方式,增强特征图的表征能力,检测的精度和每秒帧数(frames per second, FPS)分别达到了 93.4%和 25.4 Hz。文献[4]针对文献[5]添加了深度可分离卷积^[6]以替换传统的卷积操作,有助于减少网络的总体计算需求,并增加了网络的检测效率,从而提高了检测速度。文献[7]利用文献[8]中的通道混洗模块,引入新的通道拆分网络,减少模型检测的碎片化操作以提高检测速度。文献[9]提出了整合卷积网络、区域提议网络和目标检测模块等用于识别绝缘子中损伤区域的检测方法。尽管这种方法在检测精度上取得了提高,但其两阶段的检测流程导致了较高的计算资源消耗和较长的处理时间。文献[10]为实现各类巡检机器人、无人机等智能电力巡检设备所携红外热像仪采集的红外图像自动检测,提出基于改进 SSD 的电力设备红外图像异常自动检测方法。文献[11]在 YOLOv5 中融合了双向加权特征金字塔网络(bidirectional weighted feature pyramid network, BiFPN)后,减少了特征融合时小目标信息的损失。文献[12]利用三重注重力(triplet attention, TA)增加背景与建筑物的区分度,解决了检测区域背景复杂导致误检的问题。文献[13]将 faster R-CNN 中的后处理程序换为柔性非极大值抑制(soft non-maximum suppression, Soft NMS)算法,减少了同类别检测框重叠时的漏检情况。随着 YOLOv4 和 YOLOv5 等方法的提出,不论是检测精度还是速度,one-stage 均大幅度优于 two-stage。由于单阶段检测器推理速度快,所以 YOLO 系列模型在电力系统巡

检中得到了广泛运用。

尽管先前的研究在检测精度方面取得了显著进步,但仍然存在着电力设备数据集目标单一、检测效果误检和漏检率高的问题。此外,当前针对电力设备智能巡检所捕获的图像不够清晰,造成现有的目标检测算法无法充分提取特征,容易导致目标丢失和错误识别的情况发生。下面提出了一种基于 YOLOv5s 改良版本的电力设备异常检测模型。该模型旨在提高对几类常规电力设备异常的检测精度,对 YOLOv5s 模型进行了三方面的优化。首先,改进网络中的颈部(Neck)部分,将原有的特征融合结构替换为 BiFPN 结构,减少了特征融合时小目标信息的损失,可利用这个结构的特点对原始的特征融合方式进行改进,以增强模型的特征表示能力;其次,引入了 TA 机制,这是一种新型的注意力机制,电力设备所处背景通常比较复杂,TA 注意力机制可以通过 3 个分支的结构来捕捉跨维度的交互,从而以较低的计算成本提高了注意力权重的计算效率,并通过强调了多维交互的重要性,同时不牺牲任何维度,进一步提升模型的检测精度;最后,考虑到数据集中异常类型的密集分布特点,为了防止小目标的丢失,将 YOLOv5s 中的非极大值抑制(non-maximum suppression, NMS)算法替换为 Soft NMS,以提升检测性能。实验结果表明,这些改进显著提高了对电力设备异常类型的检测精度。

1 改进的 YOLOv5s 检测模型

1.1 特征融合模式改进

YOLOv5 特征融合网络采用特征金字塔网络(feature pyramid networks, FPN)加路径聚合网络(path aggregation network, PAN)的特征融合模式。底层特征图包含较强的定位特征信息,语义特征信息相对较弱。PAN 网络是通过自底向上的方式融合,可以有效传递精确的位置特征信息。而 FPN 网络则采用自顶向下的融合策略,通过上采样方法将高层次的语义信息进行传播和整合,以此来强化语义特征的表达。然而,由于输入特征分辨率的差异可能导致重要特征被忽略。此外,各类电力设备异常的尺度变化较大,因此传统的特征融合技术可能会破坏不同尺度特征的一致性。为解决这一问题,利用 BiFPN 网络结构对原始的特征融合方式进行

改进, BiFPN 的结构如图 1 所示。




图 1 BiFPN 结构

BiFPN 是一种用于目标检测和语义分割任务的特征金字塔网络^[17], 它引入了双向连接和加权融合来处理不同尺度输入特征信息。BiFPN 旨在解决传统的特征金字塔网络在处理多尺度特征时存在的信息丢失和冗余的问题, 主要包括两个关键的特征: 双向连接和加权融合。首先, 通过双向连接, BiFPN 在特征金字塔网络中引入了从高分辨率到低分辨率和从低分辨率到高分辨率的连接, 以便在不同尺度之间传播信息并促进特征的跨层融合; 其次, BiFPN 使用加权融合来学习不同尺度输入特征信息的重要性, 并对重要的特征信息进行融合, 从而调节了不同尺度特征图的贡献度, 增强了模型对不同尺度目标的检测能力。总的来说, BiFPN 能够更好地学习和利用不同尺度的特征信息, 从而改善了目标检测任务的性能。BiFPN 加权特征融合公式为

$$O = \sum_i \frac{W_i}{e + \sum_j W_j} I_i \quad (1)$$

式中: O 为输出值; W_i 和 W_j 为可学习权重, 是特征图在不同层级的融合过程中的权重系数; e 为极小值学习率, 用于约束数值的震荡; I_i 为特征图。该方法通过类似于归一化指数函数 (Softmax 函数) 的操作, 将每个归一化权重调整至 $0 \sim 1$, 这种基于 Softmax 函数的融合方式展现出了与 Softmax 函数相似的学习特性和准确度, 同时具备快速高效的训练优势。

1.2 加入注意力机制

为了提高电力设备异常检测任务的准确性, 加

入了一种三支结构的 TA 注意力机制。该注意力机制通过捕获不同维度之间的交互作用来计算注意力权重, 同时还建立了维度之间的依赖关系, 可以更有效地编码通道和空间信息, 并且保持较低的计算成本。TA 注意力机制既考虑了维度间复杂的交互, 又优化了计算效率, 从而提高了模型的性能^[18]。其结构如图 2 所示。

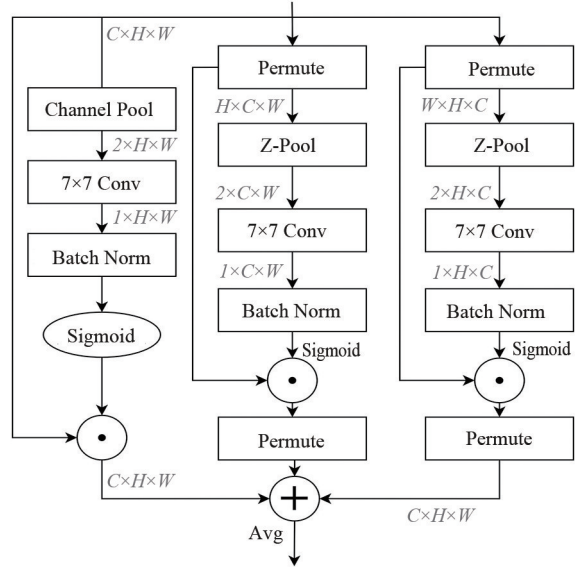


图 2 TA 网络结构

图 2 中, 从左往右第 1 条分支为空间注意力计算分支, 该分支首先将输入特征经过通道池化处理, 特征图形状大小发生变化, 转换为 $2 \times H \times W$ 的大小; 然后, 通过 Conv 层和 Batch Norm 层, 并由激活函数处理; 最后, 将注意力权重与原始特征图相乘, 使其恢复到与输入特征图相同的维度^[19]。第 2 条分支的操作是对通道 C 和空间 W 维度进行交叉捕捉; 第 3 条分支的操作是对通道 C 与空间 H 维度进行交叉捕捉。第 2 条和第 3 条分支与第 1 条分支操作类似, 但在其中加入了组合池化 (Z-Pool) 技术, 它结合了最大池化和平均池化的优点, 从而增强了特征提取的能力。最后, 将 3 个分支结果进行相加求平均后输出。TA 注意力机制通过这种方式实现了对各个通道信息的有效利用, 并促进了通道与空间之间的交互, 显著提升了对图像信息的综合利用效率。改进后的 YOLOv5s 网络结构如图 3 所示。

1.3 NMS 改进

原始网络中采用的是 NMS 算法用来筛选预测框, 其主要是抑制冗余的预测框的重叠度, 如果重叠度高于一定阈值, 则将该候选框删除。这样就可以

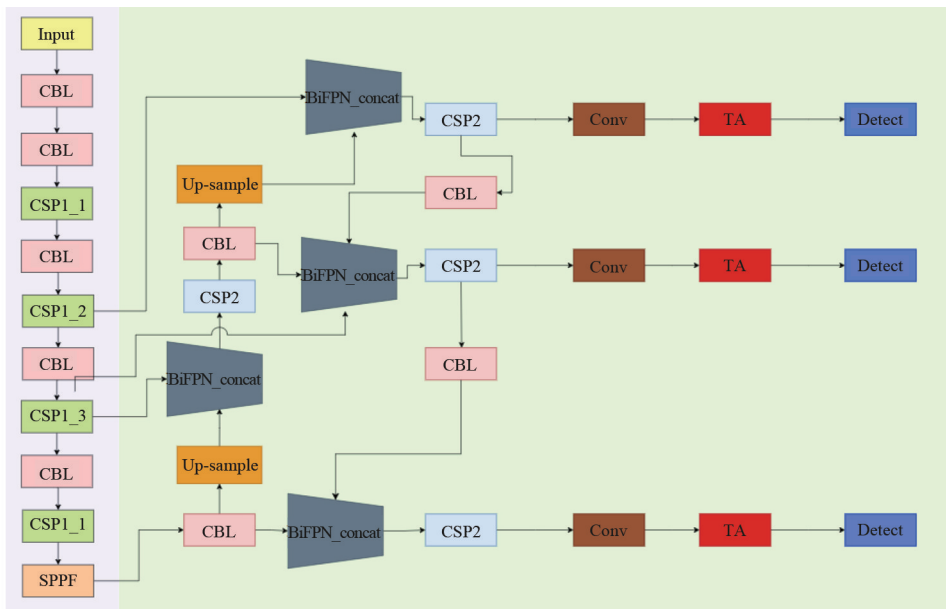


图 3 改进后的 YOLOv5s 网络结构

过滤掉多余的候选框,确保每个目标只被保留一个最具代表性的候选框。因此,NMS 存在一定的局限性,特别是在两个目标相互靠近并有重叠的情况下,仅仅通过筛选掉得分较低且重合度较高的框,可能会引发遗漏检测的问题。而由于绝缘子数据集密集,并且异常类型之间距离很近导致漏检这个问题引入 Soft NMS,该方法与传统 NMS 方法相比,区别在于它不会直接把交并比(intersection over union, IoU)超出特定阈值的边框得分设置为 0,而是通过减少这些边框的得分来处理。在应用 Soft NMS 时,一旦选出一个参考边框,当其他的预测边框的 IoU 超过了设定的阈值,这种算法不会简单地将它们剔除,而是选择性地通过降低其置信度来减弱它们的影响力。这样的处理手段有助于保留那些可能被错误丢弃的有效检测,从而在复杂场景下提升了目标检测的性能和可靠性。然后保留置信度最高的检测框,并将次高的检测框作为新的基准。按照这种循环方式,最终得到一组经过综合筛选的最优预测框,其数学表达式为

$$s_i = \begin{cases} s_i, & i_{ou}(M, b_i) < N_t \\ s_i(1 - i_{ou}(M, b_i)), & i_{ou}(M, b_i) \geq N_t \end{cases} \quad (2)$$

式中: M 为得分较高的候选先验框; b_i 为要处理的候选先验框; N_t 为设定的阈值; i_{ou} 为衰减高分的候选先验框与前一帧候选先验框的重叠分数; s_i 为剩余的第 i 个候选先验框的分数。

2 实验数据处理

2.1 数据集处理

目前,关于电力设备异常缺陷的数据集相对较为稀缺,主要来源于现场拍摄的图片以及变电站智能巡检系统历年来保存的图片人工筛选后得到。数据集缺陷类型涵盖了陶瓷绝缘子破损、陶瓷绝缘子闪络、表计破损、表计模糊、设备漏油 5 类情况,其中绝缘子原始图像仅为 422 张。由于绝缘子缺陷的尺寸较小,考虑到数据量的限制可能会影响网络模型训练的效果,因此对绝缘子数据进行了数据扩充。具体的图像增强方法如下:

- 1) 翻转:对图片进行翻转。
- 2) 亮度:对图片的亮度进行变换。
- 3) 噪声:对图片进行高斯噪声添加。

通过数据增强后最终获得 3541 张包含 5 种缺陷的电力设备异常数据集,其中绝缘子数据图片 1688 张,表盘数据图片 1064 张,漏油数据图片 789 张。在网络训练前将数据集按照训练集、测试集、验证集以 7:2:1 的比例划分。

2.2 数据标注

采用了 LabelImg 工具对电力设备图像数据集进行标记,通过人工标注的方式对数据集进行标签标注。由于数据集中的图像特点是密集分布,其中包括尺寸较小的破损和闪络异常目标,以及这些异常目标之间距离相近的情况,因此在进行异常类型

标注时需要格外细致。标注过程完成之后,每一幅图像都会生成一个与其文件名相匹配的.xml 文件,该文件记录了被标注目标的名称(name)和该目标左上角及右下角的坐标信息。标注标签为:陶瓷绝缘子损坏(jyz_sh),缺陷数量为 1260;陶瓷绝缘子闪络(jyz_sl),缺陷数量为 2723;表计模糊(bj_mh),缺陷数量为 459;表计破损(bj_ps),缺陷数量为 605;设备漏油(ly),缺陷数量为 1318。各类缺陷的样本如图 4 所示。



(a) 绝缘子闪络 (b) 绝缘子破损

(c) 表计模糊 (d) 表计破损 (e) 设备漏油

图 4 异常类型样本

3 实验结果及分析

3.1 训练参数

实验的软件环境为 Ubuntu 16.04, Pytorch 2.0.1, Torchvision 0.15.2, CUDA 10.2, 编程语言为 Python, 实验硬件环境如表 1 所示。训练使用余弦学习率衰减方法使模型精确收敛,最大学习率为 0.01,最小学习率为 0.000 1, batch size 设置为 8, epoch 设置为 100。

表 1 实验硬件环境

硬件名称	型号	数量
CPU	IntelCore i7-6800k	1
内存/GB	31.3	1
显卡	GeForce GTX 1080Ti	1
硬盘/GB	520	1

3.2 评价指标

选择使用训练后模型检测的交并比 IoU 精确率、召回率 R 、单类别平均精度值 A_p 、平均精度 m_{AP} 作为模型检测精度的评价指标^[18],其计算公式为

$$I_{oU} = \frac{A \cap B}{A \cup B} \quad (3)$$

$$P = \frac{T_p}{T_p + F_p} \quad (4)$$

$$R = \frac{T_p}{T_p + F_N} \quad (5)$$

$$A_p = \int_0^1 P(r) dr \quad (6)$$

$$m_{AP} = \frac{1}{n} \sum_{i=1}^n A_{p_i} \quad (7)$$

式中: A 为实际的边框; B 为模型预测出的边框; T_p 为真正例的数量,即那些正确被识别为正例的情况; F_p 为假正例的数量,即错误地将负例识别为正例的情况; F_N 为假负例的数量,即那些错误地被判定为负例的正例; A_p 为根据 $P(r)$ 即精确率-召回率曲线计算的面积; m_{AP} 为不同类别中 A_p 值的平均值,它的高低直接反映了检测模型整体的精确性水平, m_{AP} 值越高意味着模型的准确度越高,下面的实验中采用交并比为 0.5 时的平均精度来评价,表示为 $mAP@0.5$ 。

3.3 消融实验

为验证所提出的几种改进方法是否有效,使用所获得数据集进行消融实验,分别测试每种改进以及混合使用的效果。实验结果如表 2 所示,“√”表示模块混合改进,可用于证明各添加模块的正面影响。通过实验结果可知,原始网络结构的精确率为 88.3%,召回率为 89%,平均精度为 88.7%。以此为基准,比较改进方法的有效性。实验 1 是将原始的 Yolov5s 中 Neck 的特征融合方式替换为 BiFPN 结构。实验 2 是在原始基础模型中加入 TA,引入这种注意力机制能够在提取物体特征信息的过程中,更加有效地筛选输出通道,从而传递更有价值的信息,以此来提升检测的准确度。实验 3 是将原始模型中 NMS 改进为 Soft NMS,由于绝缘子缺陷数据较为密集,破损绝缘子及闪络绝缘子与正常绝缘子之间距离较小,因此引入 Soft NMS 解决该问题。实验 4 是同时加入了 BiFPN 结构和 TA。实验 5 是加入了 TA 以及替换为 Soft NMS。实验 6 是对模型加入了 BiFPN 结构以及替换为了 Soft NMS。实验 7 是同时将 3 种方式一起改进原始模型。改进后的网络结构有效提升了各类设备异常的检测精度。由消融实验结果可知,3 种改进方式对原网络检测精度均有正面影响,并且 3 种改进方式同时加入到模型中时使最终的电力设备异常检测效果达到最好。

表 2 YOLOv5s 改进模型的消融实验结果比较

模型	BiFPN	TA	Soft NMS	P/%	R/%	mAP@0.5/%
原模型				88.3	89	88.7
实验 1	✓			88.7	91	91.8
实验 2		✓		90.7	97	91.9
实验 3			✓	91.1	97	90.9
实验 4	✓	✓		90.4	97	92.5
实验 5		✓	✓	90.4	92	92.2
实验 6	✓		✓	92.0	92	91.9
实验 7	✓	✓	✓	90.0	93	92.8

3.4 对比实验

3.4.1 与主流模型对比分析

为了验证模型的有效性,将模型和其他主流检测模型同时以相同的超参数进行训练,用上述评价指标进行对比,对比模型包括 SSD、YOLOv4、faster R-CNN、YOLOv5s,结果见表 3。可以看出与其他主流算法相比,所提模型检测精度最高,平均精度 m_{AP} 达到了 92.8%,特别是相较于原始 YOLOv5s 模型,其 m_{AP} 值提高了 4.1 个百分点。同时对比其他模型,单个类别的检测精度也是最好,特别是相较于

原始 YOLOv5s 模型,所提模型陶瓷绝缘子闪络、陶瓷绝缘子损坏、设备漏油异常、表计破损异常、表计模糊异常等类型的 A_p 值分别提升了 4.2、4.5、4.6、1.3、5.5 个百分点。该对比实验结果验证了所提模型对于变电站设备异常检测精度提升的有效性。

表 3 模型对比实验结果

算法	mAP@0.5/%	A_p				
		jyz_sl	jyz_sh	ly	bj_ps	bj_mh
SSD	79.4	75.2	82.4	79.1	81.3	78.9
YOLOv4	81.2	78.1	81.6	87.0	82.8	76.4
YOLOv5s	88.7	86.5	91.7	91.9	89.9	83.6
faster R-CNN	79.9	79.2	83.1	76.9	82.1	78.4
所提算法	92.8	90.7	96.2	96.5	91.2	89.1

3.4.2 与基线模型对比分析

将 YOLOv5s 基线模型与改进的模型进行详细对比,结果如图 5 所示。在检测结果中,基线模型将第 1 组的表计破损错误识别成表计模糊,还将第 4 组中的绝缘子损坏位置检测错误。在加入 BiFPN

原图

原始模型检测结果

改进后的模型检测结果




图 5 检测效果对比

特征融合模块后,由于该模块能够对不同尺度的特征进行加权融合,避免了特征融合过程中的信息丢失,从而使模型的目标误检率和漏检率有所下降。在第 2 组结果中,加入 Soft NMS 解决密集目标之间距离过近导致检测精度低的问题,提高了检测精度。在第 3 组中,原始基线模型对绝缘子破损发生了漏检,并发生检测框重复的错误,在模型中加入了 TA 机制使得模型更好地关注目标特征,降低了漏检率。如图 5 所示,所提模型在电力设备异常目标检测中效果优于原始基线模型。

3.5 DOTA 数据集对比试验

为了验证模型的泛化性,实验采用 DOTA^[27] 数据集来训练和评估模型,DOTA 数据集 v1.0 共收录 2806 张 4000×4000 的图片,总共包含 188 282 个目标。数据集中共有 15 个类别如表 4 所列。将原始模型和改进后的模型在相同的参数设置和硬件环境下进行训练。通过对训练结果的分析,评估所提算法的检测能力。由表 4 结果可以看出,所提算法在 DOTA 数据集上相较于基线模型,mAP@0.5 指标从 76% 提升到了 78.8%。

表 4 DOTA 数据集各类别目标 AP 对比

类别	YOLOv5	所提算法
小型车辆	0.807	0.810
大型车辆	0.883	0.897
飞机	0.939	0.951
储罐	0.702	0.707
轮船	0.900	0.910
港口	0.867	0.881
田径场	0.396	0.547
足球场	0.458	0.542
网球场	0.971	0.976
游泳池	0.822	0.835
棒球场	0.847	0.847
环形交叉路口	0.505	0.602
蓝球场	0.823	0.834
桥梁	0.585	0.608
直升机	0.886	0.874
所有类别	0.760	0.788

再进一步对所提改进方法和原始模型在 DOTA 数据集上的目标检测结果进行展示。从图 6 的结果可以看出,在第 1 组和第 2 组对比结果中,原始模型将原本属于轮船 (ship) 和足球场 (soccer-ball-field) 的目标漏检,而所提改进方法能够正确检测,其相较于原始基线模型降低了漏检率;在第 3 组和第 4 组对比结果中,原始模型将不属于网球场 (tennis-court)

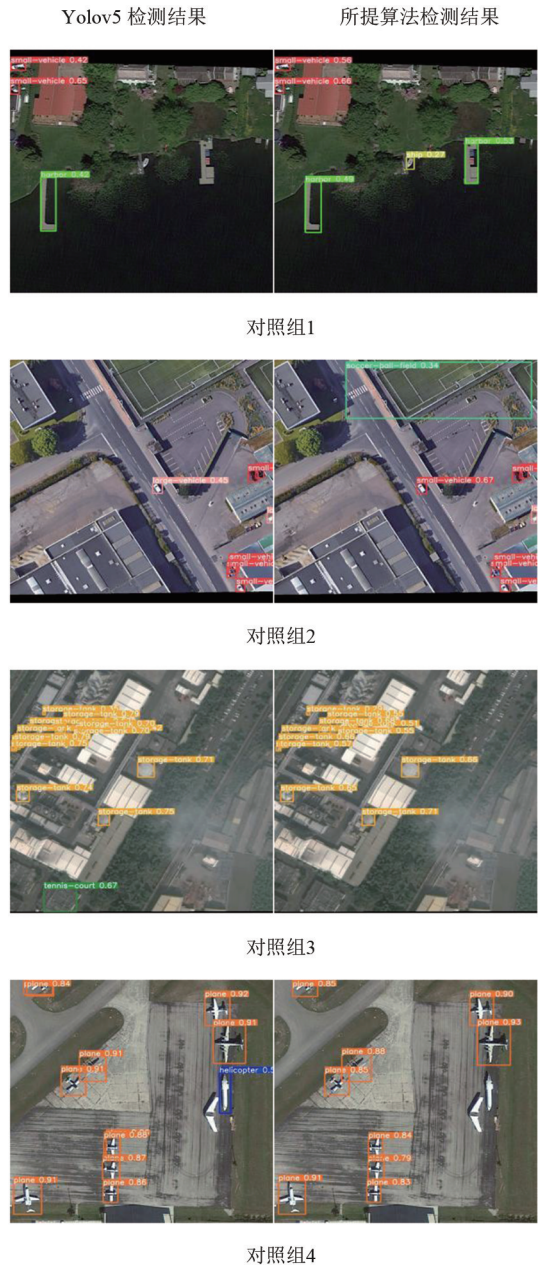


图 6 DOTA 数据集可视化结果对比

和直升机 (helicopter) 类别的目标错检,而所改进方法没有发生错检结果。所提改进方法相较于原始基线模型降低了错检率。综上,改进方法在一定程度上能够降低漏检和错检率,从而提高了检测精度。

4 结 论

上面针对电力设备异常目标尺度大小不一致的问题,将原始模型中特征融合模块改进为 BiFPN 特征融合模块,使其能够适应不同的输入分辨率和目标大小,可用于各种不同的目标检测任务,在不增加过多计算成本的情况下提高了检测精度。将 TA 注

注意力机制融合到 YOLOv5s 模型中,有效提升了模型在复杂场景下的检测性能。最后,针对数据集中绝缘子异常目标之间距离过近容易漏检的问题,引入 Soft NMS 替换原本的 NMS,提高了检测精度。从实验验证结果可以看出,改进后的电力设备异常检测模型相对于原始检测模型检测精度、精确率、召回率均有所提升,因此,改进模型能够更好地在智能巡检平台上实现对变电站设备异常的实时检测。

参考文献

- [1] 丁江桥,文屹,吕黔苏,等.基于时间序列和神经网络的电力设备状态异常检测方法[J].电测与仪表,2024,61(2):185-190.
- [2] 马学森,马吉,蒋功辉,等.基于注意力机制和多尺度特征融合的绝缘子缺陷检测方法[J].南京大学学报(自然科学),2022,58(6):1020-1029.
- [3] GU R, WANG G T, SONG T, et al. CA-Net: Comprehensive attention convolutional neural networks for explainable medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2021, 40(2):699-711.
- [4] 王道霖,张世恒,袁斌霞,等.基于改进 YOLOv5 的轻量化玻璃绝缘子自爆缺陷检测研究[J].高电压技术,2023,49(10):4382-4390.
- [5] BOCHKOVSKI A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[EB/OL]. [2023-04-13]. <https://doi.org/10.48550/arXiv.2004.10934>.
- [6] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications[EB/OL]. [2023-04-13]. <https://doi.org/10.48550/arXiv.1704.04861>.
- [7] 陈奎,刘晓,贾立娇,等.基于轻量化网络与增强多尺度特征融合的绝缘子缺陷检测[J].高电压技术,2024,50(3):1289-1300.
- [8] MA N N, ZHANG X Y, ZHENG H T, et al. Shufflenet V2: Practical guidelines for efficient CNN architecture design[C]//European Conference on Computer Vision (ECCV), September 8-14, 2018, Munich, Germany. 2018:122-138.
- [9] LIU X Y, JIANG H, CHEN J, et al. Insulator detection in aerial images based on faster regions with convolutional neural network[C]//2018 IEEE 14th International Conference on Control and Automation (ICCA), June 12-15, 2018, Anchorage, USA. IEEE, 2018:1082-1086.
- [10] 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(增刊1):302-310.
- [11] 尚明鹏,周敏,陈燕军,等.融合 BiFPN 与 YOLOv5 网络的工厂火灾检测[J].智能计算机与应用,2023,13(10):137-141.
- [12] 张晶,吕京国,张济勇,等.边缘约束的遥感影像建筑物施工变化检测[J].测绘科学,2023,48(12):130-142.
- [13] 赵云龙,田生祥,李岩,等.基于注意力模型和 Soft-NMS 的输电线路小目标检测方法[J].电子科技大学学报,2023,52(6):906-914.
- [14] 齐冬莲,韩译锋,周自强,等.基于视频图像的输变电设备外部缺陷检测技术及其应用现状[J].电子与信息学报,2022,44(11):3709-3720.
- [15] 严宇,张宏伟,肖奕,等.基于轻量级卷积网络的电力绝缘子视觉检测[J].电力科学与工程,2022,38(12):38-46.
- [16] 叶树芬,施振华,苏成悦,等.基于 YOLOv5 的电力线和杆塔实时检测算法研究[J].计算机测量与控制,2022,30(11):77-84.
- [17] TAN M X, PANG R M, LE Q V. Efficientdet: Scalable and efficient object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 13-19, 2020, Seattle, USA. IEEE, 2020:10781-10790.
- [18] MISRA D, NALAMADA T, ARASANIPALAI A U, et al. Rotate to attend: Convolutional triplet attention module[C]//2021 IEEE Winter Conference on Applications of Computer Vision(WACV), Jan.3-8, 2021, Waikoloa, USA. IEEE, 2021:3139-3148.
- [19] ZHANG T, ZHANG Y N, XIN M L, et al. A lightweight network for small insulator and defect detection using UAV imaging based on improved YOLOv5[J]. Sensors,2023,23(11):5249.
- [20] 王瑞婷,王海燕,陈晓,等.基于混合卷积与三重注意力的高光谱图像分类网络[J].智能系统学报,2023,18(2):260-269.
- [21] 蔡嘉磊,茅智慧,李君,等.基于深度学习的目标检测算法与应用综述[J].网络安全技术与应用,2023(11):41-45.
- [22] JIANG B R, LUO R X, MAO J Y, et al. Acquisition of localization confidence for accurate object detection[C]//European Conference on Computer Vision (ECCV), September 8-14, Munich, Germany.2018:816-832.
- [23] 苟军年,杜慷慷,王世铎,等.轻量化特征融合的 CenterNet 输电线路绝缘子自爆缺陷检测[J].北京

