

基于改进 YOLOv5 的轻量化绝缘子表面缺陷检测

郭雨*, 马美玲, 黎大林

上海理工大学机械工程学院, 上海 200093

摘要 针对无人机检测缺陷绝缘子时,存在目标特征不明显、小目标检测效果差、无法同时满足检测速度和精度的问题,提出一种基于改进 YOLOv5 的绝缘子缺陷检测算法。首先,针对目标特征不明显的问题,将 ConvNeXt 网络应用到 YOLOv5 主干网络中,以加强网络特征提取能力;其次,针对图像中的小目标特征,在主干网络中引入坐标注意力机制,提高对小目标的检测精度;然后,对改进模型进行剪枝操作,剪去模型中冗余的通道,从而减少模型参数量,使模型更加轻量化。实验结果表明:所提算法在绝缘子缺陷数据集 IDID 上的平均精度均值达到 93.84%,较原始算法提升了 3.4 个百分点;检测速率达到 166 frame/s,较原算法速率提升了 69.4%,可以满足对输电线路实时检测的要求。

关键词 绝缘子缺陷检测; YOLOv5; 轻量化; ConvNeXt; 注意力机制

中图分类号 TP391.4 文献标志码 A

DOI: 10.3788/LOP231032

Detection of Surface Defects in Lightweight Insulators Using Improved YOLOv5

Guo Yu*, Ma Meiling, Li Dalin

College of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract Herein, an improved insulator defect-detection algorithm, YOLOv5, is proposed to overcome the shortcomings, including inconspicuous target features and poor detection of small targets when detecting trapped insulators using unmanned aerial vehicles, which cannot satisfy both detection speed and accuracy. First, ConvNeXt is applied to the YOLOv5 reference network to improve its ability to extract the features of obscure targets. Moreover, a coordinate attention mechanism is introduced into the reference network to improve its detection accuracy with respect to small targets in an image. Then, the improved model is pruned to eliminate its redundant channels, thus reducing the number of model parameters and making the model more lightweight. The experimental results show that the improved model achieves an average detection accuracy of 93.84% with respect to the insulator-defect dataset IDID, which is 3.4 percentage points higher than the accuracy achieved by the original algorithm. Moreover, the highest detection rate achieved by the proposed algorithm is 166 frame/s, which is 69.4% higher than that achieved by the original algorithm. These results prove that the improved algorithm meets the requirements of real-time transmission-line detection.

Key words insulator defect detection; YOLOv5; light weighting; ConvNeXt; attention mechanism

1 引言

随着国民经济的快速发展和现代化进程的推进,电力网络也在不断扩大规模,电力线路的安全巡检工作面临越来越大的挑战^[1]。绝缘子作为输电线路中防范事故发生至关重要的一环,电力操作人员对于绝缘子的日常维护自然必不可少^[2]。高压输电线路中的绝缘子是输电线路中非常重要的部件,如果挂网绝缘子

出现故障,将极大地威胁高压电网的安全。由于暴露于大气中并长期工作在强电场、风雨雪雾、化学物质腐蚀等恶劣环境中,再加上本身用料、制作工艺水平、人为破坏等因素,绝缘子难以避免地会出现故障^[3]。而传统直升机巡检不但成本高且效率低。因此,电力巡检向自动化和智能化发展是必然趋势。输电线路中的绝缘子处于复杂的环境背景下,无人机巡检不仅效率高,还能保证人员安全性,可实现自动化、智能化作业,

收稿日期: 2023-04-06; 修回日期: 2023-05-08; 录用日期: 2023-05-15; 网络首发日期: 2023-05-25

基金项目: 上海市青年科技英才扬帆计划(22YF1429500)

通信作者: *1240366119@qq.com

大幅提升电网运行的可靠性,保障电网的运行安全^[4]。因此基于深度学习的无人机巡检方式研究具有重要意义。

深度学习成长迅速,目标检测也是一个研究热点。目前目标检测算法主要包括单阶段目标检测和两阶段目标检测^[5]。单阶段算法只需对图片处理一次就能获得目标的分类和位置信息,运行速度较快,可以应用于对实时性要求较高的场景^[6]。代表的算法有 Redmon 等^[7-9]提出的 YOLO 算法、Liu 等^[10]提出的 SSD 算法等。郑伟等^[11]设计了一种改进的 YOLOv4 输电线关键部件实时检测算法,通过添加自适应路径融合网络来融合更多的位置信息和语义信息,提高了多尺度目标的检测精度,减少了目标的误报率。王朝硕等^[12]通过改进 SSD 识别输电线路电力部件,该算法能够高效地检测和辨识电力部件,而且识别精度高、反应速度快。另一种是两阶段检测算法,又称基于候选区域(region proposal)的目标检测。代表的算法有 Girshick 等^[13]提出的 R-CNN 和 Fast R-CNN^[14]以及 Ren 等^[15]提出的 Faster R-CNN。黄文琦等^[16]通过 Faster R-CNN 对来自不同场景的百量级绝缘子图像进行实验,验证了 Faster R-CNN 模型在百量级图像中的可用性和鲁棒性。程海燕等^[17]基于 Faster R-CNN 对航拍图像中的绝缘子进行识别。目前,有关无人机巡检绝缘子缺陷的文献相对较少,大多是对绝缘子进行识别的,无法直接对绝缘子缺陷进行检测,而且当待检测目标处于复杂背景下时,由于小目标像素少,目标特征较小且背景复杂^[18],算法难以识别缺陷目标,并且检测速度有待提升,无法满足实时检测的要求。

因此,针对图像中小目标与多尺度目标特征融合造成传统算法难以精准检测的问题,本文提出一种基于改进的 YOLOv5 的轻量化绝缘子缺陷检测算法。本研究所做工作主要包括以下几个方面:1) 为了提升 YOLOv5 的特征提取能力,用 ConvNeXt block^[19]重构主干网络,重构后的网络对于特征不明显的绝缘子缺陷目标有着更好的检测效果;2) 为了提升 YOLOv5 在复杂背景下的小目标检测能力,在 YOLOv5 的主干网络中引入坐标注意力机制(CA)^[20],从而获取更多与目标有关的细节信息,提升模型对于空间布局的鲁棒性;3) 为了使 YOLOv5 模型轻量化,在保证检测精度的同时对模型进行剪枝,减少模型的参数量,进而提升算法的目标检测速度。

2 YOLOv5 模型改进

YOLO 系列是一种单阶段目标检测算法,Wang 等^[21]在 2022 年提出的 YOLOv7 算法,其速度和准确度都超过现有 YOLO 系列的检测器,但考虑到所提算法要应用到无人机上,所以选择稳定性更强的 YOLOv5 算法。YOLOv5 具有快速的运算速度和相对较高的识别准确率,在实际应用中具有广泛的适用性,但是对

于复杂背景下的小目标检测能力较弱,且应用在移动设备时精度和速度无法同时达到要求。基于此,提出一种改进的 YOLOv5 算法,改进模型如图 1 所示。首先,在原始 YOLOv5 模型中采用 ConvNeXt 重建主干网络,用 ConvNeXt block 替换 CSP 模块,解决原主干网络对小目标提取不足的问题;其次,增强网络对小目标的特征融合能力;然后,引入坐标注意力机制提高主干特征提取效率;最后,对模型进行轻量化操作,减少参数量、加快推理速度。

2.1 重构主干网络

YOLOv5 的主干网络使用 BottleneckCSP 结构,BottleneckCSP 结构将输入分成两个分支,一个分支进行残差操作,而另一个分支进行卷积操作,然后将两个分支合并起来,使得输入和输出大小一样。模型有着更多残差结构的同时可更高效进行特征提取,但也随之带来更多的参数量,使模型检测速度较慢,应用受限制,在某些实际的应用场景如移动设备上难以部署。

所提模型运用残差网络的核心思想,并采用 ConvNeXt block 重构 BottleneckCSP 网络。相对于传统的卷积方法,ConvNeXt block 采用深度可分离卷积(DSC)。DSC 可以看作是一个高维的卷积核,每个卷积核仅负责输入特征矩阵中的一个通道,通过将多个这样的卷积核组合在一起,ConvNeXt block 可以保持对输入特征矩阵的全局感知能力,降低了模型参数量,并提高了模型训练速度。ConvNeXt block 结构如图 2 所示。输入首先通过 1 个 DSC,然后经过 2 个 1×1 的卷积核卷积,并使用 GELU 激活函数激活,再用 layer scale 层对输出进行归一化处理,将输出的权重限制在一定范围内,可以避免梯度爆炸和梯度消失问题,并且使模型训练有着较高的稳定性,最后连接一个 drop path 来减少模型参数量。ConvNeXt block 模型不仅提升了绝缘子缺陷目标检测的准确率,也使网络的浮点运算次数降低。

2.2 注意力模型

缺陷绝缘子图像常常用无人机拍摄,通常呈现出背景大、目标小的情况,为了提高对小目标的检测精度和泛化能力,引入 CA 注意力机制,具体如图 3 所示。CA 还可以通过动态调整注意力权重,进一步提升模型的性能和适应性,使其更加灵活有效。

CA 注意力首先对水平和垂直方向进行平均池化操作,整合两者的特征信息并对其进行卷积。特征图的第 c 个通道可表示为

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

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j \leq H} x_c(j, w). \quad (2)$$

随后通过批量归一化和非线性激活函数获得有效特征,之后沿着宽度和高度进行 split 操作,并分别做卷

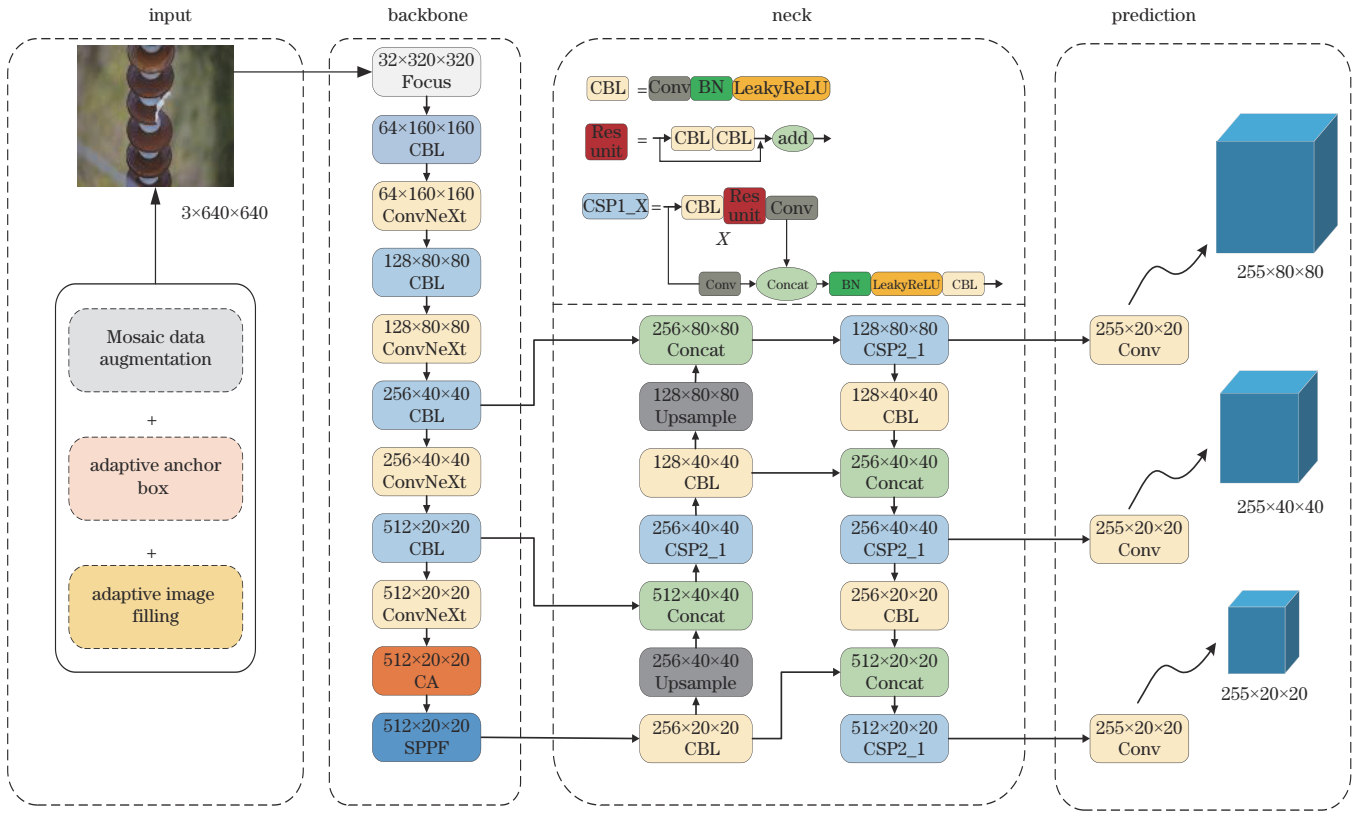


图 1 改进 YOLOv5 模型

Fig. 1 Improved YOLOv5 model

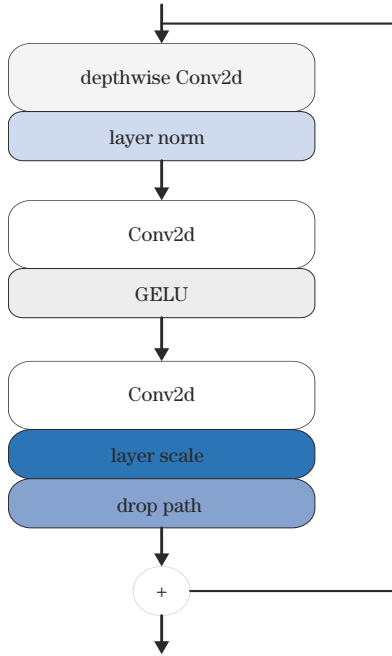


图 2 ConvNeXt block 结构图

Fig. 2 ConvNeXt block structural diagram

积处理,得到和输入具有相同通道数的特征图,再经过 Sigmoid 激活,最后重新加权获得宽度和高度方向的注意力权重:

$$f = \delta \{ F_1 [z^h, z^w] \}, \quad (3)$$

$$g^h = \sigma \{ F_h (f^h) \}, \quad (4)$$

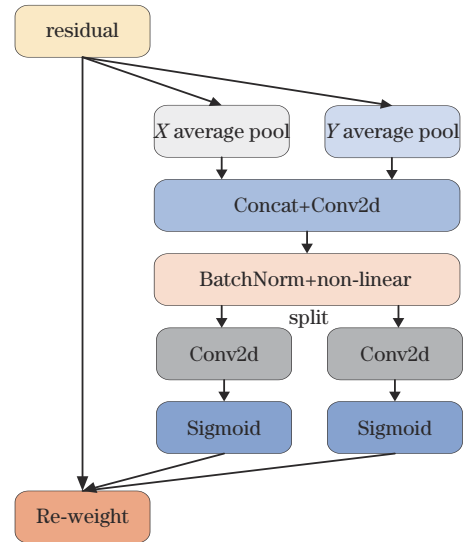


图 3 CA 注意力模块

Fig. 3 CA attention module

$$g^w = \sigma [F_w (f^w)], \quad (5)$$

$$y_c(i, j) = x_c(i, j) \times g^h(i) \times g^w(j), \quad (6)$$

式中: δ 代表下采样操作; F_1 代表 1×1 卷积核; f 代表得到的特征图, f^h 和 f^w 代表水平和垂直两个维度的特征图; σ 代表 Sigmoid 激活函数; g^h 和 g^w 代表特征图在水平和垂直方向的注意力权重; y_c 代表最终的注意力权重。

2.3 模型轻量化设计

为了使 YOLOv5 有着更快的检测速度,以达到实时检测绝缘子缺陷的效果并得到一个轻量化的 YOLOv5 模型,对 YOLOv5 模型进行剪枝操作。

深度神经网络中存在冗余神经元,剪枝算法可以使用不同的标准或方法对这些神经元进行裁剪。这种算法可以最大程度压缩空间、减少存储空间并提高速度,同时又不会损失模型的精度。在 YOLOv5 模型中,为了加快深度神经网络的训练速度,提高模型的鲁棒性和泛化性能,都会对数据进行批量归一化层(BN)处理,从而缓解网络内部协变量偏移问题,使得神经元之间的分布更加稳定,BN层的计算公式如下:

$$y_i = \gamma \cdot \hat{x}_i + \beta, \quad (7)$$

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}, \quad (8)$$

式中: x_i 代表输入; y_i 代表输出; μ_B 代表均值; σ_B 代表标

准差; γ 代表缩放因子; β 代表位移因子; ϵ 是很小的非零常数。

改进的 YOLOv5 训练后,网络的缩放因子呈现近似正态分布,只有少数缩放因子近似为 0,剪枝过程如图 4 所示,这使得对训练后的网络模型进行裁剪变得困难,因此,在进行模型裁剪之前,对 BN 层的参数加入 L1 正则化约束,可以促使网络模型进行稀疏化训练,即稀疏训练。在改进后的损失函数中,加入了 L1 正则化项,以惩罚网络中权重的绝对值之和,从而鼓励模型在训练过程中产生更多的零值权重,使模型更加稀疏,损失函数公式如下:

$$L = \sum_{(x,y)} l[f(x,W),y] + \lambda \sum_{\gamma \in \Gamma} g(\gamma), \quad (9)$$

式中: W 代表权重值; f 代表模型的输出; y 表示样本标签值; l 表示正常训练模型的损失函数; $g(\gamma)$ 代表对 γ 的 L1 正则化约束; λ 代表两个求和项的可变参数。

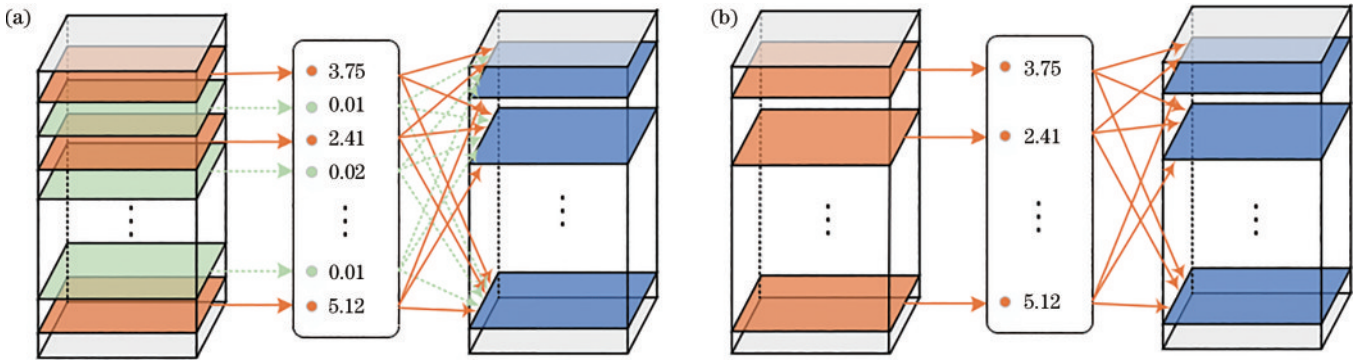


图 4 剪枝过程。(a)剪枝前;(b)剪枝后

Fig. 4 Pruning process. (a) Before pruning; (b) after pruning

3 实验结果与分析

3.1 实验环境和数据集

本实验的软硬件平台配置参数如表 1 所示。采用的数据集为网络开源 IDID 数据集,图片全为无人机实地拍摄而得,数据集中共有 1688 张破损绝缘子和闪络绝缘子,为了与输电线路保持安全距离,无人机拍摄距离较远,所以航拍到的绝缘子表面缺陷目标较小。航拍得的图片像素大约都为 4000 pixel×3000 pixel,绝缘子缺陷的目标像素都在 100 pixel×100 pixel 以内,而 YOLOv5 会把图片自适应成 640 pixel×640 pixel 大

表 1 软件和硬件平台配置参数

Table 1 Software and hardware platform configuration parameters

Environment	Configure
GPU	NVIDIA GeForce RTX3050
CPU	Intel Core i5-11400H@2.7GHz
operating system	Windows 10
framework	PyTorch 1.9.0
CUDA	cuda 11.1

小。YOLOv5 算法中新增自适应锚定框,可以对预设好的锚框大小进行更改,所提算法把最小锚框大小改为了 10 pixel×10 pixel,足以满足本研究检测需要。利用 LabelImg 标注工具对数据集进行标注,一共两类,绝缘子破损标注为 broken insulator,闪络标注为 flashover damage。按照 8:2 的比例划分训练集和验证集,训练集用不同的方法和策略来训练不同的模型,可以使用交叉验证技术来比较和选择不同的模型,并挑选出最优的模型。这个过程通过不断地迭代和优化模型,以达到对结果进行准确预测的目的。

3.2 评价指标

为了评估 YOLOv5s 算法对绝缘子缺陷的检测效果,采用精确率(P)、召回率(R)、平均精确率(R_{AP})、平均精确率均值(R_{mAP})、模型大小、模型检测速度(FPS)作为评价指标。当 FPS 达到至少 80 时,才能满足日常的检测需求。各指标的计算公式如下:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (10)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (11)$$

$$R_{mAP} = \frac{1}{C} \sum_{i=1}^C R_{APi}, \quad (12)$$

式中: N_{TP} 表示预测为正例而且实际上也是正例的数量; N_{FP} 表示预测为正例然而实际上却是负例的数量; N_{FN} 表示预测为负例然而实际上却是正例的数量; C 表示检测目标的类别数。

3.3 实验结果与分析

3.3.1 不同主干网络实验对比

针对不同主干网络对 YOLOv5 的影响, 设计 3 种不同主干网络对比实验, 验证 ConvNeXt block 对主干网络的改进效果, 实验结果如表 2 所示。

表 2 不同主干网络对比

Table 2 Comparison of different backbone networks

Model	$R_{mAP}@0.5 / \%$	Model size /MB	FPS
YOLOv5s	90.43	14.1	98
+Ghost	88.71	10.2	108
+C3TR	87.46	20.5	82
+ConvNeXt	93.27	13.6	105

分析表 2 可知, 以 YOLOv5s 为基线 (baseline), 当使用轻量化 Ghost 为主干网络时, 模型大小降低 27.7%, FPS 增大了 10.2%, 减少了参数量并加快了检测速度, 但 R_{mAP} 只有 88.71%, 下降了 1.72 个百分点。当 C3TR 作为主干网络时, R_{mAP} 降低了 2.97 个百分点, 模型也增大了 6.4 MB, 检测速度也下降明显。当使用 ConvNeXt block 作为主干网络时, R_{mAP} 增大了 2.84 个百分点, 模型也降低了 0.5 MB, 减少了参

量, FPS 也增大了 7.1%。可见以 ConvNeXt Block 作为主干网络不仅提高了检测精度而且加快了检测速度, 改进效果明显。

3.3.2 不同注意力机制对比实验

为了验证所提 CA 注意力机制的有效性, 与 4 种主流的注意力机制进行了对比实验, 实验结果如表 3 所示。

表 3 不同注意力机制对比

Table 3 Comparison of different attention mechanisms

Method	$R_{mAP}@0.5 / \%$	Model size /MB	FPS
Baseline	90.43	14.1	98
+SE	90.31	15.3	98
+CBAM	92.26	13.8	103
+ECA	91.75	13.8	99
+CA	93.48	13.2	106

由表 3 可知, 相较于基线, SE 的 R_{mAP} 下降了 0.12 个百分点, 模型大小增大了 1.2 MB, 检测速度没有变化, 而 CBAM 与 ECA 的 R_{mAP} 分别提高了 1.83 个百分点和 1.32 个百分点, 检测精度提升得并不是很明显, CA 的 R_{mAP} 提升了 3.05 个百分点, 检测精度提升明显, FPS 增大了 8.2%, 保持了良好的检测速度, 表明 CA 注意力机制对绝缘子缺陷具有较好的检测效果。

为了更加直观说明 CA 注意力的效果, 用 Grad-CAM 绘制 CA 注意力的前后对比图, 颜色越深代表网络对相关特征的关注度越高, 会更积极提取有效特征, 如图 5 所示。




图 5 CA 前后对比图。(a)原图;(b)加入前;(c)加入后

Fig. 5 Comparison diagrams before and after CA. (a) Original image; (b) before joining; (c) after joining

3.3.3 不同轻量级算法对比实验

为确保模型在修剪过程中不被过度裁剪以及找到最合适的修剪率, 图 6 是稀疏训练前后的对比图, 在训练到 50 次时, 缩放因子稳定下来, 接着确定剪枝率大小, 分别设置 40%、50%、60%、70% 的剪枝率, 测试结果如表 4 所示。随着剪枝比例的增加, 检测精度会出现不同程度的下降。剪枝率为 40% 时, 检测精度最高, 但模型大小最大, 达到 6.8 MB, 检测速度也最慢,

为 137 frame/s。当剪枝率分别为 60%、70% 时, 虽然模型最小, FPS 最大, 但其检测精度相对较低。而剪枝率分别 50% 时, 虽然精度不是最高, 但较大程度地保持检测精度又提高了检测速度。

为了进一步验证所提剪枝模型相对于其他轻量化网络的优越性, 将其与 YOLOv3-tiny、YOLOv4-tiny、YOLOX-nano 等算法进行了实验对比, 结果如表 5 所示。




图 6 稀疏训练前后对比图。(a)稀疏训练前;(b)稀疏训练后

Fig. 6 Comparison before and after sparse training (a) Before sparse training; (b) after sparse training

表 4 剪枝率对比

Table 4 Comparison of pruning rates

Pruning rate / %	$P / \%$	$R / \%$	$R_{mAP}@0.5 / \%$	Model size / MB
40	93.71	90.19	94.33	6.8
50	92.56	91.71	93.84	5.4
60	89.82	85.94	89.71	4.5
70	82.59	79.24	81.37	3.3

表 5 轻量化网络对比

Table 5 Lightweight network comparison

Model	$R_{mAP}@0.5 / \%$	Model size / MB	FPS
YOLOv3-tiny	84.37	36.2	69
YOLOv4-tiny	86.93	23.7	75
YOLOX-nano	89.71	24.8	71
Improved YOLO v5	93.84	5.4	166

由表 5 数据可知, YOLOv3-tiny、YOLOv4-tiny 的 R_{mAP} 分别为 84.37% 和 86.93%, 检测精度较低, 检测速率分别为 69 frame/s 和 75 frame/s, 相比剪枝后的 YOLOv5 分别下降 58.4% 和 54.8%, 以至于不能满足无人机实时检测的要求。YOLOX-nano 的 R_{mAP} 达到 89.71%, 相对于前两者精度有所提升, 但是模型大小和检测时间分别比 YOLOv4-tiny 增加 1.1 MB 和 0.8 ms, 改进 YOLOv5 对绝缘子缺陷的 R_{mAP} 达到 93.84%, 对小目标有着较好的检测能力, 检测速率也到达 166 frame/s, 可满足正常检测需求。

3.3.4 所提模型与其他模型对比实验

为了全面比较不同算法的检测性能, 在相同的配置环境下使用相同的训练集和验证集, 与 Faster R-CNN、YOLOv3、YOLOv5 模型进行比较, 比较结果如图 7 所示。

Faster R-CNN 能够检测出大部分目标, 但存在漏检和检测精度低问题; YOLOv3 网络在密集情况下的漏检较多, 且有误检和精度低等缺点; YOLOv5 网络能够识别大多数目标, 但存在精度相对偏低的; 所提改进 YOLOv5 算法能够准确识别并定位出绝缘子破损和闪络, 置信度较高且模型的泛化能力更强; 而在改进 YOLOv5 算法基础上进行剪枝的模型也能出色地检测出全部目标。以上对比实验说明改进 YOLOv5 模型对背景复杂、小目标有着很好的检测效果。

不同算法检测结果对比如表 6 所示。由表 6 可知, 所提改进 YOLOv5 的 R_{mAP} 最高, 达到 93.84%, 优于其他目标检测算法, 改进 YOLOv5 相对于原始 YOLOv5 算法, R_{mAP} 提升 3.41 个百分点, 比 Faster R-CNN 提升 5.78 个百分点, 而 SSD 的 R_{mAP} 最低, 只有 81.45%。在模型大小方面, 剪枝 YOLOv5 模型占用空间最少, 只有 5.4 MB, 比 YOLOv5 下降了 61.7%, 有显著的提升, 而且检测速率也最快, 达到 166 frame/s, Faster R-CNN 算法最慢, 速率只有 18 frame/s, 不能满足实时性检测需要。因此所提轻量化网络可部署到无人机上, 能够满足电力巡检的精度与速度要求。

3.3.5 消融实验

上述实验结果表明改进后的模型可取得较好的检测精度, 为了进一步验证模型中的 ConvNeXt block、CA 注意力模块及剪枝对原算法的提升效果, 设计 5 组消融实验, 实验结果如表 7 所示。

由表 7 数据可知, 以原始 YOLOv5 算法为基础, 依次添加 ConvNeXt block、CA 注意力模块和剪枝操作。通过对原算法添加 ConvNeXt block 模块, 增强网络的特征提取能力, R_{mAP} 提升 2.84 个百分点; 在原算法上添加 CA 注意力, 可获取到更多与目标有关的细节信息, 抑制一些与检测目标无关的信息, R_{mAP} 提升了 3.05

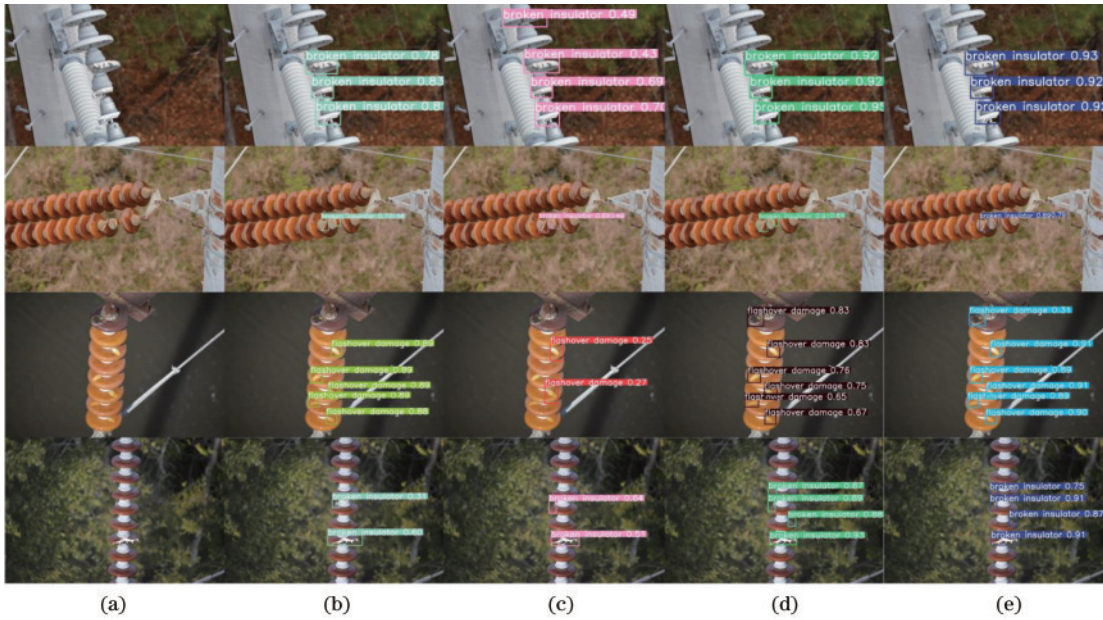


图 7 不同目标检测算法对比图。(a)原图;(b)Faster R-CNN;(c)YOLOv3;(d)YOLOv5;(e)改进 YOLOv5
Fig. 7 Comparison of different target detection algorithms. (a) Original image; (b) Faster R-CNN; (c) YOLOv3; (d) YOLOv5; (e) improved YOLOv5

表 6 不同算法实验结果对比

Table 6 Comparison of experimental results of different algorithms

Model	$P / \%$	$R / \%$	$R_{mAP}@0.5 / \%$	$R_{mAP}@0.5:0.95 / \%$	Model size / MB	FPS
SSD	80.97	76.41	81.45	58.39	176.4	55
Faster R-CNN	88.12	84.69	88.06	67.59	230.8	18
YOLOv3	85.68	83.58	87.67	65.82	67.9	62
YOLOv5	89.53	89.18	90.43	90.43	14.1	98
Improved YOLOv5	92.56	91.71	93.84	73.61	5.4	166

表 7 消融实验

Table 7 Ablation experiment

YOLOv5	ConvNeXt block	CA	Prune	$P / \%$	$R / \%$	$R_{mAP}@0.5 / \%$	FPS
✓				89.53	89.18	90.43	98
✓	✓			90.65	90.42	93.27	105
✓		✓		89.79	90.23	93.48	101
✓	✓	✓		94.12	92.86	95.25	118
✓	✓	✓	✓	92.56	91.71	93.84	166

个百分点;当 ConvNeXt block 和 CA 注意力模块同时加入时,模型的识别性能最好,达到 95.25%,提升了 5.3 个百分点;同时对原算法加入 ConvNeXt block 模块、CA 注意力模块及剪枝操作时,虽然 R_{mAP} 只提升 3.7 个百分点,但检测速率大大加快,达到 166 frame/s,足足提升了 69.4%。结果表明改进 YOLOv5 算法的检测精度较好,检测速度较快,能满足无人机对绝缘子缺陷的实时检测要求。

4 结 论

针对绝缘子缺陷检测的特征提取不足、小目标检

测效果差、检测速度和精度无法同时满足的问题,提出一种改进的 YOLOv5 算法,并进行对比实验。用 ConvNeXt block 重构主干网络,使 YOLOv5 算法特征提取能力更强,对背景复杂的目标有着更出色的检测能力。引入坐标注意力机制提高主干特征提取效率,进一步提升算法的特征提取能力,获取到更多与目标有关的细节信息。改进 YOLOv5 在测试集上 R_{mAP} 达到 93.84%, 优于其他目标检测算法,改进 YOLOv5 使模型大小减小到 5.4 MB,检测速率达到 166 frame/s,且具有较高的检测精度与检测速度,适合部署到无人机上完成绝缘子缺陷检测任务。后续可对模型进行知识

蒸馏操作,使模型更加轻量化,进一步提升模型的检测速度与检测效率。

参 考 文 献

- [1] 李科,袁智,李建东. 无人机电力线路安全巡检的关键技术[J]. 中国高新科技, 2022(5): 48-49.
Li K, Yuan Z, Li J D. Key technology of UAV power line safety inspection[J]. China High and New Technology, 2022(5): 48-49.
- [2] 王素珍,赵霖,邵明伟,等. 基于改进YOLOv5的输电线路绝缘子识别方法[J]. 电子测量技术, 2022, 45(21): 181-188.
Wang S Z, Zhao L, Shao M W, et al. Insulator identification method of transmission line based on improved YOLOv5[J]. Electronic Measurement Technology, 2022, 45(21): 181-188.
- [3] 张少平,杨忠,黄宵宁,等. 航拍图像中玻璃绝缘子自爆缺陷的检测及定位[J]. 太赫兹科学与电子信息学报, 2013, 11(4): 609-613.
Zhang S P, Yang Z, Huang X N, et al. Defects detection and positioning for glass insulator from aerial images[J]. Journal of Terahertz Science and Electronic Information Technology, 2013, 11(4): 609-613.
- [4] 张昊洋,张国春,秦志勇. 无人机电力自主巡检技术应用与分析[J]. 农村电气化, 2022(7): 51-53.
Zhang H Y, Zhang G C, Qin Z Y. Application and analysis of UAV power autonomous inspection technology[J]. Rural Electrification, 2022(7): 51-53.
- [5] 宋立业,刘帅,王凯,等. 基于改进EfficientDet的电网元件及缺陷识别方法[J]. 电工技术学报, 2022, 37(9): 2241-2251.
Song L Y, Liu S, Wang K, et al. Identification method of power grid components and defects based on improved Efficient Det[J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2241-2251.
- [6] 江波,屈若锟,李彦冬,等. 基于深度学习的无人机航拍目标检测研究综述[J]. 航空学报, 2021, 42(4): 5245-519.
Jiang B, Qu R K, Li Y D, et al. Object detection in UAV imagery based on deep learning: review[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 5245-519.
- [7] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [8] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [9] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. [2018-09-30]. <http://export.arxiv.org/abs/1804.02767>.
- [10] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. Computer Vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.
- [11] 郑伟,杨晓辉,吕中宾,等. 基于改进YOLOv4输电线路关键部件实时检测方法[J]. 科学技术与工程, 2021, 21(24): 10393-10400.
Zheng W, Yang X H, Lü Z B, et al. Real-time inspection model for key components of transmission lines based on improved YOLOv4[J]. Science Technology and Engineering, 2021, 21(24): 10393-10400.
- [12] 王朝硕,李伟性,郑武略,等. 一种改进SSD的输电线路电力部件识别方法[J]. 应用科技, 2020, 47(4): 75-81.
Wang C S, Li W X, Zheng W L, et al. An improved SSD method for power component identification of transmission lines[J]. Applied Science and Technology, 2020, 47(4): 75-81.
- [13] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 580-587.
- [14] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2016: 1440-1448.
- [15] 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.
- [16] 黄文琦,张福铮,李鹏,等. 基于Faster R-CNN的绝缘子识别探索和应用[J]. 南方电网技术, 2018, 12(9): 22-27.
Huang W Q, Zhang F Z, Li P, et al. Exploration and application on faster R-CNN based insulator recognition[J]. Southern Power System Technology, 2018, 12(9): 22-27.
- [17] 程海燕,翟永杰,陈瑞. 基于Faster R-CNN的航拍图像中绝缘子识别[J]. 现代电子技术, 2019, 42(2): 98-102.
Cheng H Y, Zhai Y J, Chen R. Faster R-CNN based recognition of insulators in aerial images[J]. Modern Electronics Technique, 2019, 42(2): 98-102.
- [18] 鞠默然,罗海波,王仲博,等. 改进的YOLO V3算法及其在小目标检测中的应用[J]. 光学学报, 2019, 39(7): 0715004.
Ju M R, Luo H B, Wang Z B, et al. Improved YOLO V3 algorithm and its application in small target detection [J]. Acta Optica Sinica, 2019, 39(7): 0715004.
- [19] Liu Z, Mao H Z, Wu C Y, et al. A ConvNet for the 2020s[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18-24, 2022, New Orleans, LA, USA. New York: IEEE Press, 2022: 11966-11976.
- [20] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 13708-13717.
- [21] Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[EB/OL]. (2022-11-28) [2023-02-03]. <https://arxiv.org/abs/2207.02696>.