

DOI:10.19651/j.cnki.emt.2209114

# 应用于绝缘子缺陷检测的轻量化 YOLOv4 研究

马进 白雨生

(华北电力大学控制与计算机工程学院 保定 071003)

**摘要:** 针对 YOLOv4 主干网络庞大、参数量多,应用于绝缘子缺陷检测中无法满足实时性要求的问题,提出一种轻量化的 YOLOv4 检测模型。首先,引入含 ECA 集成组件的 GhostNet 作为特征提取网络,保证特征提取能力的同时大幅减少模型参数,加快模型推理速度。其次,使用 K-means++ 聚类算法确定出初始锚框尺寸,以适应绝缘子缺陷大小,提升缺陷定位精度。最后,在交叉熵损失函数的基础上引入 Quality Focal Loss 改进损失函数,进一步提升模型检测性能。实验结果表明,改进后的轻量化 YOLOv4 与原始 YOLOv4 相比,模型大小压缩至原来的 62.47%,每秒帧率提升了 68.83%,绝缘子缺陷检测的准确率提升了 1.07%,在显著提升检测速度的同时保证了算法检测精度,且在小目标和复杂背景下表现突出。

**关键词:** 绝缘子缺陷检测;轻量化网络;GhostNet;YOLOv4;目标检测

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 520.6040

## Research on lightweight YOLOv4 applied to insulator defect detection

Ma Jin Bai Yusheng

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

**Abstract:** Aiming at the problem that YOLOv4 has a huge backbone network and a large number of parameters, it cannot meet real-time requirements when applied to insulator defect detection. A lightweight YOLOv4 detection model is proposed. First, GhostNet with ECA integrated components is introduced as the feature extraction network, which greatly reduces the model parameters and speeds up the model inference while ensuring the feature extraction capability. Secondly, the K-means++ clustering algorithm is used to determine the initial anchor frame size to adapt to the size of the insulator defect and improve the accuracy of defect location. Finally, on the basis of the cross-entropy loss function, the Quality Focal Loss is introduced to improve the loss function to further improve the model detection performance. Experimental results show that compared with the original YOLOv4, the improved lightweight YOLOv4 has a reduced model size of 62.47%, Frames Per Second increased by 68.83%, and the accuracy of insulator defect detection has increased by 1.07%, significantly improving the detection speed. At the same time, the detection accuracy of the algorithm is guaranteed, and it performs outstandingly in small targets and complex backgrounds.

**Keywords:** insulator defect detection;lightweight network;GhostNet;YOLOv4;object detection

## 0 引言

绝缘子作为输电线路中实现电气隔离的重要构件,其质地完备是保障线路安全稳定运行的关键。挂网后的绝缘子长期工作在户外环境中,受到恶劣气候和污秽积聚的影响很容易受损,受损引发的故障会直接威胁到电力线路的正常使用和运行寿命<sup>[1]</sup>。因此,需要定期利用无人机航拍的方式对绝缘子缺陷进行巡检。

近年来,国内外对基于图像的缺陷检测研究主要采用高效的深度学习算法<sup>[2]</sup>。相比于传统使用手工提取特征的检测方法,基于深度学习的检测方法可以充分发

挥计算机的数据处理性能,使其从训练数据集中自主学习目标特征,解决传统方法在效率、成本、准确度等方面不足,并对输电线路所处的复杂自然环境有很好的自适应能力<sup>[3]</sup>。

针对绝缘子缺陷检测的深度学习算法有两类,一类是具有良好实时检测性能的一阶段检测器,如文献[4]中基于 SSD<sup>[5]</sup>算法设计出的基于多重感知的绝缘子缺陷检测方法;文献[6]结合高斯分布提出一种改进的 YOLOv3<sup>[7]</sup>模型,提高了绝缘子缺陷检测的精确度;文献[8]结合注意力机制改进 YOLOv4<sup>[9]</sup>模型,有效提升绝缘子故障段的特征

表达能力,实现了输电线路故障检测。另一类是实现更高检测精度的两阶段检测器,如文献[10]提出的基于改进 Faster RCNN<sup>[11]</sup>模型的绝缘子检测算法,检测精度高但检测速度较慢。还有一种能够平衡检测精度和模型推理时间的基于 Anchor-Free 的目标检测算法,此类算法通过关键点来回归目标框位置和其他目标属性,能够有效缩短模型推理时间,但受正负样本不平衡的影响会出现检测性能不稳定的问题,如文献[12]提出的改进 CenterNet<sup>[13]</sup>的输电线路巡检故障检测方法。

可见,基于航拍图像和深度学习的绝缘子缺陷检测技术有着良好的应用研究前景,但上述模型普遍存在网络结构复杂、计算成本高的问题,难以实现缺陷实时检测。本文将 GhostNet<sup>[14]</sup>结构融合到 YOLOv4 的特征提取网络中,并添加一种集成注意力模块的空间金字塔结构,有效减少模型参数量;同时收集绝缘子缺陷航拍图像数据集并进行线下增广;采用 K-means++<sup>[15]</sup>算法对标注好的数据样本进行聚类,获得适应目标缺陷的先验框参数以提升缺陷定位准确率;通过 Quality Focal Loss(QFL)<sup>[16]</sup>改进损失函数进一步提升模型性能。实验表明,该方法较原始 YOLOv4

检测速度提升明显,检测精度也略有提升,可以满足绝缘子缺陷检测的实时性需求。

## 1 相关算法

### 1.1 YOLOv4 算法简介

YOLOv4 算法作为典型的一阶段目标检测算法,其模型由主干网络、颈部网络和头部网络 3 部分组成。如图 1 所示,主干网络采用 CSPDarknet53,该模块将基础层的特征进行拆分,一部分进行残差堆叠,另一部分跳跃连接到后面的特征层,然后进行特征整合,使得模型对于特征的提取更加完整。颈部网络采用空间金字塔池化(spatial pyramid pooling, SPP)和路径聚合网络(path-aggregation neck, PANet)。SPP 结构进行四个不同尺度的最大池化处理,拓宽了模型感受野。PANet 经上采样堆叠后再进行下采样堆叠,通过保留空间信息增强了模型对于精细特征的提取。头部网络采用 2 层普通卷积得到原始输出,最终的预测结果需要对输出进行解码,解码时得到预测结果的若干个真实框,通过得分排序和非极大值抑制筛选得到最准确的一个作为模型检测结果。

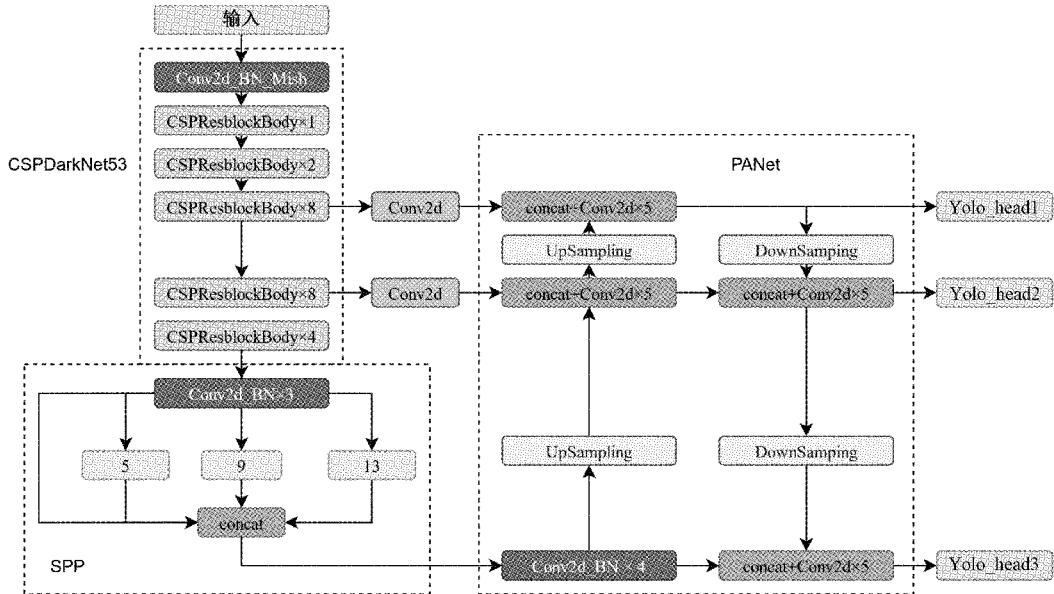


图 1 YOLOv4 网络结构

### 1.2 Ghost 模块

如图 2(a)为标准卷积过程示意图,给定输入数据  $X \in R^{c \times b \times w}$ ,其中  $c$  是输入通道,  $b \times w$  是输入维度,则生成  $n$  个特征图的标准卷积运算为:

$$Y = X * f + b \quad (1)$$

式中: $*$  表示卷积运算,  $b$  作为运算偏差,  $Y \in R^{h' \times w' \times n}$  是输出特征图,  $f \in R^{c \times k \times k \times n}$  表示卷积核,  $h' \times w'$  是输出维度,  $k \times k$  是  $f$  的内核大小。

在标准卷积过程中,通常卷积核数  $n$  和通道数  $c$  非常大,导致运算过程所需的每秒浮点运算次数(floating-point

operations per second, FLOPS)达  $n \times h' \times w' \times c \times k \times k$  之多。而在 Ghost 模块中,输出特征图是由少数初始特征图通过线性变换得到的。这些初始特征图  $Y' \in R^{h' \times w' \times m}$  由普通的卷积核生成:

$$Y' = X * f' \quad (2)$$

其中,  $f'$  是卷积核,且  $m \leq n$ 。为了得到相同维度的输出特征图,该步骤的卷积核大小、步长等超参数均与普通卷积相同。对  $Y'$  得到的每个初始特征应用线性运算,生成  $s$  个增广特征,最终获得  $n$  个特征图:

$$y_{ij} = \Phi_{i,j}(y'_i), \forall i = 1, 2, \dots, m, j = 1, 2, \dots, s \quad (3)$$

式(3)中  $y'$  是  $Y'$  中第  $i$  个初始特征图,  $\Phi_{i,j}$  表示第  $j$  个线性运算, 用于生成第  $j$  个增广特征图。每个初始特征可以生成多个增广特征图, 如图 2(b) 所示。通过使用计算量少的线性运算, 可以获得  $n$  个特征图作为 Ghost 模块的

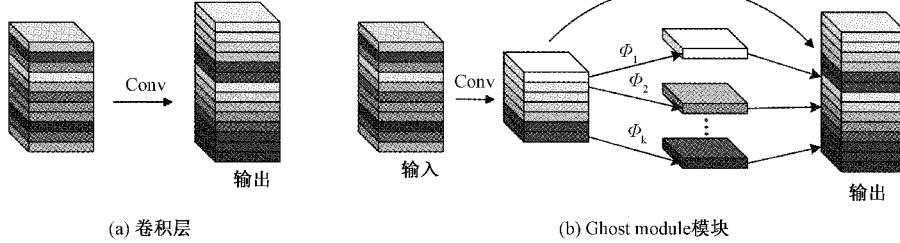


图 2 Ghost module 结构图

## 2 改进的 YOLOv4 算法

针对 YOLOv4 主干网络庞大、参数量多, 应用于绝缘子缺陷检测中无法满足实时性要求的问题, 本文对基于 YOLOv4 的绝缘子缺陷检测算法提出改进: 1) 采用 GhostNet 和空间金字塔池化来优化主干网络, 并添加 ECA 注意力机制, 在减少参数量、降低计算复杂度的同时提升了基础层的特征提取能力; 2) 采用 K-means + 聚类的方法得到初始锚框, 使得先验框尺寸更加贴合绝缘子缺陷在航拍图像中的大小, 提高模型辨识效果; 3) 使用改进的交叉熵损失函数计算模型置信度和类别损失, 专注于提升复杂背景下难分样本的检测效果, 解决标准交叉熵损失中存在的正负样本不平衡的问题, 从而提高目标检测精度。

### 2.1 主干网络改进

原始 YOLOv4 算法为实现对样本特征的充分提取, 通过大批量的卷积运算搭建深度神经网络, 导致网络模型参数量多, 计算量大, 进而使得检测实时性差。鉴于此问题, 选择 GhostNet 改进 YOLOv4 的主干特征提取网络。如图 3 所示, GhostNet 的主要结构是 Ghost BottleNeck (GBN), GBN 主要由两个堆叠的 Ghost 模块组成, 第 1 个用来拓展通道数, 增强特征提取能力, 第 2 个用来缩减通道数, 使输入输出通道数相匹配。构造出的 GBN 根据步幅 (Stride) 不同有两种结构, 搭建网络模型时灵活调用两种 Ghost 模块以建立 GhostNet。

改进的 YOLOv4 算法整体结构框架如图 5 所示, 第一层是标准卷积, 用来获取原始特征, 然后是不同维度的 GBN, 这些 GBN 根据其输入尺寸分为不同的阶段。每个阶段的最后均为 stride=2 的 GBN 模块, 其余应用 stride=1 的 GBN 模块。最终输出 3 个大小分别为  $52 \times 52 \times 40$ 、 $26 \times 26 \times 112$  和  $13 \times 13 \times 160$  的有效特征层作为颈部网络的输入。

在 GhostNet 结构的后端添加轻量化通道注意 ECA 模块, 其结构如图 4 所示, 该模块通过当前通道及其  $k$  个

输出, 这与标准卷积生成数量一致。在 Ghost 模块中, 仅采用了 1 次标准卷积和一些线性运算生成与普通卷积相同数量的特征图, 这大大降低了普通卷积带来的庞大的计算量和运算参数, 大幅降低特征冗余, 减少了计算成本。

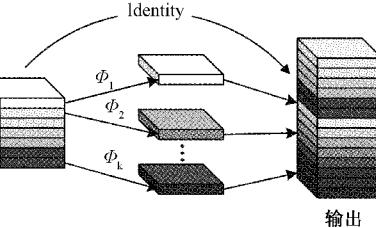


图 3 Ghost BottleNeck 结构图

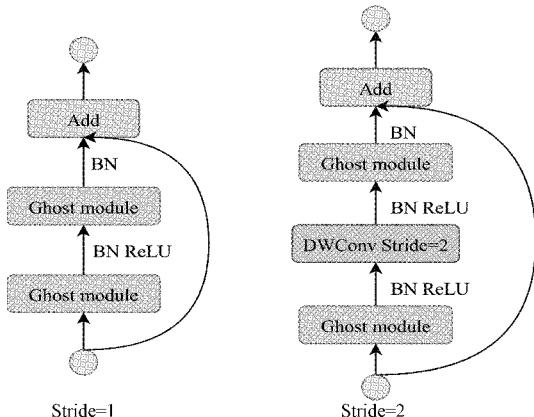
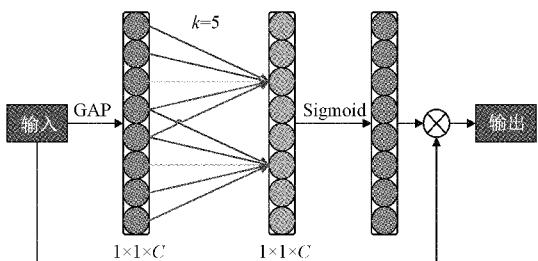


图 4 ECA 模块结构

邻通道实现跨通道信息捕获, 使其无需降低通道数就能有效获取通道交互信息, 这种机制在保证计算效果的同时, 也兼顾了模型效率。通过该模块计算特征图在通道位置上的权重信息, 并根据该信息进行权重分配, 使模型能够更多关注到特征层中有利于检测的绝缘子缺陷特征信息, 还可以抑制图像背景及其他非缺陷的次要信息, 从而有效提升网络模型的性能。

为了使模型主干网络在提取特征时能够增强感受野并分离出重要的语义信息。将空间金字塔池化结构置于主干网络中, 与 ECA 注意模块和 GhostNet 主干中的最后一个 GBN 进行集成。



集成后的模块能够输出包含最多语义信息的特征, 并

与其余两个有效特征层进行堆叠融合,进而将特征图转换

为特征向量进行特征提取和分类,最终实现准确的预测。

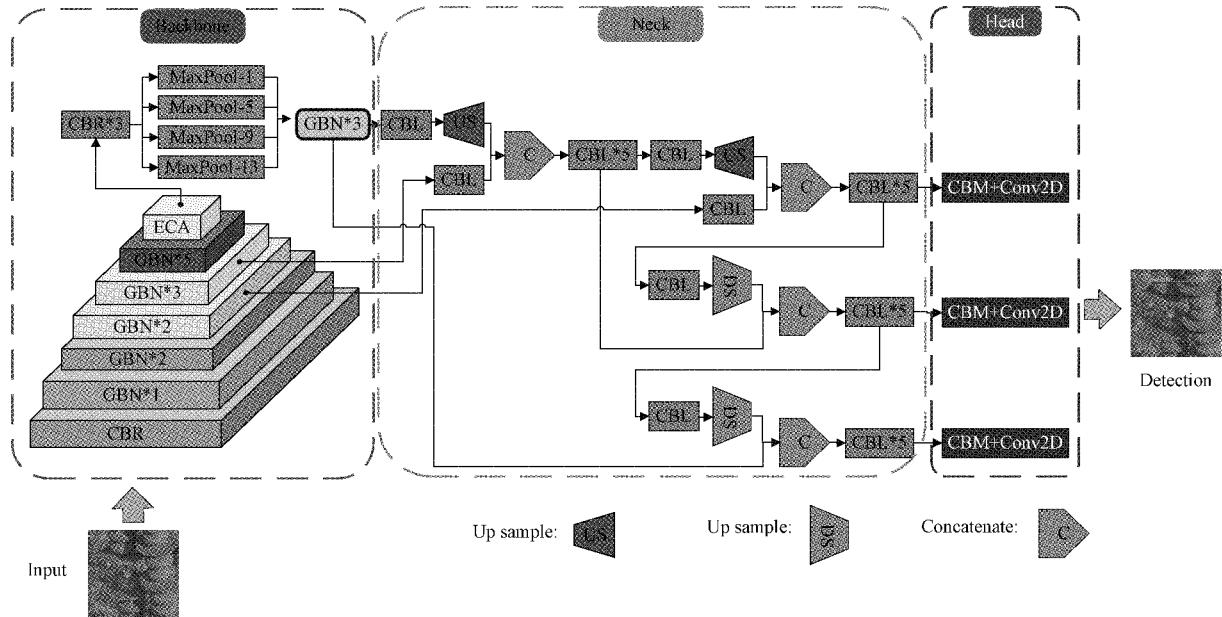


图 5 Ghost\_YOLOv4 网络结构

## 2.2 基于 K-means++聚类的锚框选择

在目标检测算法中使用先验框参数,训练时加入先验锚框尺寸,有助于模型加速收敛。本文采用 K-means++聚类的方法计算出更加贴合航拍图像绝缘子缺陷的先验框尺寸,代替原始锚框进行网络训练,进一步提升模型性能。K-means++算法<sup>[16]</sup>的基本流程是先从数据集中随机选取一个样本作为聚类中心,计算出每个样本与聚类中心的相似性度量,将其分配给与之距离最近的簇中心,并根据该值选取下一个聚类中心,直到选出 K 个所需要的簇中心。

本文检测的绝缘子缺陷数据集真实框由左上顶点和右下顶点标注,即  $(x_{\min}, y_{\min})$  和  $(x_{\max}, y_{\max})$ 。在本文检测方法中,检测结果的正确与否取决于锚框(anchor)与真实框(box)的交并比(intersection over union, IOU),与真实框的大小无关,故使用 IOU 作为相似性度量。锚框与真实框的 IOU 计算如式(4)所示。IOU 值越大,表示两框距离越近,锚框置信得分越高。最终度量公式如式(5)所示。

$$C_{IOU}(box, anchor) = \frac{A_{anchor} \cap A_{box}}{A_{anchor} \cup A_{box}} \quad (4)$$

$$D(box, anchor) = 1 - C_{IOU}(box, anchor) \quad (5)$$

其中,  $A_{anchor}$  代表预测锚框的面积,  $A_{box}$  代表真实框的面积。采用 K-means++聚类算法对绝缘子缺陷数据集进行聚类,得到 9 个锚框,聚类结果为(41,39),(90,99),(103,50),(152,191),(161,122),(227,304),(254,172),(316,83),(420,332)。聚类中心在整个数据集中显示,如图 6 所示。

## 2.3 损失函数改进

损失函数在模型训练时给出调整权值的信号来降低

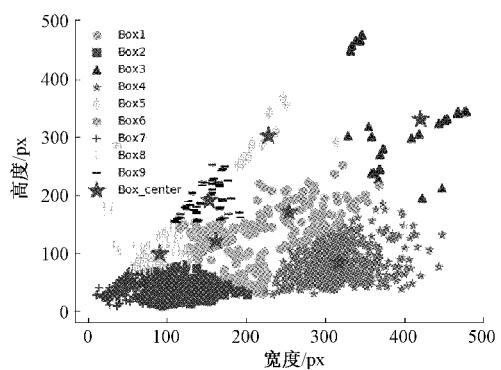


图 6 K-means++聚类结果

分类误差,所以在模型预测错误时,损失函数应能及时给出反馈。YOLOv4 算法的损失函数可分为回归框预测误差、置信度误差、类别误差 3 部分,如式(6)所示。

$$L = L_{iou} + L_{conf} + L_{class} \quad (6)$$

为解决正负样本数不均衡问题,通常在 YOLOv4 的损失函数基础上引入 Focal loss。引入 Focal loss 的损失函数虽然能够使少量的正样本和大量的负样本一起成功训练,但仍然存在复杂场景下回归框建模效果差的问题。针对以上情况,本文对于复杂背景下的电力绝缘子缺陷检测采用 Quality Focal Loss(QFL)<sup>[17]</sup> 损失函数来改进置信度损失和类别损失。QFL 损失函数在标准交叉熵损失基础上进一步改进,表示为式(7)。

$$L_{QFL}(\sigma) = -|y - \sigma|^{\beta}((1 - y)\log(1 - \sigma) + y\log(\sigma)) \quad (7)$$

式中:  $y$  为真实标签,  $\sigma$  为标签的预测值,其差的绝对值的  $\beta$  幂次作为调节因子,用于调节样本权重,以提高网络训练

速度,使得模型可以更好地实现样本的特征学习,并在解决正负样本不平衡的同时使其支持连续数值的监督,从而进一步提高检测精度。

因此,引入 QFL 后的损失函数  $L'$  由  $L_{iou}$ 、 $L_{conf}$ 、 $L_{class}$  组成,分别表示为:

$$L_{iou} = \lambda_{iou} \left[ 1 - C_{iou} + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha\nu \right], \quad (8)$$

$$\begin{cases} \rho^2(b, b^{gt}) = (b_x - b_x^{gt})^2 + (b_y - b_y^{gt})^2 \\ \alpha = \frac{\nu}{(1 - C_{iou}) + \nu} \\ \nu = \frac{4}{\pi^2} (\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h})^2 \end{cases} \quad (9)$$

式中:  $\lambda_{iou}$  表示该类损失权重系数,  $C_{iou}$  表示锚框与真实框的交并比,  $\rho^2(b, b^{gt})$  表示锚框与真实框几何中心的欧氏距离,  $c$  是重合区域对角线距离,  $\alpha$  是自取的权衡参数,  $\nu$  用来衡量宽高比,  $gt$  代表真实框的信息,  $w, h$  分别表示锚框的宽、高。

$$L_{conf} = \lambda_{conf1} \sum_{i=0}^{s^2} \sum_{j=0}^B I_{i,j}^{obj} (-|\hat{C}_i^j - C_i^j|^\beta) [\hat{C}_i^j \log(C_i^j) + (1 - \hat{C}_i^j) \log(1 - C_i^j)] + \lambda_{conf2} \sum_{i=0}^{s^2} \sum_{j=0}^B I_{i,j}^{noobj} (-|\hat{C}_i^j - C_i^j|^\beta) [\hat{C}_i^j \log(C_i^j) + (1 - \hat{C}_i^j) \log(1 - C_i^j)], \quad (10)$$

$$L_{class} = \lambda_{class} \sum_{i=0}^{s^2} \sum_{c \in class} (-|\hat{P}_i^j - P_i^j|^\beta) [\hat{P}_i^j \log(P_i^j) + (1 - \hat{P}_i^j) \log(1 - P_i^j)]. \quad (11)$$

式(10)、(11)中,  $\lambda_{conf1}$ 、 $\lambda_{conf2}$ 、 $\lambda_{class}$  代表类别损失权重,  $s^2$  为划分网格数,  $B$  为各个网格中的先验框数目,  $c$  表示类别,  $I_{i,j}^{obj}$  表征第  $i$  个单元格的第  $j$  个预测框内是否包含预

测目标,值为 1 即包含,取 0 则不包含;  $I_{i,j}^{noobj}$  则相反,为 1 时不包含,为 0 时包含;  $\hat{C}_i^j$  为实际置信度,  $C_i^j$  为预测置信度;  $\hat{P}_i^j$  代表单元格中目标所属类别的实际概率,  $P_i^j$  表示预测概率。

### 3 实验结果与分析

在实验过程中,首先建立绝缘子缺陷航拍数据集;其次,借助迁移学习的思想,采用 VOC2007 数据集对 Ghost\_YOLOv4 网络进行预训练,得到网络预训练权重;然后,选用建立的绝缘子缺陷数据集对预先训练好的网络进行参数调整;最后,完成绝缘子缺陷的检测。

#### 3.1 数据集的建立

本实验采用的数据是由某电网公司搜集的真实背景下的绝缘子航拍图片,图片中绝缘子类型包含玻璃绝缘子、瓷绝缘子、悬式绝缘子、支柱绝缘子 4 种。由于原始绝缘子缺陷图像数量有限,如果直接用来训练神经网络容易造成模型过拟合。因此,本文运用角度翻转(Flip)、亮度调整(Bright)、对比度调整(Contrast)、噪声扰动(Noise)操作对原始图像进行了线下数据增广,部分增广效果如图 7 所示。数据增广后最终得到的数据集共有 3 899 张图片,以 8:2 的比例划分训练集和测试集,训练集有 3 119 张,分为实际训练集 2 495 张和验证集 624 张,测试集有 780 张。数据集增广后采用开源标注工具 LabelImg 对所有图片中的缺陷进行标注,生成对应的 XML 文件,并将标注好的图像制作成为 VOC2007 格式。在算法实际测试过程中,利用格式转换程序将 XML 文件转化为包含样本路径、缺陷位置信息的 txt 文件,供神经网络训练使用。

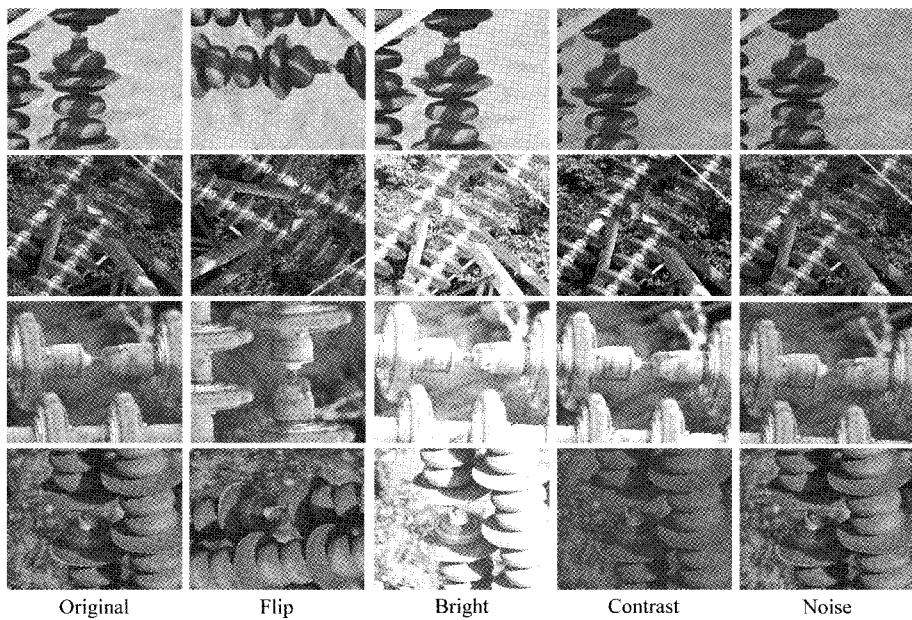


图 7 数据集增广效果

### 3.2 实验效果测试

#### 1) 实验平台及训练过程

本文网络模型训练所用的实验平台硬件环境配置为 Intel(R) Xeon(R) E5-2678 v3 CPU, Tesla K80 GPU, 12 G 显存的服务器。测试算法的硬件平台为 Intel(R) Core(TM) i7-6700HQ CPU, NVIDIA GeForce GTX 960 M GPU, 8 G 内存笔记本电脑。软件实验环境采用 Python 语言和 PyTorch 深度学习框架进行编码。其中, Python 版本为 3.7.3, CUDA10.0, cuDNN7.6.5, torch1.2.0, 软件测试平台为 pycharm-professional。

在实际训练过程中, 将模型输入图像分辨率设为  $416 \times 416$ , 不同分辨率的样本图片会自行转换成模型需要的尺寸大小供神经网络训练使用。训练时采用余弦退火学习率(Cosine Scheduler)对模型进行梯度优化, 上升时保持线性增加, 下降时模拟余弦函数。训练过程设置训练总迭代次数为 100, 并借助迁移学习的思想, 将整个训练过程分为两个阶段, 分别是冻结阶段(Freeze)和解冻阶段(Unfreeze)。在网络冻结阶段, 冻结模型主干, 特征提取网络不发生变化, 此时占用 GPU 显存较小, 仅对网络进行微调; 在解冻阶段, 不冻结模型主干, 特征提取网络会发生改变, 相应过程中占用的显存较大, 网络所有的参数都会发生改变, 不同阶段(Stage)网络批大小(Batch\_size)以及初始学习率(Learning\_rate)等超参数设置如表 1 所示。

表 1 网络超参数设置

Stage	Batch_size	epoch	Learning_rate
Freeze	32	50	0.001
Unfreeze	16	50	0.0001

#### 2) 实验结果与分析

为了客观评价改进的 YOLOv4 模型性能, 使用目标检

测领域常用的指标: 模型大小(size)、查准率(precision, P)、查全率(recall, R)、平均精度(average precision, AP) 和每秒传输帧率(frames per second, FPS) 衡量, 相关计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (12)$$

$$R = \frac{TP}{TP + FN} \quad (13)$$

$$AP = \int_0^1 P dR \quad (14)$$

其中, TP(true positive) 表示网络预测正确的正样本数; FP(false positive) 表示网络预测错误的负样本数; FN(false negative) 为模型预测错误的正样本数; 查准率和查全率联合评估了模型的全局优劣度, 两值均维持一个较高的水平时, 模型能够较好的预测出正样本; AP 为 P-R 曲线围出的面积, 该值越高, 说明目标检测模型性能越好; FPS 表示模型在一秒内可以检测的图像数, 表征了模型的检测速度。

为验证本文改进的轻量化 YOLOv4 算法中 ECA 集成模块和 QFL 损失函数对绝缘子检测性能的影响以及采用 GhostNet 替换主干网络对模型大小的简化效果, 进行了一组消融实验, 对比分析了:(1) 原 YOLOv4 模型;(2) 仅引入 Quality Focal Loss(QFL) 损失函数的 YOLOv4+QFL 模型;(3) 仅使用 GhostNet 改进特征提取网络的 Ghost\_YOLOv4 模型;(4) 引入 QFL 损失函数并使用 GhostNet 改进特征提取网络的 Ghost\_YOLOv4+QFL 模型;(5) 引入 ECA 集成组件改进 GhostNet 并采用 QFL 损失函数的本文改进模型。在相同实验条件下, 通过本文数据集训练以上五个模型, 得到各模型的绝缘子缺陷检测结果并进行对比。具体消融实验结果见表 2。该实验分别比较了各种结构替换后的模型大小(Size)、检测平均精度(AP)和每秒传输帧数(FPS)。

表 2 消融实验结果

Model	ECA	GhostNet	QFL	Size/MB	AP/%	FPS
YOLOv4	—	—	—	245.53	90.82	7.7
YOLOv4+QFL	—	—	✓	245.89	92.14	7.7
Ghost_YOLOv4	—	✓	—	155.67	89.17	12.9
Ghost_YOLOv4+QFL	—	✓	✓	155.82	91.51	12.8
ECA+Ghost_YOLOv4+QFL	✓	✓	✓	153.38	91.89	13.0

可以看出, 原 YOLOv4 的模型大小为 245.53 M, 采用 GhostNet 网络结构替换 CSPDarknet53 后模型大小下降了 90 M 左右, 仅为原来的 63.4%, 说明 GhostNet 可以有效简化模型, 降低模型大小; 引入 QFL 损失函数的 YOLOv4+QFL 网络, 相较于原 YOLOv4 网络, AP 值提高了 1.32%, 两者检测速度相当, 说明本文改进的损失函数对 YOLOv4 模型提升绝缘子缺陷辨识性能有明显作用,

有效解决了由于正、负样本不均衡导致的检测精度较低的问题; 而采用 GhostNet 结构的 Ghost\_YOLOv4 网络检测效果相较于未改进的 YOLOv4 网络而言, 绝缘子缺陷检测的 AP 值降低了 1.65%, 检测速度提升了 67.5%, 验证了采用 GhostNet 结构的 Ghost\_YOLOv4 网络在保证检测精度不下降太多的前提下提高绝缘子缺陷检测速度的有效性; Ghost\_YOLOv4+QFL 的网络将 GhostNet 结构和改

进后的损失函数同时加入 YOLOv4 网络,相较于原 YOLOv4 网络和单独添加 GhostNet 结构,该模型的精度分别提升了 0.69 和 2.34 个百分点,虽略差于直接在 YOLOv4 模型上改进损失函数,但却将检测速度提升了 66.2%,模型参数量也大幅度下降,验证了采用 GhostNet 和 QFL 损失函数的改进策略具有提高绝缘子缺陷检测精度和速度的有效性;表中引入 ECA 集成组件改进 GhostNet 并采用 Quality Focal Loss(QFL)损失函数的优化模型在模型大小、检测精度和检测速度几个方面均优于改进前的 YOLOv4 网络模型,其中,模型大小压缩至原来的 62.47%,精度提升了 1.07 个百分点,FPS 提升了 68.83%,且相较于未加入 ECA 集成模块前的改进模型性能也实现了一定提升,主要原因是加入 ECA 注意力机制,能够更好关注特征图中通道位置上的语义信息,提取出更

为关键的图像特征,其结构中的快速  $1 \times 1$  卷积在 Ghost 模块的基础上进一步缩减了模型参数,并通过紧密集成的 SPP 结构加强对特征的利用率,从而在保证检测速度的同时提高绝缘子缺陷检测的准确率,使得模型的综合性能得到了进一步提升。

为进一步验证本文改进算法的有效性,在检测过程中,将本文的改进模型与目前主流的目标检测模型进行横向比较,包括 CenterNet、SSD、YOLOv3 以及 MobileNetv2<sup>[17]</sup>、MobileNetv3<sup>[18]</sup>轻量化改进 YOLOv4 主干网络的模型。为确保检测到的绝缘子缺陷更贴近实际缺陷,更好地体现模型性能,指定 IOU 阈值为 0.75,表 3 中列出了各模型的骨干网络(Backbone)、模型大小(Size)、查准率(P%)、查全率(R%)、平均精度(AP)和每秒传输帧数(FPS)以说明几种方法对于绝缘子缺陷的检测结果。

表 3 模型对照实验结果

Model	Backbone	Size/MB	P%	R%	AP/%	FPS/(f×s <sup>-1</sup> )
CenterNet	Resnet50	124.61	87.56	84.45	85.79	13.5
SSD	VGG16	100.27	91.13	83.03	87.33	14.1
YOLOv3	Darknet53	236.32	86.92	85.11	85.42	9.2
MobileNetv2_YOLOv4	MobileNetv2	156.70	89.38	89.53	89.14	12.8
MobileNetv3_YOLOv4	MobileNetv3	147.99	88.20	87.71	87.83	13.1
本文算法	ECA_GhostNet	155.82	90.81	92.32	91.89	13.0

上述对照试验结果表明,本文算法与当下主流的几种一阶段目标检测模型相比,在识别精度和速度上都具有较大优势,改进后网络 AP 值最高可达到 91.89%,相比于 CenterNet、SSD、YOLOv3 分别提高了 6.1%、4.56%、6.47%。将本文改进模型与其他两种轻量化的改进模型 MobileNetv2\_YOLOv4、MobileNetv3\_YOLOv4 进行对比,可以发现,本文改进模型大小与上述模型相当,但平均精度分别高两者 2.75 和 4.06 个百分点。在检测速度方面,改进模型优于 YOLOv3 和 MobileNetv2 改进主干网络的

YOLOv4 模型,略差于 MobileNetv3\_YOLOv4、CenterNet 和 SSD 模型,鉴于模型精度提升较大且在复杂背景下对小目标的识别能力较优,本文改进模型基本达到识别精度和速度的平衡。综上所述,本文所改进的算法模型相较于主流算法的模型性能有较大提升,考虑到模型在进行航拍目标检测时应保证实时性要求,本文模型凭借高精度、轻量化的性能更适合在实际环境中进行绝缘子缺陷的识别。

改进模型在测试集上的绝缘子缺陷检测部分结果如图 8 所示。其中,图 8(a)组实现了小目标绝缘子缺陷的识

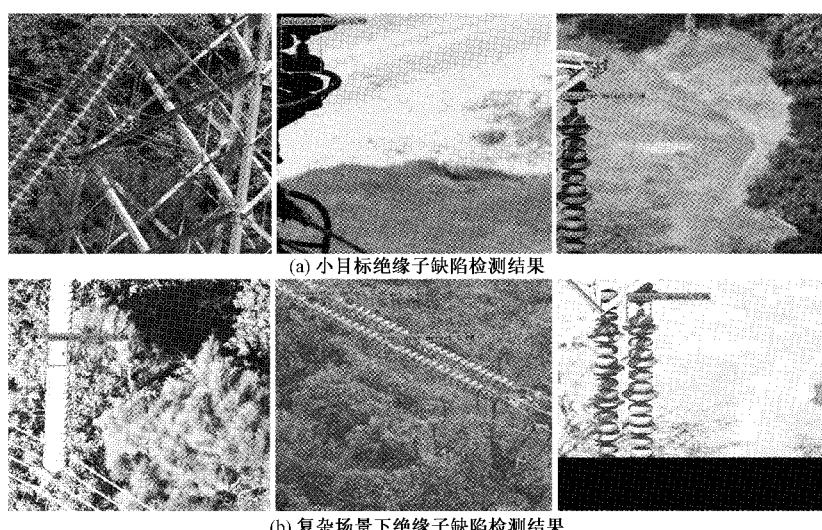


图 8 绝缘子缺陷检测结果

别;图8(b)组是在复杂背景下绝缘子缺陷的检测效果。可以看到,本文提出的改进目标检测模型准确实现了包括小目标缺陷在内的复杂场景下绝缘子缺陷检测,具有一定的实际应用价值。

## 4 结 论

为解决绝缘子缺陷检测算法特征提取计算成本高昂而无法满足实时性要求的问题,本文在YOLOv4模型基础上对其特征提取网络和损失函数进行改进,并以K-means++聚类的方法设计锚框,同时借助迁移学习训练网络,加速模型收敛。以数据增强后的绝缘子缺陷图像作为数据集,分别做了消融实验和不同模型对照实验。实验结果表明,本文所提改进点均产生了一定的模型优化效果,引入的GhostNet降低了模型大小,提升了检测速度,采用ECA集成模块并引入QFL改进的损失函数提升了模型检测精度;此外,本文算法相较于主流检测算法在精度上实现不同幅度的提升,检测速度提升明显。因此,改进模型对于航拍绝缘子缺陷图像的检测效果优于其他方法,能快速、精确实现复杂背景下的绝缘子缺陷检测。

## 参考文献

- [1] 商俊平,李储欣,陈亮.基于视觉的绝缘子定位与自爆缺陷检测[J].电子测量与仪器学报,2017,31(6):844-849.
- [2] 蔡彪,沈宽,付金磊,等.基于Mask R-CNN的铸件X射线DR图像缺陷检测研究[J].仪器仪表学报,2020,41(3):61-69.
- [3] 李鑫,刘帅男,杨桢,等.基于改进Cascade R-CNN的输电线路多目标检测[J].电子测量与仪器学报,2021,35(10):24-32.
- [4] JIANG H, QIU X, CHEN J, et al. Insulator fault detection in aerial images based on ensemble learning with multi-level perception[J]. IEEE Access, 2019: 61797-61810.
- [5] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector [C]. European Conference on Computer Vision, Springer, 2016: 21-37.
- [6] 汪权,易本顺.基于Gaussian YOLOv3的航拍图像绝缘子缺陷识别[J].激光与光电子学进展,2021,58(12):1210022.
- [7] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. ArXiv Preprint, 2018, ArXiv:1804.02767.
- [8] 崔江波,侯兴松.基于注意力机制的YOLOv4输电线路故障检测算法[J].国外电子测量技术,2021,40(7):24-29.
- [9] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv:2004.10934.
- [10] 马耀名,张雨.基于改进Faster-RCNN的绝缘子检测算法[J].计算机应用,2022,42(2):631-637.
- [11] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(6): 1137-1149.
- [12] 赵锐,赵国伟,张娟,等.改进CenterNet的高压输电线路巡检故障实时检测方法[J].计算机工程与应用,2021,57(17):246-252.
- [13] ZHOU X, WANG D, KRAHENBUHL P. Objects as points[J]. ArXiv Preprint, 2019, ArXiv:1904.07850.
- [14] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [15] ARTHUR D, VASSILVITSKII S. K-means ++: The advantages of careful seeding[C]. Proceedings of the 18th Annual ACM-SIAM Symposium on Discrete Algorithms. Philadelphia, PA:SIAM,2007: 1027-1035.
- [16] LI X, WANG W, WU L, et al. Generalized focal loss: learning qualified and distributed bounding boxes for dense object detection[J]. Advances in Neural Information Processing Systems, 2020, 33: 21002-21012.
- [17] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [18] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenetv3 [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.

## 作者简介

- 马进,博士,副教授,硕士生导师,主要研究方向为人工智能在电力系统应用、神经网络建模。  
E-mail:majinwj@sina.com
- 白雨生,硕士研究生,主要研究方向为计算机视觉、图像处理在电力系统中的设计与应用。  
E-mail:351079342@qq.com