

DOI:10.16136/j.joel.2022.06.0712

基于轻量化 YOLOv4 的复杂场景绝缘子缺陷检测算法

李利荣^{1,2*}, 张云良¹, 陈 鹏¹, 张 开¹, 熊 炜^{1,2}, 巩朋成^{1,2}

(1. 湖北工业大学 电气与电子工程学院, 湖北 武汉 430068; 2. 湖北工业大学 太阳能高效利用湖北省协同创新中心, 湖北 武汉 430068)

摘要:针对目前高压线路绝缘子缺陷检测速度慢, 复杂场景下精度低的问题, 提出一种基于轻量化 YOLOv4 (you only look once) 的复杂场景绝缘子缺陷检测算法。首先利用轻量级的 ECA-GhostNet (efficient channel attention GhostNet) 作为骨干网络, 以提升检测速度; 然后在预测层引入分类-定位质量估计联合表示方法, 并采用广义分布表示边界框的灵活分布, 以提升复杂场景下的检测性能。训练阶段分别采用定位质量损失函数 (quality focal loss, QFL) 与分布损失函数 (distribution focal loss, DFL) 更好地监督联合表示与边框回归。将该算法在具有复杂背景的数据集上对正常与自爆缺陷绝缘子两类目标进行验证实验, 结果表明, 该算法在复杂场景下的检测精度均优于目前主流算法, 且检测速度达 49 FPS, 比 YOLOv4 原始算法检测速度提升了约 40%。

关键词: 绝缘子; YOLOv4 算法; 联合表示; 缺陷检测; 广义分布

中图分类号: TP183; TP391.43 **文献标识码:** A **文章编号:** 1005-0086(2022)06-0598-09

Insulator defect detection algorithm for complex scenes based on lightweight YOLOv4

LI Lirong^{1,2*}, ZHANG Yunliang¹, CHEN Peng¹, ZHANG Kai¹, XIONG Wei^{1,2}, GONG Pengcheng^{1,2}

(1. School of Electrical & Electronic Engineering, Hubei University of Technology, Wuhan, Hubei 430068, China; 2. Hubei Collaborative Innovation Center for High-efficiency Utilization of Solar Energy, Hubei University of Technology, Wuhan, Hubei 430068, China)

Abstract: Aiming at the problem of current slow detection speed of insulator defects in high-voltage lines and low accuracy in complex scenarios, this paper proposes an insulator defect detection algorithm for complex scenes based on lightweight you only look once (YOLOv4). Firstly, the lightweight efficient channel attention GhostNet (ECA-GhostNet) is used as the backbone to improve the detection speed. Then the classification-IoU joint representation is introduced in the head, and the general distribution is utilized to represent the flexible distribution of the bounding boxes to improve detection performance in complex scenes. In the training phase, quality focal loss (QFL) and distribution focal Loss (DFL) are used to better supervise joint representation and bounding boxes regression. Proposed method verifies the two types of targets of normal and self-explosive defective insulators on a dataset with complex background. The results shows that the detection accuracy of our approach in complex scenes is better than the current mainstream algorithms, and the detection speed reaches 49 FPS, which is about 40% higher than the original YOLOv4 algorithm's detection speed.

Key words: insulator; YOLOv4 algorithm; joint representation; defect detection; general distribution

* E-mail: Rongli@hbut.edu.cn

收稿日期: 2021-10-17 修订日期: 2021-11-20

基金项目: 国家自然科学基金(62071171)、湖北省自然科学基金(2019CF530)和新能源及电网装备安全检测湖北省工程研究中心 2021 年度开放研究基金(HBSKF20212)资助项目

1 引言

绝缘子是高压输电线路的关键部件之一,主要起支撑和固定作用,并将高压输电线与地之间形成良好的绝缘。受外部恶劣气候及环境的影响,绝缘子极易受到损坏,导致出现污秽、裂纹、掉串、自爆等缺陷^[1],因此对高压输电线路的绝缘子进行定期巡检是十分必要的。

目前无人机航拍是高压输电线路绝缘子巡检的重要方法,但采用人工判别方法处理大量的航拍图片效率很低,故研究者将图像处理技术引入到绝缘子缺陷检测中。传统的绝缘子缺陷检测算法主要包括边缘检测、阈值分割与纹理特征检测3类^[2],ZHAO等^[3]针对传统边缘检测算法对复杂背景绝缘子图像检测效果差的问题,提出将NSCT(non subsampled contourlet transform)应用到绝缘子图像边缘检测中;HUANG等^[4]提出一种基于遗传算法的最大阈值绝缘子图像分割算法;PENG等^[5]根据绝缘子串具有周期性重复纹理的特点,提出一种红外图像绝缘子自动定位方法。但上述传统检测方法只能在特定环境下对绝缘子进行局部定位和缺陷检测,且在复杂场景下检测精度较低、实时性较差。

自2012年AlexNet算法在ImageNet比赛中获得冠军后,深度学习重新引起了广泛关注,采用基于深度卷积神经网络(convolutional neural network, CNN)的目标检测算法进行绝缘子巡检成为新趋势。TAO等^[6]提出一种基于CNN的级联结构进行绝缘子缺陷检测,第1级网络采用区域建议网络实现绝缘子定位,第2级网络识别缺陷的具体位置。MIAO等^[7]提出一种基于SSD(single shot multibox detector)与两阶段微调策略的绝缘

子识别方法,先利用具有广泛特性的航拍绝缘子图像建立基本绝缘子模型,再根据实际场景的绝缘子尺寸对基本模型进行微调,上述两阶段方法相比传统方法能一定程度提高检测精度但无法实现端到端的检测。故研究者^[8,9]通过采用改进的(Faster recurrent convolutional neural network, Faster RCNN)算法实现端到端的绝缘子缺陷检测,但其模型计算量大、检测速度慢。为此研究者^[10,11]提出采用YOLO(you only look once)系列算法进行绝缘子缺陷的实时检测,但由于YOLO算法存在分类与定位质量估计使用不一致问题,且其是在狄拉克 δ (dirac-delta)分布下进行边界框回归,缺乏对标签不确定性的估计,从而导致在复杂场景下对绝缘子及其缺陷的定位不准确。

针对上述问题,本文提出一种基于轻量化YOLOv4^[12]的复杂场景绝缘子缺陷检测算法,采用改进的GhostNet^[13]作为基础骨干网络,提取绝缘子及缺陷特征;预测层引入分类-定位质量估计联合表示的方法^[14],并利用广义分布^[15]取代狄拉克 δ 分布表示边界框的灵活分布,训练时采用文献[15]中提出的定位质量损失函数(quality focal loss, QFL)与分布损失函数(distribution focal loss, DFL)优化联合表示与边框回归。将本文算法与目前主流目标检测算法进行对比实验,结果表明本文算法在降低模型复杂度,提升网络检测速度的同时,有效提升了复杂场景下绝缘子识别与缺陷检测性能。

2 YOLOv4 算法及 GhostNet 网络

2.1 YOLOv4 算法

YOLOv4是YOLO系列算法的4版,其整体网络结构如图1所示,骨干网络采用CSPDarknet53,




图1 YOLOv4 算法的网络框架

Fig. 1 The network structure of the YOLOv4 algorithm

其是在 Darknet53 的基础上融合了跨阶段局部网络结构(cross stage partial network, CSPNet),有效解决了网络推理过程中不同层之间梯度信息重复的问题,减少了模型计算量,同时保证了准确率。骨干网络的最后输出层加入了一个空间金字塔池化模块(spatial pyramid pooling, SPP),利用 4 个卷积核大小分别为 1×1 、 5×5 、 9×9 、 13×13 的最大池化层对输出特征图进行 4 次并行的池化操作,然后进行特征拼接(concat),使输出获得更加丰富的感受野。

将骨干网络最后 3 个大残差块的输出作为不同的目标尺度,结合路径聚合网络结构(path aggregation network, PANet)构成特征融合层,左侧先进行自上而下的上采样,再进行自下而上的下采样后得到 3 个多尺度融合后的输出,将 3 个输出分别输入 YOLOhead(you only look once head)预测层得到 3 个预测结果 $76 \times 76 \times 21$ 、 $38 \times 38 \times 21$ 、 $19 \times 19 \times 21$,分别用于小、中、大 3 个尺度目标的检测。

2.2 GhostNet 网络

GhostNet 是一个新颖的轻量级端侧神经网络结构。由于标准卷积输出特征图彼此间具有高度相似性的特点, GhostNet 采用一种计算简便的 Ghost 模块来生成相似特征图,如图 2 所示是该模块的示意图。




图 2 Ghost 模块示意图

Fig. 2 Schematic diagram of Ghost module

假设标准卷积输入为 $X \in R^{c \times h \times w}$, 输出通道数为 n , Ghost 模块则将标准卷积操作分成两个部分:一部分使用少量的标准卷积核生成 m 个原始特征图,即图 2 中的 Identity 操作,其运算过程可表示为:

$$G' = X * f', \quad (1)$$

式中, $*$ 表示卷积操作, $f \in R^{c \times k \times k \times m}$ 为卷积核,且 $m \leq n$, 卷积核大小、步长及填充等超参数与标准卷积相同,以保证输出特征图的高和宽保持一致。另一部分则采用简便的线性运算从原始的特征图中生成 s 个相似特征图,其运算可以表示为:

$$g_{ij} = \Phi_{ij}(g'_j), \quad \forall i = 1, \dots, m; j = 1, \dots, s, \quad (2)$$

式中, g'_i 为 m 个原始特征图中的第 i 个特征图, Φ_{ij} 为第 j 个线性运算,用于生成相似特征图 g_{ij} 。通过采用线性运算可以产生 $m \times s$ 个输出特征图,从而避免了使用大量卷积运算,极大地减少了参数数量和计算量。GhostNet 整体沿用了 MobileNetV3 的架构,将由 Ghost 模块构成的瓶颈层代替 MobileNetV3 中的瓶颈层,并加入 SE(squeeze-and-excitation)通道注意力模块,用于更好地提取特征。

3 绝缘子缺陷检测整体网络框架

本文提出的网络模型如图 3 所示。根据上述 2.2 节的分析,为了提升检测速度,将 YOLOv4 的骨干网络用 GhostNet 代替 CSPdarknet53,并对 GhostNet 做进一步改进:1) 将 SE 模块采用更加轻量化且高效的通道注意力机制 ECA(efficient channel attention)模块^[16]代替,减小模型计算量;2) 移除网络最后的平均池化层、 1×1 卷积层和全连接层(fully connected layers, FC),并将网络第 5、12、18 3 层的输出 $f_1(76 \times 76 \times 40)$ 、 $f_2(38 \times 38 \times 112)$ 、 $f_3(19 \times 19 \times 960)$ 作为绝缘子的 3 个不同尺度特征用于特征融合,提升小目标的检测效果。对 GhostNet 改进后得到 ECA-GhostNet,其整体网络结构如表 1 所示。特征融合层仍采用 YOLOv4 算法中的 PANet 结构和 SPP 结构, f_1 、 f_2 和 f_3 经过特征融合后得到 $m_1(76 \times 76 \times 20)$ 、 $m_2(38 \times 38 \times 40)$ 和 $m_3(19 \times 19 \times 80)$ 3 个输出,分别用于小、中、大三个尺度目标的检测。

为提升复杂场景下绝缘子的检测效果,本文对预测层进行改进。针对 YOLOv4 算法分类与定位质量估计(intersection over union, IoU)使用不一致的问题,受文献[14]的启发,在预测层引入分类-定位质量估计联合表示的方法,以获取高质量的预测框,并利用 QFL 损失函数监督联合表示。YOLOv4 算法的边框定位是在狄拉克 δ 分布下学习,但在复杂场景中常存在模糊和不确定的目标,例如由于遮挡、模糊等原因,导致许多目标的边界不清晰,如图 4 所示。

此时,狄拉克 δ 分布无法准确地描述边界框的灵活分布,因此根据文献[15]中所提出的对于边框回归的改进思路,本文采用一种更加灵活的广义分布实现边框的概率建模,并利用广义分布的统计量指导定位质量估计,以获得可靠的 IoU 得分。此外,使用 DFL 损失函数监督边框回归,使网络快速地聚焦到真实框附近的坐标。YOLOhead 经过改进后得到图 3 中的 CIJhead(classification-IoU joint head)。




图 3 绝缘子缺陷检测整体网络框架

Fig. 3 Overall network framework for insulator defect detection

表 1 ECA-GhostNet 整体网络结构

Tab. 1 Overall architecture of ECA-GhostNet

Input	Operator	# exp	# out	ECA	Stride
608×608×3	Conv2d	-	16	-	2
304×304×16	G-bneck	16	16	-	1
304×304×16	G-bneck	48	24	-	2
152×152×24	G-bneck	72	24	-	1
152×152×24	G-bneck	72	40	1	2
76×76×40	G-bneck	120	40	1	1
76×76×40	G-bneck	240	80	-	2
38×38×80	G-bneck	200	80	-	1
38×38×80	G-bneck	184	80	-	1
38×38×80	G-bneck	184	80	-	1
38×38×80	G-bneck	480	112	1	1
38×38×112	G-bneck	672	112	1	1
38×38×112	G-bneck	672	160	1	2
19×19×160	G-bneck	960	160	-	1
19×19×160	G-bneck	960	160	1	1
19×19×160	G-bneck	960	160	-	1
19×19×160	G-bneck	960	160	1	1
19×19×160	Conv2d	-	960	-	1

3.1 ECA

ECA 模块是对通道注意机制 SE 的改进,SE 模块使用 2 个 FC 和 1 个 Sigmoid 激活函数生成通道权值信息,2 个 FC 的主要作用是跨通道交互和对输入特征向量进行降维以减小模型复杂度,但其降维操作丢失了大量通道与权值信息之间对应关系,对通道注意力预测起了反作用;此外,使用 FC 获取所有通道间的依赖关系是低效的、也是不必要的。而 ECA 采用一种不降维的局部跨通道交互策略,使用一个快速一维卷积进行局部跨通道信息交互,并自适应地选择一维卷积核大小进而确定局部跨通道交互的覆盖率,在减小模型复杂度和参数数量的同时提高了通道注意力的学习效率。

图 5 是 ECA 模块的示意图,先将大小为 $W \times H \times C$ 的输入特征向量利用全局平均池化(global average pooling, GAP)进行特征聚合,然后使用一维卷积进行局部跨通道交互:

$$\omega = \sigma(\text{Conv1D}_k(T)), \quad (3)$$




图 4 模糊与不确定目标样本

Fig. 4 Fuzzy and uncertain target samples




图 5 ECA 模块示意图

Fig. 5 The schematic diagram of ECA module

式中, Conv1D 表示一维卷积, $\mathbf{T}$ 为输入特征向量, σ 表示 Sigmoid 激活函数, k 为局部跨通道交互的覆盖率, 即一维卷积核大小, 其可以根据输入特征的通道数 C 自适应地确定。

$$k = \Psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}}, \quad (4)$$

式中, b 和 γ 是常量, 分别设置为 1 和 2, $|t|_{\text{odd}}$ 表示 k 取离 t 最近的奇数。

3.2 CIJhead 预测层

在 YOLOv4 算法中, 训练和测试过程中存在分类与 IoU 使用不一致的问题: 分类过程能够将少量正样本与负样本一起训练, 而定位质量估计只训练正样本; 但在测试时, 非极大抑制 (non-maximum suppression, NMS) 会将所有样本的分类得分值与 IoU 得分值相乘用于排序, 导致一部分分类得分较低的真实负样本, 其定位质量预测由于未受监督而获得一个极高的 IoU 分数, 从而导致这些负样本的 NMS 排序超过真正的正样本。故本文在预测层引入分类-定位质量估计联合表示方法避免上述不一致问题。图 3 最右侧虚线框为 CIJhead 的整体结构, 其中 **Branch1** 代表分类分支, **Branch2** 代表回归分支, 其中回归分支采用广义分布对边界框进行建模: 给定标签 y 的范围 $y_0 \leq y \leq y_n$, 则边界框的预测值为:

$$\hat{y} = \int_{-\infty}^{+\infty} P(x) x dx = \int_{y_0}^{y_n} P(x) x dx; y_0 \leq \hat{y} \leq y_n. \quad (5)$$

因连续积分无法在 CNN 中实现, 因此需将连续域上的积分转换成离散形式, 把连续区间 $[y_0, y_n]$ 离散成一个集合 $\{y_0, y_1, \dots, y_n\}$, 取间隔为 1, 利用采样点到边框四边的相对偏移量作为回归目标, 如图 6 所示。




图 6 广义分布示意图

Fig. 6 The schematic of general distribution

将边框左、右、上、下四边分别标记为 l, r, t, b , 则边框的广义分布即为 $P^m = \{P^m(y_0), P^m(y_1), \dots, P^m(y_n)\}$, 其中 $m \in \{l, r, t, b\}$, 且满足 $\sum_{i=0}^n P^m(y_i)$

$= 1$, 此时边框预测值又可以表示为:

$$\hat{y} = \sum_{i=0}^n P^m(y_i) y_i. \quad (6)$$

图 3 预测层中 **Branch3** 为定位质量估计分支, 该分支利用广义分布指导定位质量估计: 取回归分支学习到的广义分布中的 Top- k 个概率值及其均值, 并将它们进行拼接作为基本统计特征输入 **Branch3** 分支。

$$\mathbf{F} = \text{Concat}(\{\text{Topkm}(P^m) \mid m \in \{l, r, b, t\}\}), \quad (7)$$

式中, $\text{Concat}(\cdot)$ 为通道拼接操作, Topkm 为计算 Top- k 值及其均值的联合操作。定位质量估计分支采用两个全连接层, 后分别接 ReLU 和 Sigmoid 激活函数实现定位质量估计, 式(8)是其前向传播过程。

$$\mathbf{I} = \sigma(\mathbf{W}_2 \eta(\mathbf{W}_1 \mathbf{F})), \quad (8)$$

式中, η 与 σ 分别表示 ReLU 和 Sigmoid 激活函数, 且 $\mathbf{W}_1 \in R^{p \times 4(k+1)}$, $\mathbf{W}_2 \in R^{1 \times p}$, k 是 Top- k 中取值的个数, 本文 k 取 4; p 是 FC 隐层的维度, p 取 64, 则联合表示输出为:

$$\mathbf{J} = \mathbf{Branch1} \times \mathbf{Branch3}. \quad (9)$$

3.3 损失函数

3.3.1 QFL

QFL 损失函数是对 FL(Focal Loss) 损失函数的改进, FL 的提出是为了解决在单阶段目标检测算法中存在的前景和背景类之间不平衡的问题, 但其只适用于离散标签, 而本文在引入分类-定位质量估计联合表示后, 标签变为 0—1 之间的连续值, 因此原始的 FL 损失函数不再适用, 故 QFL 损失函数针对上述问题做了以下改进: 1) 将 FL 中 $-\log(\cdot)$ 部分扩展为完整的交叉熵; 2) 将动态缩放因子扩展为连续标签 y 与联合表示输出 α 的绝对值, 即:

$$\text{QFL}(\alpha) = -|y - \alpha|^\beta ((1 - y) \log(1 - \alpha) + y \log(\alpha)), \quad (10)$$

式中, β 为一个可调参数, 本文取 $\beta = 2$; 与 FL 损失函数类似, QFL 由完整交叉熵与缩放因子 $|y - \alpha|^\beta$ 组成, 缩放因子主要作用是减少易分类样本对损失的贡献, 使网络更加关注困难样本。

3.3.2 DFL

由于边框回归采用广义分布表示边界框的灵活分布, 而广义分布的取值是任意的, 故存在无穷多个组合可以使得最终的积分结果满足式(6), 导致网络学习效率低。因此本文引入 DFL 损失函数优化边框回归, 其通过明显地增大 y_i 与 y_{i+1} (离标签 y 最近的两个值, $y_i \leq y \leq y_{i+1}$) 的概率来使网络快速地专注于

学习目标边框 y 附近的坐标,从而提高网络的学习效率,加快收敛速度,其表达式如下:

$$\text{DFL}(S_i, S_{i+1}) = -((y_{i+1} - y) \log(S_i) + (y - y_i) \log(S_{i+1})). \quad (11)$$

因边框回归不存在类别不平衡的问题,故 DFL 损失函数只需采用交叉熵来实现,其中 S_i 、 S_{i+1} 分别表示 y_i 和 y_{i+1} 的广义分布的概率值。

4 实验结果与分析

4.1 实验数据集构建

本文数据集来源于 github 中由国家电网公开的数据集 InsulatorDataSet(<https://github.com/InsulatorD-ata>)和第八届“泰迪杯”数据挖掘挑战赛数据集(<http://www.tipdm.org/bdrace/tzbstysj/20200228/1637.html>)。其中 InsulatorDataSet 数据集中含有 848 张尺寸大小为 1152×864 的绝缘子图片,其中 600 张为正常绝缘子图片,248 张为合成的缺陷绝缘子图片;泰迪杯挑战赛数据集中含有 40 张高像素的玻璃绝缘子图片。为获得统一的训练数据集,本文对上述源数据集做如下处理:首先对 40 张高像素绝缘子图片进行 4×4 切割,并去除少量不包含绝缘子的图像,降低参数量的同时扩充数据集。然后将数据集的尺寸大小统一为 608×608 ,便于网络训练。因缺陷绝缘子数据集类型较单一且数量较少,为了加强网络的鲁棒性和泛化能力,防止训练中出现过拟合,对缺陷绝缘子数据集采用镜像、翻转、改变对比度和饱和度等方法进行数据增强。经过数据增强后,得到 1500 幅绝缘子图像,其中包括正常绝缘子图像 800 张,缺陷绝缘子图像 700 张。使用 LabelImg 标注软件进行标注,并将制作完成的数据集按 8:2 的比例随机划分为训练集和验证集。

4.2 实验环境及参数设置

本文所采用的实验环境为:Ubuntu18.04 操作系统、Pytorch1.7 深度学习框架、Python3.8、GeForce RTX 2080 显卡(11 GB 内存)。实验设置 batch_size 为 8,共训练 400 个 epoch,每个 epoch 迭代 151 次;初始学习率设置为 0.0001;采用 Multi-StepLR(多步长衰减)学习策略,衰减参数 gamma 设置为 0.8;初始动量设置为 0.9,权重衰减系数设置为 0.005,优化器采用 Adam。

4.3 实验内容

实验部分首先验证 ECA-GhostNet 骨干网络和 CIJhead 预测层的性能,然后将本文算法与当前主流的目标检测算法进行对比实验。为了综合评价不同

网络模型的性能,本文采用平均精度(average precision, AP)、均值平均精度(mean average precision, mAP)、计算量(FLOPs)、参数量(parameters)及检测速度(detection speed)作为评价指标。AP 是目标检测中评价单一类检测精度的重要指标,其等于精确度(P)与召回率(R)构成曲线所围成的面积,即式(13)所示。本文分别取阈值(IoU)为 0.5、0.75 及 0.5—0.95(IoU 从 0.5 取到 0.95,步长 0.05,并求均值)下的 $AP_{0.5}$ 、 $AP_{0.75}$ 、 $AP_{0.5:0.95}$ 3 个值。

$$\begin{cases} P = \frac{TP}{TP + FP} \\ R = \frac{TP}{TP + FN} \end{cases}, \quad (12)$$

$$AP = \int_0^R P(r) dr, \quad (13)$$

式中,TP 为真正例,即正样本被正确识别为正样本的数量,FP 为假正例,即负样本被错误识别为正样本的数量,FN 为假负例,即正样本被错误识别为负样本的数量。mAP 即对所有类别的 AP 求平均,本文检测目标包含正常绝缘子与自爆缺陷绝缘子两类,则 mAP 可表示为:

$$mAP = \frac{AP_{\text{insulator}} + AP_{\text{defect}}}{2}. \quad (14)$$

FLOPs 指浮点运算次数,即为计算量,目标检测中常用该指标衡量模型的复杂度。FPS 为网络每秒处理图片的数量,常用来衡量模型的检测速度。

4.3.1 ECA-GhostNet 性能验证实验


为验证 ECA-GhostNet 的性能,使 YOLOv4 其他部分不变,分别以 GhostNet 及 ECA-GhostNet 作为骨干网络进行训练。表 2 给出了两种骨干网络的实验结果,表中 N 为正常绝缘子,F 为自爆缺陷绝缘子,结果表明,采用 ECA-GhostNet 时,不同阈值下的 AP 值均有提升,其中缺陷绝缘子的 $AP_{0.5:0.95}$ 和 $AP_{0.75}$ 分别提升了 1.6% 和 5.7%。表明 ECA 比 SE 对缺陷具有更优的检测效果。

表 2 不同骨干网络性能对比实验

Backbones	$AP_{0.5:0.95} / \%$		$AP_{0.5} / \%$		$AP_{0.75} / \%$	
	N	F	N	F	N	F
GhostNet	64.1	49.9	96.5	96.9	78.6	41.3
ECA-GhostNet (ours)	64.2	51.5	96.9	97.6	77	47.0

图 7 是利用 Grad-CAM 方法得到的热力图可视

化结果对比,从图中可看出 ECA-GhostNet 的热力图区域能够更好地覆盖目标区域,并能够充分利用目标区域周围的关联信息。



(a) Original image (b) GhostNet (c) ECA-GhostNet

图 7 不同骨干网络 Grad-CAM 可视化

Fig. 7 Grad-CAM visualization of different backbone networks

表 3 广义分布与分类-定位质量估计联合表示性能验证实验

Tab. 3 Verification experiment of general distribution and classification-IoU joint representation

Methods	$AP_{0.5:0.95}/\%$		$AP_{0.5}/\%$		$AP_{0.75}/\%$	
	N	F	N	F	N	F
Branch1+Branch2(Dirac)	55.0	49.6	81.4	90.1	61.7	43.3
Branch1+Branch2(General)	74.2	56.9	95.8	97.5	87.4	57.9
Branch1+Branch2(General)+Branch3	74.8	59.5	97.2	99.3	86.9	68.9

注:N代表正常绝缘子,F代表自爆缺陷绝缘子。

表 4 不同预测层性能对比实验

Tab. 4 Comparative experiments of different head

Heads	$AP_{0.5:0.95}/\%$		$AP_{0.5}/\%$		$AP_{0.75}/\%$	
	N	F	N	F	N	F
YOLOhead	64.1	51.5	96.9	97.6	77.0	47.0
CIJhead(ours)	74.8	59.5	97.2	99.3	86.9	68.9

4.3.3 不同检测算法对比实验

为了验证本文算法性能的优越性,将其与 Faster RCNN^[17]、SSD^[18]、YOLOv3^[19] 分别进行对比实验,表 5—表 7 分别给出了不同算法测试后获得的各项性能指标。表 5 为本文算法与其他 4 种主流算法的绝缘子识别与缺陷检测精度比较,从 mAP 看,本文算法在 IoU 阈值为 0.5、0.75 及 0.5—0.95 时的 mAP 分别为 98.3%、77.9%和 67.2%,相比于其他

4.3.2 CIJhead 性能验证实验

为了验证引入广义分布及分类-定位质量估计联合表示的效果,对两者进行验证实验,实验结果如表 3 所示。其中 **Branch2**(Dirac)表示回归分支采用狄拉克分布,**Branch2**(General)表示回归分支采用广义分布,**Branch3** 为定位质量估计分支。通过结果发现:预测层同时引入广义分布和定位质量估计分支的效果是最好的,绝缘子缺陷的 $AP_{0.5:0.95}$ 和 $AP_{0.5}$ 分别达到 59.5%和 99.3%,相比于回归分支,使用狄拉克分布时分别提升 9.9%和 9.2%,检测性能提升明显。

为验证所改进预测层的效果,分别以 CIJhead 和 YOLOhead 作为预测层进行训练。实验结果如表 4 所示,改进后的预测层在不同阈值下的 AP 值均有大幅提升,其中正常绝缘子的 $AP_{0.5:0.95}$ 提升了 10.7%,缺陷绝缘子对应的 $AP_{0.75}$ 提升了 21.9%。表明 CIJhead能够在复杂场景下获得更加精确的边框定位。

4 种模型均有不同程度提升,其中 $mAP_{0.5:0.95}$ 相较 Faster RCNN 和 SSD 分别提升了 22%和 11.8%,提升幅度较大,较 YOLOv4 原始算法提升 7.9%。从单类别 AP 看,本文算法在不同阈值下对绝缘子缺陷的检测精度相比于其他 4 种方法有明显提高,其中 $AP_{0.75}$ 和 $AP_{0.5:0.95}$ 相比 YOLOv4 分别提升 16.6%和 7%,表明本文改进算法对复杂场景下的绝缘子与缺陷具有更精确的定位效果。

表 6 给出了本文算法与其他 4 种算法在计算量和参数量方面的对比,从表中可以看出,YOLOv4 算法的计算量和参数量分别为 63.83 G 和 63.94 M,模型大小为 256.2 M,对硬件设备的性能要求较高;而本文改进算法经过轻量化处理后,计算量和参数量减少到 1.78 G 和 2.09 M,比改进前分别降低了

97%和 96%,模型大小也由 256.2 M 减小到 8.7 M,说明本文改进后的算法能够满足轻量化和实时性的要求。

表 7 是本文算法与其余 4 种检测算法推理速度的对比。将不同算法在相同硬件设备使用同一张测

试图像前向推理 1 000 次,将其均值作为最终的推理速度。本文算法推理速度为 49 FPS,均高于其他 4 种网络模型的推理速度,相比 YOLOv4 的 35 FPS 提升了 40%。总体表明,本文算法在速度和精度两方面均优于原始 YOLOv4 和主流目标检测

表 5 不同检测算法性能对比实验

Tab. 5 Performance comparison experiments of different algorithms

Methods	$AP_{0.5 \pm 0.95} / \%$			$AP_{0.5} / \%$			$AP_{0.75} / \%$		
	N	F	mAP	N	F	mAP	N	F	mAP
Faster RCNN	66.5	23.8	45.2	96.3	70.5	83.4	79.5	7.0	43.3
SSD	68.5	42.3	55.4	90.7	93.7	92.2	80.4	24.3	52.3
YOLOv3	73.0	51.2	62.1	97.2	96.0	96.6	86.3	42.8	64.5
YOLOv4	66.0	52.5	59.3	97.1	96.9	97.0	78.3	52.3	65.3
Our approach	74.8	59.5	67.2	97.3	99.3	98.3	86.9	68.9	77.9

算法。

表 6 不同检测算法计算量与参数量对比

Tab. 6 Comparison of FLOPs and parameters in different algorithms

Methods	FLOPs/G	Parameters/M	Weights/M
Faster RCNN	188.53	136.73	546.8
SSD	87.86	24.53	196.3
YOLOv3	155.00	61.51	246.4
YOLOv4	63.83	63.94	256.2
Our approach	1.78	2.09	8.7

表 7 不同检测算法推理时间与检测速度对比

Tab. 7 Comparison of inference speed of different algorithms

Methods	Inference time /ms	Detection speed/FPS
Faster RCNN	55.00	18
SSD	29.41	34
YOLOv3	25.00	40
YOLOv4	28.57	35
Our approach	20.40	49

4.4 实验结果可视化

本节将本文算法与其他 4 种算法的测试结果进行可视化,如图 8 所示,图 8(a)是本文算法测试结果,(b)、(c)、(d)和(e)分别对应 YOLOv4、SSD、YOLOv3 及 Faster RCNN 的可视化结果。图中虚线框为真实框。

从图 8(a)可以看出,本文算法的绝缘子与缺陷预测框几乎与真实框完全重合,相比于其他 4 种算法边框定位更加精确;此外,从第 2、3 行检测结果看,本文算法在模糊与遮挡的复杂场景下对绝缘子及其缺陷具有更好的检测效果,再次表明本文算法比目前主流检测算法具有更优的检测性能。

5 结 论

本文提出一种基于轻量化 YOLOv4 的复杂场景绝缘子缺陷检测算法。该算法利用 ECA-GhostNet




图 8 不同算法测试结果可视化

Fig. 8 Visualization of test results of different algorithms

网络提取绝缘子及缺陷特征,在预测层引入分类-定位质量估计联合表示的方法,并采用广义分布代替狄拉克 δ 分布优化边框回归,训练过程中利用 QFL 损失函数和 DFL 损失函数监督联合表示和边框回归。实验结果表明,本文算法在复杂场景下比目前主流检测算法检测性能更优,且参数量与模型复杂度大幅减小,检测速度比 YOLOv4 原始算法提升 40%,充分说明了本文改进算法的优越性。下一步研究工作是在保证检测精度的同时,进一步减小网络复杂度,提升检测速度。

参考文献:

- [1] LV Z N. Summary of analysis and detection methods of common faults in transmission lines[J]. Automation & Instrumentation, 2020(1): 161-164, 168.
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.
- [2] GAO J C, ZHANG J H, LI Y N, et al. Research on insulator burst fault identification based on YOLO-v4 [EB/OL]. (2021-04-09)[2021-08-19]. <https://kns.cnki.net/kcms/detail/31.1690.TN.20210409.0942.052.html>.
高健宸, 张家洪, 李英娜, 等. 基于 YOLOv4 的绝缘子爆裂故障识别研究[EB/OL]. (2021-04-09)[2021-08-19]. <https://kns.cnki.net/kcms/detail/31.1690.TN.20210409.0942.052.html>.
- [3] ZHAO Z B, JIN S X, LIU Y C. Aerial insulator image edge extraction method based on NSCT[J]. Chinese Journal of Scientific Instrument, 2012, 33(9): 2045-2052.
- [4] HUANG X N, ZHANG Z L. A method to extract insulator image from aerial image of helicopter patrol[J]. Power System Technology, 2010, 34(1): 194-197.
- [5] PENG X Y, LIANG F X, QIAN J J, et al. Automatic recognition of insulator from UAV infrared image based on periodic textural feature[J]. High Voltage Engineering, 2019, 45(3): 922-928.
- [6] TAO X, ZHANG D P, WANG Z H, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 50(4): 1486-1498.
- [7] MIAO X R, LIU X Y, CHEN J, et al. Insulator detection in aerial images for transmission line inspection using single shot multibox detector[J]. IEEE Access, 2019, 7: 9945-9956.
- [8] HUO H T, MIN Y Z, YANG K, et al. Research on detection algorithm of catenary insulator based on improved Faster R-CNN[C]//Proceedings of the 2020 Chinese Automation Congress, November 6-8, 2020, Shanghai, China. New York: IEEE, 2020: 3814-3818.
- [9] ZHAO Z B, ZHEN Z, ZHANG L, et al. Insulator detection method in inspection image based on improved faster RCNN[J]. Energies, 2019, 12(7): 1204-1219.
- [10] SADYKOVA D, PERNEBAYEVA D, BAGHERI M, et al. IN-YOLO: real-time detection of outdoor high voltage insulators using UAV imaging[J]. IEEE Transactions on Power Delivery, 2020, 35(3): 1599-1601.
- [11] WANG S H, NIU L L, LI N. Research on image recognition of insulators based on YOLO algorithm[C]//Proceedings of the 2018 International Conference on Power System Technology, November 6-8, 2018 Guangzhou, China. New York: IEEE, 2018: 3871-3874.
- [12] BOCHKOVSKIY A, WANG C Y, MARK LIAO H Y. YOLOv4: Optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2021-08-19]. <https://arxiv.org/abs/2004.10934>.
- [13] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations [C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE, 2020: 1577-1586.
- [14] LI X, WANG W H, HU X L, et al. Generalized focal loss V2: learning reliable localization quality estimation for dense object detection[EB/OL]. (2020-11-25)[2021-08-19]. <https://arxiv.org/abs/2011.12885>.
- [15] LI X, WANG W H, WU L J, et al. Generalized focal loss: learning qualified and distributed bounding boxes for dense object detection[EB/OL]. <https://arxiv.org/abs/2006.04388>.
- [16] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE, 2020: 11531-11539.
- [17] 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.
- [18] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//Proceedings of the 2016 European Conference on Computer Vision (CVPR), October 11-14, 2016, Amsterdam, USA. Berlin, Heidelberg: Springer, 2016: 21-37.
- [19] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL]. (2018-08-08)[2021-08-19]. <https://arxiv.org/abs/1804.02767>.

作者简介:

李利荣 (1974—), 女, 博士, 讲师, 硕士生导师, 主要研究方向为计算机视觉、图像分析与处理。