

DOI: 10.13382/j.jemi.B2206039

绝缘子自爆缺陷的轻量化检测网络 DE-YOLO^{*}

贾晓芬^{1,2} 吴雪茹¹ 赵佰亭¹
(1. 安徽理工大学电气与信息工程学院 淮南 232001; 2. 安徽理工大学省部共建深部煤矿
采动响应与灾害防控国家重点实验室 淮南 232001)

摘 要:为了实现输电线路的高精度、高速度巡检,设计了一种适用于移动终端设备的轻量化目标检测网络 DE-YOLO。首先融合深度可分离卷积、逐点卷积和 ECA 注意力机制提出了特征提取模块 NewC3,它负责显著降低网络参数、同时强化网络提取绝缘子有效信息的能力。再借助通道数成倍增长策略和通道注意力机制 SE 设计了轻量化模块 DC-SE,它用于削弱复杂背景对绝缘子故障的干扰、互补提取绝缘子细微特征,进而增强浅层网络对目标特征信息的提取能力。实验表明,DE-YOLO 网络在自制绝缘子数据集上的 GFLOPs 降低 45%,运行参数降低 42%,自爆缺陷检测精度高达 93.2%。NewC3 和 DC-SE 能保证 DE-YOLO 的轻量化,同时满足绝缘子自爆缺陷实时检测的要求。

关键词:绝缘子;自爆缺陷;深度学习;注意力机制;深度可分离卷积

中图分类号: TM769 **文献标识码:** A **国家标准学科分类代码:** 470.4017

Lightweight detection network for insulator self-detonation defect DE-YOLO

Jia Xiaofen^{1,2} Wu Xueru¹ Zhao Baiting¹
(1. China Institute of Electrical and Information Engineering, Anhui University of Science and Technology,
Huainan 232001, China; 2. State Key Laboratory of Mining Response and Disaster Prevention and Control
in Deep Coal Mines, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: In order to meet the requirements of high detection accuracy, fast inspection speed and easy to be embedded in mobile devices, a lightweight object detection structure DE-YOLO is designed for mobile terminal devices. Firstly, combining depth-separable convolution, point-by-point convolution and ECA attention mechanism, the feature extraction module NewC3 is proposed, which is responsible for significantly reducing network parameters and strengthening the ability of network to extract effective insulator information. Then, the lightweight module DC-SE is designed with the help of channel number multiplication strategy and channel attention mechanism SE. It is used to weaken the interference of complex background to insulator fault, extract the subtle features of insulator complementary, and then enhance the extraction ability of target feature information of shallow network. Experiments show that the GFLOPs of DE-YOLO network on the expanded Homemade insulator data dataset are reduced by 45%, the running parameters are reduced by 42%, and the detection accuracy of self-exploding defects is up to 93.2%. NewC3 and DC-SE can ensure the lightweight of DE-YOLO and meet the requirements of real-time detection of self-exploding insulator defects.

Keywords: insulator; self-exploding defect; deep learning; attention mechanism; depth-separable convolution

0 引言

输电线路是电网系统的重要组成部分,研究如何更安全、快捷地对输电线路进行监测是十分必要的^[1]。绝缘子作为输电线路中机械支撑和电气绝缘支撑部件,对输电线路的安全运行起到至关重要的作用。绝缘子长期暴露在自然环境下容易发生自爆、掉串、污秽等故障,绝缘子一旦发生缺陷等故障,将直接影响到输电线路的使用和寿命^[2-3]。

输电线路铺设范围广,地理位置特殊,传统巡检大都采用人工作业,但是人工巡检方式不仅效率低且在不同巡检环境下受地理环境影响,视觉上容易产生误判、漏检等问题^[4]。随着无人机技术的不断发展,使用搭载可见光或红外摄像的无人机设备进行巡查,逐渐成为输电线路巡检的重要方式之一。利用搭载深度学习算法的无人机装置进行巡检,很大程度上解决了人工巡检作业危险、效率低、人工成本高等实际问题^[5-7]。

智能通信与控制设备在电力系统中的应用,能够增加故障检测的可靠性和便利性。近年来,深度学习领域的学者在绝缘子检测方向开展了很多研究工作,其主流研究方向分为两种:一是通过优化二阶网络或采用较大网络模型直接提升网络检测精度。二是随着 YOLO 系列网络的不断优化,通过训练单阶段轻量化网络以实现轻量化实时检测。

提升网络检测精度的典型成果包括,Zhao 等^[8]在二阶模型 Faster R-CNN 的基础上采用金字塔策略,优化复杂背景下绝缘子的特征提取能力。Feng 等^[9]对 YOLOv5x 较大网络模型优化 K-means 聚类算法,提升网络对绝缘子目标的检测精度。以上改进虽然提升了网络的检测精度,但是模型参数量大、运算过程复杂对于移动设备的算力仍然是个极大的挑战,无法满足无人机巡检的实际应用需求。

致力于轻量化的代表成果包括,Zhang 等^[10]在 YOLOv3 的基础上提出密集金字塔结构,提高网络深层语义信息利用率、轻量化网络体积。刘行谋等^[11]利用 YOLOv4 单阶段检测网络的特性训练模型,通过改进平衡交叉熵以及 SPP 结构的方式提高网络的检测精度。颜宏文等^[12]将 YOLOv5 主干网络替换为 shuffleNetV2 网络,将 PANet 下采样网络替换为深度可分离卷积以达到降低网络参数的目的。以上几种单阶检测网络优化后对网络参数与模型体积进行大幅降低和压缩,但是在无人机设备巡检中对绝缘子自爆缺陷的检测效果较差。

为了解决绝缘子缺陷检测阶段目标检测算法运算复杂、模型体积庞大导致算法部署到无人机嵌入式设备较困难的问题,设计了特征提取模块和轻量化模块,提出绝

缘子自爆缺陷的轻量化检测网络 DE-YOLO,它在保证对模型体积进行压缩的同时使检测精度也取得较为满意的结果。

1 DE-YOLO 轻量化检测模型

实现架空线路中的绝缘子缺陷特征在复杂背景下的自动识别以及轻量化智能检测网络嵌入无人机移动设备,一直以来都是利用无人机装置对架空线路自动巡检的两大行业难题。在单阶段 YOLO 系列算法中 YOLOv5s 算法相较于其他目标检测算法,无论在检测精度还是检测速度上都有较好的表现。为此,以 YOLOv5s 作为骨干网络,设计一种用于绝缘子自爆缺陷智能检测的轻量化网络 DE-YOLO,网络结构如图 1 所示,它包含主干网络 (Backbone)、颈部特征融合 (Neck) 以及预测输出 (Output) 3 部分,主要创新点包含两部分:

1) 设计特征提取模块 NewC3。将原始网络 C3 模块中的 bottleneck 优化为由深度卷积、逐点卷积与通道注意力机制组成的 New-bottleneck-1 与 New-bottleneck-2(前者含跳跃连接),并构成 NewC3-1 和 NewC3-2,分别应用到 Backbone 和 Neck 中。此设计在降低模型参数的同时,通过结合通道信息增强网络对绝缘子有效特征的提取能力。

2) 设计轻量化模块 DC-SE。在 Backbone 中,融合传统卷积与深度卷积,随着网络不断加深利用数目成倍增长的卷积逐步扩大通道数量,助力绝缘子特征的互补提取。同时,引入注意力机制 SE 强化主干网络对细节特征的表达能力,提高网络对不同尺寸绝缘子图像的特征融合能力,改善特征融合过程对细节信息的丢失问题,从而加强浅层网络对绝缘子自爆缺陷特征的检测性能。

1.1 NewC3 模块设计

YOLOv5s 采用 C3^[13] 模块进行特征提取与融合,C3 结构中 bottleneck 模块采用传统卷积与 BN、SiLU 激活函数直接堆叠而成,网络在特征提取与融合过程中容易丢失细节信息,且该模块使用较多的传统卷积进行特征提取,导致网络的参数量很大。

输电线路中绝缘子的特征信息与背景信息较为相似,且绝缘子的故障点相对整张图像而言属于小目标。为了充分提取绝缘子上的小目标特征并解决原始 C3 模块所带来的问题,设计 NewC3- j ($j=1,2$) 模块,如图 2 所示。每个 NewC3- j 模块由 x 个 New-bottleneck j 与 2 个卷积模块 (Conv+BN+SiLU) 组成,Conv+BN+SiLU 由 1×1 传统卷积、BN 归一化以及 SiLU 激活函数组成,其通道数为 NewC3- j 模块的输入通道数。

New-bottleneck j 模块由 3×3 深度卷积、逐点卷积和 ECA 构成,分为 New-bottleneck1 与 New-bottleneck2 两种




图 1 DE-YOLO 网络结构

Fig. 1 DE-YOLO structure diagram




图 2 New-C3 模块结构图

Fig. 2 New-C3 Module structure diagram

结构。New-bottleneck1 输入与输出之间采用残差连接, 残差连接用于优化主干网络可以缓解梯度爆炸问题。New-bottleneck2 采用串行的方式进行信息传输, 因为其作用于颈部的融合结构, 直接输出的方式更大程度上保留融合特征信息。Backbone 中含有 4 个 NewC3-1, 该模块依次含有 3、6、9、3 个 New-bottleneck1。Neck 中含有 4

个 NewC3-2, 其中均含 3 个 New-bottleneck2。

绝缘子图像进入 New-bottleneck j 模块首先经过 3×3 的深度卷积进行特征提取, 深度卷积与逐点卷积组成的深度可分离卷积^[14]负责降低网络的参数量。假设输入特征图尺寸是 $H \times W \times C_x$, 输出特征图尺寸是 $H \times W \times C_y$, 则经过传统卷积处理的运算量与经过深度可分离卷积的运算量之比为:

$$\frac{P_{sum}}{P_{conv}} = \frac{H \times W \times 1 \times C_x + 1 \times 1 \times C_x \times C_y}{(H \times W \times C_x) \times C_y} = C_y + \frac{1}{(H \times W)^2} \quad (1)$$

其中, P_{sum} 表示深度可分离卷积总参数, P_{conv} 表示传统卷积总参数; $H \times W \times 1$ 是深度卷积的卷积核大小, C_x 为卷积核个数, $1 \times 1 \times C_x$ 为逐点卷积核大小, C_y 为逐点卷积核个数; $H \times W \times C_x$ 为传统卷积核大小, C_y 为传统卷积核个数。

由式(1)可知, 采用 3×3 深度卷积与 1×1 逐点卷积处理后, 参数量约为传统卷积的 $1/9$, 深度可分离卷积在保证提取更多特征属性的同时减少了更多的参数量^[15]。

逐点卷积负责将深度卷积生成的特征进行新的通道拼接, 随后将信息传入 ECA^[16] 注意力机制进行处理。绝缘子独特的重复式螺旋构造使其特征信息在局部具有相似性, ECA 模块采用一种更有效的学习方式, 通过内核的快速一维卷积来共享相同的学习参数, 让模型具有更

轻体积的同时有效捕获了跨通道交互、强化了网络提取绝缘子有效信息的能力、提高了特征融合的质量进一步提高了网络检测精度。

1.2 DC-SE 轻量化模块设计

YOLOv5s 主干网络中采用大量由 3×3 传统卷积、归一化模块与激活函数串行的卷积块进行特征提取。传统卷积对输入的图像进行特征提取,使得网络对自爆缺陷较小的像素信息提取能力稍有不足,且参数量较大,难以在使用较小算力的情况下更最大限度地提取有效特征信息。此外,主干网络所处理的特征图中包含着大量的目标信息,但是浅层网络的感受野较小、提取有效特征有限、容易丢失局部信息,难以对输入的图像信息全面的感知和提取^[17]。为解决上述问题,设计一种基于深度卷积的轻量化模块 DC-SE,结构如图 3 所示。




图 3 DC-SE 模块结构

Fig. 3 DC-SE Module structure diagram

DC-SE 模块通过 1 个 1×1 卷积和 d 个深度卷积串联并经 BN 处理和 SiLU 激活后再与 1×1 卷积拼接,实现特征提取,它能在一定程度上保留原始特征信息,避免了网络对自爆缺陷的小目标提取不充分的问题。然后利用通道注意力机制 SE^[18] 解决输电线路巡检时所拍摄图片背景复杂干扰信息过多的问题。SE 模块通过全局池化将每个通道的权重信息提取出来,进一步强化了主干网络对绝缘子自爆缺陷的特征提取能力,提高目标检测的精确度^[19]。

在 Backbone 中使用 4 个 DC-SE 模块,其中深度卷积的数量分别为 128、256、512、和 1 024,它们利用数目成倍增长的卷积逐步扩大通道数,强化提取绝缘子上的小缺陷特征。DC-SE 模块的计算过程为:

$$Y_0 = \text{Conv}(K_i) \quad (2)$$

$$Y_1 = \text{Concat}(Dw_d(\dots Dw_2(Dw_1(Y_0))), Y_0) \quad (3)$$

$$K_{i+1} = SE(Y_1) \quad (4)$$

其中, Y_0 表示对输入 $K_i (i=1, 2, \dots, n)$ 经 Conv 卷积提取的特征图, Y_1 表示对 Y_0 Dw 卷积后再和 Y_0 拼接的结果, K_{i+1} 表示 SE 模块最终提取的特征图。

DC-SE 模块在对通道信息全局提取的同时,借助 SE 自适应学习不同通道之间的依赖关系,自适应的增强目标的特征像素,削弱复杂背景信息对绝缘子故障检测的干扰,在扩大浅层网络感受野的同时保证网络对缺陷的精准提取。

2 实验与结果分析

2.1 绝缘子数据集

绝缘子图像数据来自中国电力绝缘子数据集 (CPLID), 并收集了某地区实际输电线路的绝缘子图像。由于原始数据集数量较少,且样本数目不平衡,故采用随机 HSV、镜像翻转、随机去除等方式进行数据增强,如图 4 所示。将数据集扩充至 4 000 张,按照 7:2:1 划分训练集、验证集与测试集。划分完成后使用 LabelImg 标注工具,将图片进行逐一标注。




图 4 图像扩充样例

Fig. 4 Sample image expansion

2.2 实验环境与评价指标

设备配置: NVIDIA GeForce RTX2080Ti 的 GPU, Intel Core i7-10700k @ 3.80 GHz 的 CPU, Windows10 系统, 基于 Pytorch 框架, Cuda10.0、Cudnn7.6.5 加速, 实验参数如表 1 所示。

表 1 实验参数

Table 1 Experiment parameter

实验参数	参数量
Epoch	200
Batch size	8
Learning rate	0.001
Optimizer	SGD
Size	640

选用 Parameter、GFLOPs 与 @mAP0.5 作为网络模型性能的评价指标。精准率的计算如式(5)所示,召回率的计算如式(6)所示,AP 计算基于式(7),@mAP0.5 表示阈值为 0.5 时,每个检测种类的平均 AP。其中,预测值为正样本记为 P (positive),预测值为负样本记为 N (negative),预测正确记为 T (true),预测错误记为 F

(false), 预测值与真实值一致时记为 TP, 预测值与真实值不一致时记为 FN, 预测值与真实值不一致时记为 FP。

$$Precision = \frac{TP}{TP + FP} \tag{5}$$

$$Recall = \frac{TP}{TP + FN} \tag{6}$$

$$AP = \int_0^1 P(R) dR \tag{7}$$

2.3 验证 DE-YOLO 网络的合理性

1) 消融实验

为了验证 DE-YOLO 网络设计的轻量性与合理性,需要验证 NewC3 和 DC-SE 模块的效果,其中 NewC3 模块中主要是验证 New-bottleneck (同时使用 New-bottleneck1 和 New-bottleneck2) 的作用。为此,开展表 2 所示的 4 个实验,其中“√”表示使用了该模块,实验 1 为不添加任何改进模块的 YOLOv5s 原网络,实验 2、3、4 分别为引入 DC-SE 模块,引入 New-bottleneck 模块与同时引入两种模块后的 DE-YOLO 轻量化网络。

表 2 消融实验结果

Table 2 Ablation experiment results

Test	DC-SE	New-bottleneck	Parameter/M	GFLOPs	@ mAP0.5
1			7.2	16.0	93.0%
2	√		6.2	13.9	92.4%
3		√	5.0	10.6	93.5%
4	√	√	4.2	8.8	93.2%

由表 2 可知,实验 1 中原始 YOLOv5s 模型参数量为 7.2 M,浮点运算为 16.0,其检测精度为 93.0%。实验 2 是在 YOLOv5s 的主干网络中使用 DC-SE 模块进行特征提取,替换后网络的参数量下降了 13.8%,浮点运算量降低 13%,网络检测精度仅损失 0.6%;实验 3 将 YOLOv5s 的 C3-bottleneck 模块替换为 New-bottleneck 模块后参数量减少了 30%、浮点运算量降低了 33.8%,检测精度相较于原网络有较大提升,高达 93.5%;实验 4 在网络中同时引入 New-bottleneck 模块与 DC-SE 模块,模型参数量低至 4.2 M,大幅度压缩了近 42%,浮点运算降低至 8.8 减少了 45%且检测精度高达 93.2%。

综上,NewC3 和 DC-SE 模块的设计是合理的,NewC3 在降参的同时会使精测精度略有降低,DC-SE 在降参的同时还能有效提高检测精度。两个模块能够保证 DE-YOLO 在高效检测绝缘子自爆缺陷的同时实现网络轻量化。

2) 检测精度及损失

公平起见,使用 YOLOv5s 网络的损失函数测试 DE-YOLO 网络的效果。图 5 与 6 分别为 DE-YOLO 网络与 YOLOv5s 网络的检测精度和损失值对比结果。由图 5 可

以看出 DE-YOLO 网络收敛速度相对于 YOLOv5s 有较快提升且趋于稳定,训练 200 批次后其检测精度高于 YOLOv5s。由图 6 可以看出 DE-YOLO 网络在 80 批次左右损失趋于稳定,且其训练损失和验证损失在收敛后都低于 YOLOv5s 的损失值。综合上述对比结果,表明 DE-YOLO 网络相较于 YOLOv5s 网络有较快的收敛速度和较好的鲁棒性。




图 5 准确率对比

Fig. 5 Accuracy comparison chart




图 6 损失对比

Fig. 6 Loss comparison chart

综上,引入 DC-SE 模块后在牺牲极小检测精度的情况下,通过深度卷积与普通卷积拼接的信息提取策略,大大降低了网络参数。引入 New-bottleneck 模块,使用深度可分离卷积显著降低模型复杂度的同时,依托轻量化注意力机制跨信道交互策略,增强了浅层网络对绝缘子目标特征的提取能力,进一步提升了网络的检测精度。New-bottleneck 与 DC-SE 模块同时作用时,在压缩模型体积与降低运行参数方面的优化能力可以达到令人满意的结果,对绝缘子有效特征提取的能力也达到较为理想的状态,可以实现在复杂背景下对绝缘子进行较高精度的自爆缺陷检测。

2.4 验证 DE-YOLO 网络的性能

为了验证 DE-YOLO 的检测效果,将它与 Faster R-CNN^[20]、SSD^[21]、YOLO 系列^[22-23] 5 个经典目标检测网络,在增强后的绝缘子数据集上开展对比试验,结果如表 3 所示。

表 3 不同检测模型对比实验结果

Table 3 Comparative experiment of different detection models

网络结构	Parameter/M	GFLOPs	Precision	Recall	@ mAP0.5
Faster R-CNN	72.4	26.8	91.8%	90.89%	94.3%
SSD	25.6	33.6	79.5%	75.1%	81.9%
YOLOv3	62.5	156.1	91.5%	89.9%	93.6%
YOLOv4	52.5	119.7	88.8%	89.1%	92.6%
YOLOv5s	7.2	16.0	88.7%	90.2%	93.0%
DE-YOLO	4.2	8.8	90.7%	90.3%	93.2%

由表 3 可知,二阶目标检测网络 Faster R-CNN 检测精度比单阶网络 YOLO 系列仅高了 1% 左右,但在模型体积与浮点运算量上却远超 YOLOv5s 网络数十倍,在无人机巡检的应用中是不可行的。SSD 网络检测精度最低,为 81.9% 且网络模型体积较大,运算复杂。YOLOv3 网络的检测精度可达 93.6%,模型体积达 62.5 M 远超 DE-YOLO 数十倍,其浮点运算量更是高达 156;YOLOv4 网络检测为 92.6%,其模型体积与浮点运算量较为庞大不利

于绝缘子自爆缺陷实时检测。DE-YOLO 网络在网络深度减少的同时,模型体积仅为 4.2 M,相较于 YOLOv5s 网络的模型体积压缩了 41.6%、浮点运算降低了 45%,检测精度也有所提升可达 93.2%。由上述实验结果可知,DE-YOLO 网络拥有较好的鲁棒性与较低的模型复杂度,各项性能均达到令人满意的水准,更适合应用在无人机巡检绝缘子的移动设备中。

为了直观显示 DE-YOLO 网络的检测效果,图 7 分别给出了 YOLOv5s、DE-YOLO 网络在简单背景、复杂背景以及实况拍摄下的检测效果。图 7(a) 中简单环境下绝缘子自爆缺陷检测精度仅为 72%,表明 YOLOv5s 模型对小目标缺陷的提取能力较弱;DE-YOLO 网络以 93% 较高的精度定位出绝缘子的位置,缺陷检测精度为 75%,实现了绝缘子特征的有效提取。图 7(b) 中面对复杂背景 YOLOv5s 对自爆缺陷检测准确率仅为 77%;DE-YOLO 网络不仅以高达 94% 的准确率定位出绝缘子位置,更以 87% 的准确率检测出绝缘子自爆的小目标缺陷。图 7(c) 中 YOLOv5 以及 DE-YOLO 网络对实际拍摄图像检测平均精度均可达到 88.8%,符合实际检测应用。可见,DE-YOLO 网络即使在不同复杂程度背景下仍具有较高的检测精度,且在模型轻量化方面可以满足移动设备的应用。




图 7 YOLOv5s 与 DE-YOLO 不同背景下的检测效果
Fig. 7 Comparison of detection effects between YOLOv5s and DE-YOLO in different background

3 结 论

文中针对绝缘子自爆缺陷提出的轻量化检测网络 DE-YOLO,能解决无人机在绝缘子自爆缺陷检测中遇到

的目标特征提取不充分、目标与背景特征易混淆、网络运算量大不易嵌入在移动设备等难题,经过消融与对比实验论证了:New-C3 模块,在特征提取 New-Bottleneck 部分提出的结合注意力机制 ECA 模块的轻量化结构,通过结合深度卷积、逐点卷积与注意力机制,可以在减少网络参

数、压缩模型体积的同时,进一步削弱背景信息的干扰、增强网络提取目标特征的能力。DC-SE 模块,在主干网络使用深度卷积减少网络运算,通过传统卷积与深度卷积信息拼接的操作更好地保留了输入图像的细节信息,引入通道注意力 SE 机制可以增强浅层网络的语义信息提取能力,极大地提高网络检测精度。

在对绝缘子数据集进行扩充后,经大量实验证明,DE-YOLO 轻量化网络模型参数量仅为原网络的 57%,检测精度高达 93.2%,无论是在压缩模型体积还是提升检测精度等方面都有着令人满意的效果,这对于推进无人机巡检领域中的深度学习技术的开发和应用有一定意义。

参考文献

- [1] 江秀臣,刘亚东,傅晓飞,等. 输配电设备泛在电力物联网建设思路与发展趋势[J]. 高电压技术,2019,45(5):1345-1351.
JIANG X CH, LIU Y D, FU X F, et al. The idea and development trend of ubiquitous power iot construction [J]. High Voltage Technology, 2019, 45(5): 1345-1351.
- [2] 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.
LYU ZH N. Survey of common fault analysis and detection methods for transmission lines [J]. Automation and Instrumentation, 2020(1): 161-164, 168.
- [3] TAO X, ZHANG D, WANG Z, 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, 2018, 50(4): 1486-1498.
- [4] YAN D. Research and application status of industrial robot control system [C]. International Conference on Mechanical, Control and Computer Engineering (ICMCCE), 2018: 16-20.
- [5] 温新叶,杨忠伟,陈昌. 输电线路无人机智能巡检应用研究[J]. 中国设备工程,2021(23):31-32.
WEN X Y, YANG ZH W, CHEN CH. Research on intelligent inspection application of UAV for transmission line [J]. China Equipment Engineering, 2021 (23): 31-32.
- [6] 陈庆,闫斌,叶润,等. 航拍绝缘子卷积神经网络检测及自爆识别研究[J]. 电子测量与仪器学报,2017,31(6):942-953.
CHEN Q, YAN B, YE R, et al. Aerial insulator convolution neural network detection and explosive identification study [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31 (6): 942-953.
- [7] ALAHYARI A, HINNECK A, TARIVERDIZADEH R, et al. Segmentation and defect classification of the power line insulators: A deep learning-based approach [C]. 2020 International Conference on Smart Grids and Energy Systems (SGES), 2020:476-481.
- [8] ZHAO W, XU M, CHENG X, et al. An insulator in transmission lines recognition and fault detection model based on improved faster RCNN[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-8.
- [9] FENG Z, GUO L, HUANG D, et al. Electrical insulator defects detection method based on YOLOv5 [C]. 2021 IEEE 10th Data Driven Control and Learning Systems Conference (DDCLS), 2021: 979-984.
- [10] ZHANG X, ZHANG Y, LIU J, et al. InsuDet: A fault detection method for insulators of overhead transmission lines using convolutional neural networks [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.
- [11] 刘行谋,田浩,杨永明,等. 复杂环境背景下绝缘子缺陷图像检测方法研究[J]. 电子测量与仪器学报, 2022,36(2):57-67.
LIU X M, TIAN H, YANG Y M, et al. Insulator defect images under the complex background of environmental detection method research [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (2): 57-67.
- [12] 颜宏文,万俊杰,潘志敏,等. 基于改进 YOLOv5-Lite 轻量级的配电组件缺陷识别[J/OL]. 高电压技术:1-10.
YAN H W, WAN J J, PAN ZH M, et al. Lightweight distribution component defect identification based on improved YOLOv5-lite [J/OL]. High Voltage Technology: 1-10.
- [13] WANG C, MARK LIAO Y, WU Y, et al. CSPNet: A new backbone that can enhance learning capability of CNN [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2020:1571-1580.
- [14] HOWARD A, ZHU M, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Hawaii: IEEE, 2017: 1704-1712.
- [15] 贾晓芬,于业齐,郭永存,等. 航拍绝缘子自爆缺陷的轻量化检测方法[J]. 高电压技术,2023,49(1): 294-300.
JIA X F, YU Y Q, GUO Y C, et al. Lightweight detection method of self-exploding defects of aerial insulator [J]. High Voltage Technology, 2023, 49(1):

- 294-300.
- [16] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 11534-11542.
- [17] 赵凤, 李永恒, 李晶, 等. 基于改进 YOLOv4-tiny 的轻量化室内人员目标检测算法 [J]. 电子与信息学报, 2022, 44(11): 3815-3824.
- ZHAO F, LI Y H, LI J, et al. Lightweight indoor person object detection algorithm based on improved YOLOv4-tiny [J]. Journal of Electronics and Information Technology, 2022, 44(11): 3815-3824.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [19] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized intersection over union: A metric and a loss for bounding box regression [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 658-666.
- [20] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. Advances in Neural Information Processing Systems, 2015, 28: 91-99.
- [21] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [22] REDMON J, FARHADI A. YOLOv3: An incremental

improvement [J]. arXiv preprint arXiv: 1804.02767, 2018.

- [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.

作者简介



贾晓芬, 2002 年于青岛科技大学获得学士学位, 2009 年于哈尔滨工业大学获得硕士学位, 2019 年于安徽理工大学获得博士学位, 现为安徽理工大学教授, 主要研究方向为深度学习、机器视觉、图像处理。
E-mail: jxfzbt2008@163.com

Jia Xiaofen received her B. Sc. degree from Qingdao University of Science and Technology in 2002, M. Sc. degree from Harbin Institute of Technology in 2009 and Ph. D. degree from Anhui University of Science and Technology in 2019. Now she is a professor at Anhui University of Science and Technology. Her research interests include deep learning, machine vision and image processing.



吴雪茹 (通信作者) 2021 年于柳州工学院获得学士学位, 现为安徽理工大学硕士研究生, 主要研究方向为图像处理、绝缘子故障检测。
E-mail: 442077478@qq.com

Wu Xueru (Corresponding author) received her B. Sc. degree from Liuzhou Institute of Technology in 2021. Now she is a M. Sc. candidate at Anhui University of Science and Technology. Her main research interests include image processing and insulator fault detection.