

DOI:10.19651/j.cnki.emt.2313971

# 基于改进 YOLOv7 的输电线路绝缘子识别检测研究<sup>\*</sup>

王伯涛 周福强 吴国新 王少红

(北京信息科技大学现代测控技术教育部重点实验室 北京 100192)

**摘要:** 针对绝缘子目标尺寸小导致检测精度低、误检漏检率高的问题,提出一种基于 YOLOv7 改进的输电线路绝缘子检测模型。首先,将双支路融合通道注意力机制与主干部分的 ELAN 模块进行融合,强调重要的通道信息,抑制噪声等无用信息的干扰;其次,在特征融合部分加入局部自注意力机制,使得局部微小区域局部关注度增强;同时,在 Neck 部分融入 BiFPN 跨层连接,在增加部分计算量的同时,使得边缘信息得到更好的保留,更利于小目标的检测;最后,以精确度、召回率、平均精度均值等作为评价指标,对采集的数据集进行了消融实验和对比实验。实验结果表明,改进后的网络模型对输电线路绝缘子检测精度为 92.1%,相比于传统的 YOLOv7 网络模型提高 3%,并且其平均检测均值、召回率分别提高 3.1%、3.6%;同时,改进的模型在各个评估指标上相比 YOLOv5-ECA 和 Faster-R-CNN 等均有显著优势,针对输电线路绝缘子检测具有良好效果。

**关键词:** 输电线路绝缘子;YOLOv7;双支路融合通道注意力机制;局部自注意力机制;BiFPN

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 510.4050

## Research on identification and detection of transmission line insulators based on improved YOLOv7

Wang Botao Zhou Fuqiang Wu Guoxin Wang Shaohong

(Key Laboratory of Modern Measurement & Control Technology Ministry of Education, Beijing Information  
Science & Technology University, Beijing 100192, China)

**Abstract:** Addressing the issue of low detection accuracy and high false positive and false negative rates caused by the small size of insulator targets, a transmission line insulator detection model based on the improved YOLOv7 is proposed. Firstly, the dual-branch fused channel attention mechanism is integrated with the main ELAN (encoder-local aggregation network) module to emphasize crucial channel information and suppress interference from noise and irrelevant data. Secondly, a locally self-attentive mechanism is introduced in the feature fusion section to enhance the focus on local tiny regions. Additionally, the BiFPN (Bi-directional feature pyramid network) cross-layer connection is incorporated in the Neck section to preserve edge information better and improve the detection of small targets while slightly increasing computational load. Lastly, using evaluation metrics such as precision, recall, and mean average precision, ablation experiments and comparative experiments are conducted on collected datasets. Experimental results indicate that the improved network model achieves a detection accuracy of 92.1% for transmission line insulator detection, a 3% enhancement over the traditional YOLOv7 network model. The average detection mean, recall rate, are also improved by 3.1% and 3.6% respectively. Furthermore, the improved model demonstrates significant advantages over YOLOv5-ECA and Faster R-CNN in various evaluation metrics, proving its effectiveness in detecting transmission line insulators.

**Keywords:** transmission line insulators; YOLOv7; dual-branch fusion channel attention mechanism; local self-attention mechanism; BiFPN

## 0 引言

随着电力工业的迅速发展,越来越多的电网设备在复

杂环境下得到建设和部署。这给电力系统设备的安全维护提出了更高的要求。其中,绝缘子作为保证输电线路正常运行的重要组成部分,扮演着至关重要的角色<sup>[1]</sup>。然而,由

收稿日期:2023-06-27

\*基金项目:北京信息科技大学勤信人才项目(QXTCP202120)资助

于长期暴露于恶劣的自然环境中,绝缘子常常会受到鸟啄、风蚀、覆冰施压、高温等多种不良因素的影响,从而导致不同程度的故障和缺陷。这些故障和缺陷给输电线路的稳定性带来了潜在的安全隐患<sup>[2]</sup>。因此构建对绝缘子的识别检测方法具有非常重要的现实意义。

随着人工智能领域的不断发展,基于深度学习的绝缘子定位检测已成为目前的潮流;以 YOLO(you only look once)为首的单阶段回归检测凭借着端到端高性能在绝缘子的检测中有一定的应用与研究。2019 年,吴涛等<sup>[3]</sup>将裁剪 MobileNetV1<sup>[4]</sup> 网络得到 Crop-MobileNet 作为 YOLOv3<sup>[5]</sup>的基础特征提取网络,并使用金字塔结构融合绝缘子特征,以完成物体定位及类别划分。Yao 等<sup>[6]</sup>提出一种 GIOU (generalized intersection over union) 和 YOLOv3 融合的绝缘子检测定位的方法。使得收敛速度更快,绝缘子的检测精度得到提升。但是测试结果中绝缘子目标漏检、误检情况比较大。2021 年,Han 等<sup>[7]</sup>提出了一种改进的 Tiny-YOLOv4 绝缘子破损识别算法,通过引入自注意力机制减少噪声信息的影响,并在特征融合层引入 ECA(efficient channel attention) 网络来增强模型特征提取能力,改进后的算法在实际应用中有显著提升。2022 年,王素珍等<sup>[8]</sup>在主干网络中引入 k3-Ghost 结构和 SENet (squeeze-and-excitation network) 模块,颈部引入 DC-BiFPN (dual-context bi-directional feature pyramid network) 结构使得改进后的模型检测准确率达到 89.5%。2023 年,宋智伟等<sup>[9]</sup>提出了一种基于 Flexible YOLOv7 的绝缘子缺陷检测算法;在特征提取的过程中集成 GAM (global attention module) 注意力机制,通过高效的 Ghost SPPCSPC 结构减少参数量,引入 EIOU (efficient intersection over union) Loss 提升原始模型的检测精度,实验结果表明,本文算法在密集目标、遮挡、小目标缺陷检测中具有显著提升。

针对以上改进的绝缘子检测研究方法,并结合自身数据集,共总结出如下问题:

1) 注意力机制大多仅在特征融合前一层引入,以实现对感兴趣区域的一次加强提取,部分目标检测准确率虽有提升,但针对小目标区域,仍存在高误检、漏检的问题。

2) 原始网络模型特征融合部分使用的是 PANet 结构,未充分考虑多尺度特征块间包含的空间信息和语义信息,缺少内部块之间的相互联系。

3) 本文自制数据集大多为小目标,样本数量分布不均匀且方向固定,不同角度或噪点引入可能会影响实际检测准确率。

如何提高小目标检测准确度,降低误检漏检率,是本文的难点。基于以上问题,本文提出改进的 YOLOv7 绝缘子识别检测算法;在数据集上,利用数据增广技术(翻转、明暗变化、噪点引入等),扩充数据集样本,使各类别样本数量达到均衡并扩充数据样本的形态,防止过拟合问题的发生;在

网络结构上,首先将双支路融合通道注意力机制与主干部分的高效聚合网络 (efficient local aggregation network, ELAN) 模块进行融合,进行第 1 次的兴趣区域关注度提升;其次,在主干网络输出的不同尺度特征图后加入结合 transformer 思想的局部自注意力机制,进行局部关注度二次提升;最后,在 Neck 部分引入双向特征金字塔网络 (Bi-directional feature pyramid network, BiFPN) 跨层链接思想;通过消融实验、不同模型对比实验以及可视化分析进行验证,证明了改进后模型的有效性。

## 1 改进 YOLOv7 的输电线路绝缘子检测算法

### 1.1 YOLOv7 网络模型

YOLOv7 主要由 4 部分构成:输入(input)、主干网络(backbone)、特征提取网络(neck)、检测头(head)<sup>[10]</sup>。首先将对检测图像输入到 backbone 网络中,然后经主干网络网络输出 3 层不同尺度大小的特征图,经过 detect 输出预测结果。YOLOv7 网络结构如图 1 所示。




图 1 YOLOv7 网络结构

### 1.2 双支路融合通道注意力机制

ELAN 是一个由多个复合卷积模块 (Conv2d + Batch Normalization + SiLU, CBS) 堆叠而成的高效网络结构,它通过控制最短和最长梯度路径,使网络能够学习更多的特征并具有更强的鲁棒性。ELAN 模块共包含两大分支,一个分支将输入特征图送入多层特征提取结构,另一分支直接送入卷积模块。最后利用通道间级联的方式将两分支输出的特征图进行融合。ELAN 具体结构如图 2 所示。




图 2 ELAN 结构

然而,不同通道捕获的特征是不同的,如果仅仅通过通道间级联的方式对特征进行融合,会忽略特征在通道间的相互依赖关系。为此,本文提出双支路融合通道注意力模块 (dual-branch fusion channel attention mechanism,

DFCA)。该模块能够动态调整所有通道映射对应的相关特征的重要性,从而选择性地强调重要的特征信息,抑制浅层特征中的噪声和其他干扰信息。<sup>[11]</sup> 双支路融合通道注意力模块结构如图 3 所示。




图 3 双支路融合通道注意力机制

首先,对输入的特征图分别进行平均池化和最大池化操作,帮助网络自动学习每个通道的关键信息,进而选择性地强调重要的特征,抑制不重要的特征。其次,对最大池化和平均池化结果分别进行  $1 \times 1$  卷积进行通道降维,并使用 ReLU 激活函数激活,对于两者输出的结果采用  $1 \times 1$  卷积进行升维并将两个注意力权重结果相加,使之特征信息得到交融。<sup>[12]</sup> 计算过程可由式(1)~(3)表示。

$$\beta_1 = C_s R(C_t(\text{Avgpool}(X))) \quad (1)$$

$$\beta_2 = C_s R(C_t(\text{Maxpool}(X))) \quad (2)$$

$$\beta = \text{Sig}(\beta_1 \oplus \beta_2) \quad (3)$$

最后,拼接后的各通道权重经 Sigmoid 函数激活后,与输入特征图进行逐元素相乘,从而得到经过通道注意力调控的输出特征图;输入特征图重新校准过程由式(4)表示:

$$X_2 = f_{\text{DFCA}}(X, \beta) \quad (4)$$

式中: $X$  表示输入特征图矩阵;Avgpool 为平均池化;Maxpool 为最大池化; $R$  为 ReLU 激活函数; $C_t$  和  $C_s$  分别表示降维卷积和升维卷积; $\beta_1$  和  $\beta_2$  表示通道注意力权重; $\oplus$  表示级联操作;Sig 表示 Sigmoid 函数; $f_{\text{DFCA}}$  表示输入特征图和级联后的通道注意力权重逐通道相乘; $X_2$  表示校准后的特征图。

最后,将双支路融合通道注意力模块添加至 ELAN 模块中,将 Concat 模块融合后的特征信息经过双支路融合通道注意力模块动态调整每个通道的权重,使网络自适应地选择和强调对于当前任务更有意义的特征,抑制浅层特征中的背景噪声等干扰信息,增强了通道内小尺寸特征的表达能力,从而改善了对小目标检测的整体性能。改进后的 ELAN 模块整体网络结构如图 4 所示。




图 4 改进的 ELAN 结构图

### 1.3 局部自注意力模块

针对绝缘子检测效果不佳且为更好地捕捉特征图中的细微变化和局部关联性,提高对局部重要特征的关注度。本文提出局部自注意力模块 (local self-attention mechanism, LSA)以实现特征的局部关注和增强,LSA 结构图如图 5 所示。




图 5 局部自注意力模块

首先,对于输入的特征经过查询(Query)、键(Key)和值(Value)卷积层,从中提取相应的特征表示。为了处理局部区域,特征图经过最大池化操作进行分割,得到查询、键和值的局部窗口特征图。其计算公式可由式(5)~(7)表示。

$$X_Q = \text{Maxpool}(Q(X)) \quad (5)$$

$$X_K = \text{Maxpool}(K(X)) \quad (6)$$

$$X_V = \text{Maxpool}(V(X)) \quad (7)$$

式中: $X$  表示输入特征图; $Q(\cdot)$ 、 $K(\cdot)$ 、 $V(\cdot)$  分别表示 3 种卷积层;

其次,通过卷积操作计算局部窗口内的注意力权重,将查询特征图与键特征图进行点积操作,再经过 Softmax 函数进行归一化,其计算过程可由式(8)表示。

$$X_1 = \delta(X_Q^T(X_K)) \quad (8)$$

式中: $T$  表示转置; $\delta$  表示 Sigmoid 函数; $X_1$  表示点积后的结果。

最后,将注意力权重与值特征图进行加权求和,调控得到最终的特征表示以实现对重要特征的关注程度和表示能力。其计算过程可由式(9)表示。

$$X_2 = A(X_1, X_V, X) \quad (9)$$

式中: $A$  表示加权求和操作; $X_2$  表示最终输出结果。

本文将提出的局部自注意力模块添加至主干网络输出的 3 种不同尺度特征图后,加入后的网络结构简图如图 6 所示。检测效果对比图如图 7 所示。




图 6 加入 LSA 模块的网络结构简图




图 7 检测效果对比

由图 7 可知,局部自注意力模块的加入,使得网络模型在特征增强、上下文信息整合两个方面均有显著提升,具体表现如下:

1)图 7(b)与(a)相比,在共同检测到的 4 个区域上,图 7(a)检测的置信度结果虽最高可达 0.90,但最低也达到 0.27,检测结果极不稳定;而图 7(b)检测到的置信度结果虽最高未达到 0.90,但均达到 0.80 以上,检测结果十分稳定。由此可得,LSA 的加入,使得模型能够更好地捕捉目标的细粒度特征,同时,重要的局部区域关注度以及目标的边界信息和细节特征也会得到增强,利于模型对预测结果的确定性程度提高。

2)在相同的输入数据、参数以及硬件配置下,原模型仅能检测出 4 个缺陷;而 LSA 的加入,使得边缘不易被检测的区域均被检测出来;由此可以看出,LSA 的加入,在整合局部区域内的上下文信息上,模型能够更好地理解目标在整个图像中的位置和语义信息,模型的感知力和理解力得到提高,有利于小目标的精准定位。

综上,局部自注意力模块的加入,能够帮助网络更好地理解输入数据的空间结构。在特征处理和整合上下文信息上均作出一定贡献,使网络能够更准确地感知目标的空间位置和关系,更好地处理目标的尺度变化、姿态变化和遮挡等复杂情况,提高了目标检测的精度和鲁棒性。

#### 1.4 跨层特征融合网络

YOLOv7 在特征融合部分使用的是路径聚合网络(path aggregation network, PANet)结构;它通过自顶向下和自底向上的路径在不同尺度上建立特征金字塔,用于对不同尺度的特征图进行融合。<sup>[13]</sup> PANet 结构如图 8 所示。

然而,PANet 结构的特征融合思想仅考虑同层路径的上一级和上层路径的横向一级特征;并没有充分考虑多尺度特征块间包含的空间信息和语义信息,缺少内部块之间的相互联系<sup>[14]</sup>,因此在小目标检测定位上容易出现误检漏检现象。其次,浅层特征中包含大量的边缘特征信息,有利于小目标的空间信息定位;但随着网络层数的加深,浅层特征保留下来的信息逐渐减少,使得小目标定位检测上受到不利影响;基于此,本文在 PANet 结构的基础上融合了跨层连接思想,将浅层特征信息与深层特征信息进行跨层




图 8 PANet 结构图

融合,在增加少量参数量的同时,聚合更多特征,保留了浅层边缘空间信息,利于小目标类别的定位检测。跨层特征融合网络如图 9 所示。




图 9 跨层特征融合网络

通过跨层链接,浅层的细节信息可以传递给深层,同时深层的语义信息也可以反馈到浅层,网络的多尺度感知能力和特征表达能力得到一定的提高,在小目标的检测中有一定积极意义<sup>[15]</sup>。

#### 1.5 改进的 YOLOv7 网络结构

改进后 YOLOv7 网络结构如图 10 所示;具体改进点包括:1)改进后的 ELAN 模块,针对重要通道的特征信息进行加强,减少了其他信息的干扰,利于后续特征融合部分有效进行;2)局部自注意力机制模块(LSA)模块的加入,使得贡献度大的局部细微区域关注度得到加强,利于小目标检测准确度的提高;3)在 Neck 部分融合了 BiFPN 跨尺度连接的思想,使得浅层边缘空间信息与深层语义信息得到充分融合。

## 2 实验设备及数据预处理

### 2.1 实验设备

本文的实验环境搭建在网络服务器上,硬件配置如表 1 所示。




图 10 改进的 YOLOv7 网络结构

表 1 实验所需配置信息

名称	配置信息
操作系统	Windows 10(X64)
GPU	RTX A5000
GPU 加速库	CUDA11.7
深度学习框架	Pytorch1.11.0
脚本语言	Python

## 2.2 数据预处理

本实验数据集原始图片 2 227 张,通过平移翻转、明暗增强、噪点引入等方式对原始数据集进行增强操作,最终获得数据集图片共约 8 900 张,按照 7:1:2 比例划分为训练集、验证集、测试集,通过 labelme 软件对数据集进行标注,数据集共分为 3 类:输电线路绝缘子良好为 good、绝缘子破损为 defect、绝缘子缺失为 insulator。随机图片数据增强效果图如图 11 所示,实际应用检测图如图 12 所示。




图 11 数据增强图




图 12 实际应用检测图

## 3 实验结果及分析

### 3.1 评估指标

为了评估改进后模型的性能,本文使用帧率(frame per second, FPS)、精确度(precision, P)、召回率(recall, R)、平均精确度(average precision, AP)和平均精度均值(mean average precision, mAP)作为检测效果的评价指标。<sup>[16]</sup>具体公式如下:

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

$$AP = \int_0^1 P(r) dr \quad (11)$$

$$mAP = \frac{\sum_k AP_k}{n} \quad (12)$$

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

式中: TP 为模型预测为正的正样本; FP 为模型预测为负的负样本; FN 为模型预测为正的负样本。

### 3.2 训练过程

训练检测网络模型时,将迭代次数设置为 400 次,权重衰减系数设置为 0.000 5,初始学习率设置为 0.001,动量参数设置为 0.937,批量大小(batch size)设置为 64。损失曲线及 mAP@0.5 曲线如图 13、14 所示,经过 400 次迭代后,loss 降低至 0.031 4,mAP@0.5 达到 93.5%。




图 13 loss 曲线




图 14 mAP@0.5 曲线

### 3.3 消融实验

本文改进的算法是以 YOLOv7 为基础模型进行改进;改进点包括如下 3 个部分:提出 DFCA 和 LSA 两个注意力模块,分别添加至主干网络特定部分;特征融合网络融合跨尺度连接思想。为验证以上改进点的有效性,在相同实验条件下,将不同模块分别加入到 YOLOv7 检测算法中,评估各模块对检测算法性能的影响,结果如表 2 所示。

表 2 消融实验对比结果

序号	模型				R/%	P/%	mAP@0.5/%	Speed/fps
	YOLOv7	DFCA	BiFPN	LSA				
1	√	—	—	—	87.0	89.1	90.6	66.0
2	√	—	√	—	87.7	90.0	91.0	65.2
3	√	—	—	√	90.0	91.2	93.1	65.7
4	√	√	—	—	89.2	90.6	92.7	67.2
5	√	√	√	√	90.6	92.1	93.7	65.8

实验结果发现,(序号 2) 特征融合网络融合跨尺度连接思想后,虽增加部分计算量导致检测速度略微降低,但其余各项模型评估指标均有小幅度上升,其中 R、P、mAP@0.5 分别上升 0.7%、1.1%、0.4%;(序号 3) LSA 的加入,使得局部微小区域关注度显著增强,与原模型相比小目标检测性能明显提高,R、P、mAP@0.5 分别上升 3%、2.1%、2.5%;(序号 4) 双支路融合通道注意力机制(DFCA)模块的加入,提高主干网络 ELAN 模块特征提取的性能,通过调整不同通道权重使得输出不同尺度的特征图更顺应当前检测的要求,该模块的融入在模型检测性能和推理速度上显著提升,使得 R、P、mAP@0.5 分别上升 2.2%、0.7%、1.1%;(序号 5) 改进后的 YOLOv7 融合以上所有模块,在各项指标上有了明显提高,和传统的 YOLOv7(序号 1)相比,R 提升了 2.4%,精确率 P 上升了 3%,mAP@0.5 提高了 3.1%,但在检测速度上下降 0.2 fps。综上所述,整体改进后的 YOLOv7 算法虽在检

测速度上略微降低,但在其余各项属性中均有显著提升,明显优于原始和其他模型。故本文改进的算法对于输电线路绝缘子检测的效果比传统的 YOLOv7 表现更优秀,能够较为准确的检测识别出相关物体。

### 3.4 不同算法对比

为了更好的评估改进后的 YOLOv7 网络模型在该数据集上的检测性能,本文在相同实验环境及参数配置下,采用 Faster-RCNN、YOLOv5 等主流 YOLO 目标检测算法及本文算法分别进行了检测实验;以 mAP@0.5 和检测速度作为衡量水平好坏的标准,通过实验对比,进一步验证本文算法的有效性;检测结果如表 3 所示。

从表 3 中 4 种算法的比较可以看出,改进的 YOLOv7 算法与 Faster-RCNN 相比,mAP@0.5 提升 11.7%,检测速度提高了 15.2fps;与 YOLOv5 和 YOLOv5-tiny 相比,mAP@0.5 分别提升 7.5%、7%,检测速度分别提高了 13.5、8.2 fps;与其他改进后的网络模型(YOLOv5-ECA、

表 3 不同算法对比

检测模型	mAP@0.5	Speed/fps
Faster-RCNN	82.0	50.6
YOLOv5	86.2	52.3
YOLOv5-tiny	86.7	57.6
YOLOv5-ECA	92.1	62.2
YOLOv7-多注意力融合	93.1	54.1
改进的 YOLOv7	93.7	65.8

YOLOv7-多注意力融合)相比, mAP @ 0.5 分别提升 1.6%、0.6%, 检测速度分别提高了 3.6、11.7 fps; 综上所述, 本文算法在 mAP@0.5 和检测速度上均优于上述所有算法, 效果显著, 表明了所提方法的有效性。

### 3.5 可视化对比

本数据集共包含 3 种类别, 针对 3 种不同类别的图片进行了改进模型的针对性类别检测, 检测结果如表 4 所示; 由表可知, 在 YOLOv7 模型中, good 类别的图片检测准确度良好, 能达到 96%; 而 defect 和 insulator 类别的图片因尺寸小, 背景模糊, 噪点多等因素的影响, 导致误检漏检率高, 进而影响整个数据集的整体准确度, 导致整体检测效果不佳, defect 和 insulator 类别的检测准确度仅有 73.6% 和 83.2%; 在改进后的 YOLOv7 模型中, 3 种类别

的检测准确度均有显著提升, 尤其是在 defect 和 insulator 类别检测上, 与原模型相比, P 分别上升 10.7%、7.4%, 虽然依旧存在一定的错误率, 但整体检测效果得到了明显的改善。

表 4 不同类别检测结果对比

类别	检测数量	P/%	
		YOLOv7	改进的 YOLOv7
good	427	96.0	98.8
defect	521	73.6	84.3
insulator	469	83.2	90.6

为了更加直观看到改进后的 YOLOv7 模型在针对 defect 和 insulator 等小目标检测过程中的优越性; 随机选取测试集中 defect 和 insulator 两类别的两张样本进行可视化对比; 如图 15 所示; 每张可视化对比图从左到右依次是, 原图、YOLOv7 检测、改进后的 YOLOv7 检测; 通过两组图片的可视化对比, 可以清晰的看到, YOLOv7 模型在绝缘子缺失和破损类别较多时, 漏检、误检明显; 改进后的 YOLOv7 在两类别的检测中有了明显的提升, 虽不能达到 100% 检测率, 但在小目标检测中起到了至关重要的作用。




图 15 可视化对比图

## 4 结 论

本文基于 YOLOv7 提出了一种改进的目标检测算法: 双支路融合通道注意力机制(DFCA)的加入, 使得主干网络 ELAN 模块在特征提取后能动态调整不同通道的权重, 利于输出的不同尺度特征图在 Neck 更好的融合; 局部自注意力模块(LSA)的提出, 使得贡献度大的局部细微区域关注度增强, 改善了小目标误检漏检的问题; BiFPN 跨尺度连接思

想的融合, 缩短浅层特征和高层特征融合的路径, 使得浅层边缘特征和定位信息可以更好与高层语义信息进行充分融合。最后通过消融实验和不同模型对比实验证可得, 本文算法在各项指标上均优于传统的 YOLOv7 算法, 对于后续输电线路绝缘子检测具有一定的参考意义。在未来的研究工作中, 将会在该模型的研究基础上, 尝试模型剪枝、引入轻量化卷积等手段, 对参数量和计算量进行降低处理, 在保证精确度的同时, 提升模型的检测速度。

**参考文献**

- [1] 许爱华,陈佳韵,张明文,等.基于改进的 YOLO v4 绝缘子目标识别算法研究[J].吉林大学学报(信息科学版),2023,41(3):545-551.
- [2] 张鋆,王继业,宋睿,等.基于边缘智能的输电线路异常目标高效检测方法研究[J].电网技术,2022,46(5):1652-1661.
- [3] 吴涛,王伟斌,于力,等.轻量级 YOLOv3 的绝缘子缺陷检测方法[J].计算机工程,2019,45(8):275-280.
- [4] CAI K, MIAO X, WANG W, et al. A modified YOLOv3 model for fish detection based on MobileNetv1 as backbone [J]. Aquacultural Engineering, 2020, 91: 102117.
- [5] FARHADI A, REDMON J. YOLOv3: An incremental improvement [C]. Computer Vision and Pattern Recognition. Berlin/Heidelberg, Germany: Springer, 2018:1804. 02767.
- [6] YAO L, QIN Y Y. Insulator detection based on GIOU-YOLOv3 [C]. 2020 Chinese Automation Congress (CAC), IEEE, 2020:5066-5071.
- [7] HAN G J, HE M, ZHAO F, et al. Insulator detection and damage identification based on improved lightweight YOLOv4 network[J]. Energy Reports, 2021,7(S7).
- [8] 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.
- [9] 宋智伟,黄新波,纪超,等.基于 Flexible YOLOv7 的输电线路绝缘子缺陷检测和故障预警方法[J/OL].高电压技术:1-16[2023-06-19].
- [10] 赵元龙,单玉刚,袁杰.改进 YOLOv7 与 DeepSORT 的佩戴口罩行人跟踪[J].计算机工程与应用,2023,59(6):221-230.
- [11] 连伯杨.小目标检测算法的研究及其在焊缝缺陷检测中的应用[D].天津:天津大学,2021.
- [12] 宋亮,谷玉海,石文天.基于改进 BiSeNet 的非结构化道路分割算法研究[J].应用光学,2023,44(3):556-564.
- [13] 朱豪,周顺勇,刘学,等.基于深度学习的单阶段目标检测算法综述[J].工业控制计算机,2023,36(4):101-103.
- [14] 杨翌晗.基于卷积神经网络的小目标检测算法研究[D].西安:西安电子科技大学,2022.
- [15] 杜文汉.复杂背景下的目标检测技术研究[D].淄博:山东理工大学,2022.
- [16] 张涛,谢探阳,李玉梅,等.基于改进 YOLOv4 算法的玻璃杯缺陷识别方法研究[J].电子测量技术,2023,46(2):46-51.

**作者简介**

**王伯涛**,硕士研究生,主要研究方向为机器视觉。

E-mail:614792931@qq.com

**周福强**(通信作者),博士,研究员,主要研究方向为机器视觉、智能轮胎研究等。

E-mail:fuqiangzhou@126.com