

基于改进ACR-YOLO的绝缘子缺陷检测研究

韩明^{1,2}, 张照坤¹, 于平平¹, 苏鹤³

(1. 河北科技大学信息科学与工程学院, 河北石家庄 050018; 2. 石家庄学院未来信息技术学院, 河北石家庄 050035;
3. 河北工业大学电气工程学院, 天津 300131)

摘要: 针对当前绝缘子缺陷检测领域中小目标物体缺陷检测精度与实时性无法兼顾、特征提取能力不足、上下文信息利用不充分等核心问题, 提出一种基于改进ACR-YOLO的目标缺陷检测算法。该算法在主干网络使用可变核卷积, 使卷积操作能够更精确地适应不同的数据集和目标位置, 增强特征提取能力; 在颈部网络增加P2小目标检测层, 以提高对细小缺陷的敏感性, 更全面地捕捉和分析输电线路中的潜在问题; 引入CARAFE算子, 从而有效提升在不同尺度下的目标信息捕获能力, 并充分利用上下文信息, 细致地恢复图像细节; 创新性地提出RTdecoder头部网络, 显著提升了模型推理速度。实验结果表明, 在绝缘子缺陷检测任务中, 改进后模型的平均精度均值为91.46%, 相比基线模型提升了4.37%, 同时检测速度相比基线模型提升了25.8%。

关键词: 小目标检测; 缺陷检测; 可变核卷积; CARAFE算子; RTdecoder头部网络

DOI: 10.11907/rjdk.241648

开放科学(资源服务)标识码(OSID):

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2025)009-0181-08



Research on Defect Detection of Insulators Based on Improved ACR-YOLO

HAN Ming^{1,2}, ZHANG Zhaokun¹, YU Pingping¹, SU He³

(1. School of Information Science and Engineering, Hebei University of Science and Technology, Shijiazhuang 050018, China;

2. College of Future Information Technology, Shijiazhuang University, Shijiazhuang 050035, China;

3. School of Electrical Engineering, Hebei University of Technology, Tianjin 300131, China)

Abstract: In the current field of insulator defect detection, the core problems such as the inability to balance the detection accuracy and real-time performance of small and medium-sized target objects, insufficient feature extraction ability, and insufficient utilization of context information are addressed. In this paper, a target defect detection algorithm based on improved ACR-YOLO is proposed. The algorithm uses variable kernel convolution in the backbone network, so that the convolution operation can adapt to different data sets and target locations more accurately, and enhance the feature extraction ability. A P2 small object detection layer was added to the neck network to improve the sensitivity to small defects and capture and analyze the potential problems in the transmission line more comprehensively. At the same time, the CARAFE operator is introduced to effectively improve the capture ability of target information at different scales, make full use of context information, and carefully restore the details of the image. And the RTdecoder head network is innovatively proposed, which significantly improves the inference speed of the model. Experimental results show that in the insulator defect detection task, the average precision of the improved model is 91.46%, which is 4.37% higher than that of the baseline model, and the detection speed is 25.8% higher than that of the baseline model.

Key Words: small object detection; defect detection; variable kernel convolution; CARAFE operator; RTdecoder head network

收稿日期: 2024-07-30

扫描二维码阅读全文:



基金项目: 中央引导地方科技发展资金项目(246Z0107G); 河北省教育厅青年基金项目(QN2023185); 石家庄市科技计划项目(221130321A)

作者简介: 韩明(1984-), 男, 博士后, CCF会员, 河北科技大学信息科学与工程学院教授、硕士生导师, 石家庄学院未来信息技术学院教授、研究方向为计算机视觉、图像处理等; 张照坤(1998-), 男, 河北科技大学信息科学与工程学院硕士研究生, 研究方向为图像处理; 于平平(1984-), 女, 博士, 河北科技大学信息科学与工程学院副教授、硕士生导师, 研究方向为计算机视觉、人工智能等; 苏鹤(1993-), 男, 河北工业大学电气工程学院博士研究生, 研究方向为电工装备可靠性理论及应用。本文通讯作者: 于平平。

0 引言

在输电线路系统中,绝缘子作为关键组件,承担着隔离导线与支撑结构的核心作用,以确保电力线路的正常运行,并有效预防漏电及短路事故。绝缘子的主要缺陷类型有掉串、机械损伤及闪络痕迹^[1-5]。这些缺陷会降低绝缘子支撑结构的稳定性和使用寿命。因此,对绝缘子缺陷的及时诊断与处理对于确保电力系统的高效、安全运行和降低维护成本具有重要的实际意义^[6-9]。

目前,绝缘子缺陷检测技术已从传统的直升机巡检、红外热像法和紫外光检测法逐步演进至更为先进的无人机巡检结合深度学习技术的应用^[10-12]。例如,赵振兵等^[13]提出融合结构推理的深度模型用于输电线路金具及其缺陷检测,通过引入结构推理机制,有效提升了输电线路金具及其缺陷的检测精度。然而,在处理复杂背景和多样性较高的缺陷特征时,模型的稳定性仍有提升空间。此外,其还提出了联合结构—语义关系图知识推理的输电线路螺栓缺陷识别方法^[14]。该方法利用语义关系图的知识推理能力,提升了对输电线路螺栓缺陷的识别效果,但在面对大规模数据集时,模型的计算复杂度有所增加。Liu等^[15]构建基于YOLOv3的密集网络,采用多尺度特征融合和多级特征映射模块以优化特征复用与传播,但该模型在处理极小或极大绝缘子时可能遭遇尺寸范围外的检测问题。Zhao等^[16]改进了Fast R-CNN模型,融合特征金字塔网络(FPNs)提升对绝缘子定位的准确性,但在复杂背景和光线条件变化的场景中仍存在检测误差。汝承印等^[17]设计了一种结合轻量级MobileNet-SSD目标检测网络和MobileNetV2-DeeplabV3+图像分割网络实现绝缘子高效分类、定位与分割的方法,尽管检测速度得到提升,但其网络结构增加了计算的复杂性。此外,郝帅等^[18]设计了PK-AMNet网络,通过YOLOv5数据扩充和特征迁移技术优化了复杂背景下的检测精度,但在复杂或噪声丰富的背景中仍会出现误报或误检情况。同时,翟永杰等^[19]在Faster R-CNN模型中引入FPN结构与SENet通道注意力机制,有效提高了对被遮挡小目标绝缘子检测的准确性,但也带来了更多的计算需求。

尽管目前各种先进的目标检测算法不断涌现,但有关无人机巡检绝缘子缺陷检测的文献中,检测精度与实时性之间的权衡仍然是一个较大的挑战。针对这一核心问题,本文深入探索并提出一种改进的ACR-YOLO(AKConv-CARAFE-RTdecoder-YOLO)绝缘子缺陷检测算法。该方法融合了先进的目标检测技术与实时优化策略,不仅提升了检测的精度和稳定性,而且显著提高了检测速度和实时性,适合部署于无人机上进行绝缘子缺陷巡检,实现“机器为主,人工为辅”的效果。

1 ACR-YOLO模型介绍

本章将深入探讨ACR-YOLO模型的结构及其特性。该模型基于YOLOv5s传统目标检测框架进行改进,致力于克服原始算法在绝缘子缺陷检测领域的局限性^[20-21]。优化后的网络架构如图1所示。在特征提取层面,ACR-YOLO突破了标准卷积采样形状固定的限制,将C3模块内的Conv卷积改进为AKConv,以改善卷积操作在多样数据集和复杂目标位置上的精确度与适应性,有效增强了特征提取能力。为加强对微小绝缘子缺陷的敏感性,在特征融合网络中引入P2小目标检测层,以精细化模型对微小缺陷的识别与定位,进一步提升模型在微小绝缘子缺陷上的检测性能。在图像细节保留方面,采用CARAFE轻量级上采样算子,这一前沿技术不仅相比传统上采样方法能更有效地融合上下文信息,而且能更为细腻地恢复图像细节,提升了模型的精细化视觉感知能力。最后,ACR-YOLO的头部网络创新性地将原有的head层替换为RTdecoder检测头,这一设计不仅有效改善了位置预测的准确性,而且显著减少了计算的冗余度。

1.1 主干网络结构改进

可变核卷积(AKConv)机制作为对普通Conv的改进,主要提供一种灵活的卷积机制,允许卷积核具有任意数量的参数和采样形状^[22-23]。该方法突破了传统卷积局限于固定局部窗口和固定采样形状的限制,使卷积操作能够更精准地适应不同数据集和不同位置的目标。

AKConv的流程如图2所示。输入图像的维度为(C, H, W),根据生成任意卷积核大小的初始采样坐标,获取不规则卷积核大小的初始采样形状;采用Conv2d从输入图像中提取关键特征;通过学习获得的偏移量,动态调整初始采样形状,使卷积核能够灵活地适应图像特征的变化;在调整后的采样形状中进行重采样,捕获与这些不规则采样形状相匹配的特征;最后对重采样后的特征图进行重塑、额外的卷积、标准化等操作,并通过激活函数SiLU进行处理,得到最终的输出结果。

AKConv通过不规则卷积完成特征提取过程,其可以根据偏移量灵活调整样本形状。在绝缘子缺陷检测任务中,不同缺陷类型对应不同的特征表示。AKConv为此提供了多样化的特征描述,有助于准确捕捉各种缺陷。

1.2 增加小目标检测层

本文引入P2小目标检测层,该层专门针对小尺度缺陷进行检测和定位,提高了模型对微小缺陷的识别准确度^[24]。原始YOLOv5模型在backbone部分经过5次下采样操作,每次下采样将特征图尺寸减半,最终形成了5层特征表达,分别标记为P1-P5。为更有效地应对绝缘子缺陷检测任务中普遍存在的中小尺度目标问题,本文首先对原模型的backbone部分进行一次额外的下采样操作,生成P2




Fig. 1 ACR-YOLO network architecture

图1 ACR-YOLO网络结构




Fig. 2 AKConv network structure

图2 AKConv网络结构

尺度的特征表达,以增强模型的感受野。P2特征层主要来自于主干网络的浅层特征。这些浅层特征只经过少量的卷积操作,保留了大量有助于定位的细粒度信息,如边缘、轮廓和纹理等。此外,浅层特征层中的小目标信息得以保留,从而提升了对小目标的检测性能。如图3所示,浅层特征能够捕捉目标的细粒度信息,深层特征则具有更大的感受野,能够捕捉更广泛的上下文信息。本文所使用的P2小目标检测层在浅层特征中的占比较小。




Fig. 3 Characteristic maps of different scales

图3 不同尺度的特征图

1.3 轻量级上采样算子

CARAFE作为一种轻量级的上采样算子,能够保留图像细节和特征信息,提高模型对小尺寸目标的感知能力^[25]。其可以有效利用全局上下文信息,从而提高目标检测效果。CARAFE作为一种重组操作符,其核心思想包括两个步骤:

(1)根据目标位置的内容预测一个重组核,以重新组合局部区域内的特征。在给定尺寸为 $C \times H \times W$ 的特征图 X 和上采样比例为 σ 的情况下,CARAFE将生成一个尺寸为 $C \times \sigma H \times \sigma W$ 的新特征图 X' 。对于输出 X' 的任意目标位置 $I' = (i', j')$,在输入特征图 X 中都存在相应的源位置 $I = (i, j)$ 。其中, $i = bi'/\sigma c, j = bj'/\sigma c$ 。CARAFE算子将 X_I 的 $k \times k$ 子区域定义为 X_I 的邻域。

(2)CARAFE算子利用预测的核对特征进行重新组合,如式(1)所示。

$$X'_{i',j'} = \sum_{l \in N(X_I, k)} \text{CARAFE}(X_l, W'_{l,l}) \quad (1)$$

其中, $N(X_I, k)$ 是 X_I 的邻域, $(W'_{l,l})$ 是从目标位置 L'

到源位置 L 预测的重组核。CARAFE操作符通过内容感知的方式,根据特征内容而不是位置距离重新组合局部区域内的特征。重组后的特征图能够更准确地反映图像中的细微变化。

预测核模块由3个子模块组成,即通道压缩器、内容编码器和内核归一化器,如图4所示。通道压缩器减少了输入特征图的通道,之后内容编码器将压缩的特征图作为输入,使用大小为 k_{encoder} 的卷积层根据输入特征的内容生

成重组核。编码器参数为 $k_{\text{encoder}} \times k_{\text{encoder}} \times C_m \times C_{up}$ 。增加 k_{encoder} 可以扩大编码器的感受野,并利用更大区域内的上下文信息,但是会增加计算复杂度。为了使性能与效率之间取得良好平衡,编码器核与重组核的关系需满足公式(2)。

$$k_{\text{encoder}} = k_{up}^2 \quad (2)$$

最后,内核归一化器对每个重组内核应用softmax函数进行归一化处理。




Fig. 4 Kernel prediction model

图4 核预测模型

1.4 头部网络改进

RT-DETR的解码器部分不需要YOLOv5算法中的NMS(Non-Maximum Suppression)算法,因此可以极大地改善NMS算法导致推理速度延迟的问题^[26-28]。RT-DETR中的decoder层用来处理YOLOv5颈部网络所产生的特征。其利用自注意力机制捕捉和理解图像中的复杂模式,从而实现更精准的目标定位和识别,同时保持较高的检测速度。其可以辅助预测头,负责生成包括对象类别、位置和大小在内的检测结果。

RTdecoder主要包括多尺度可变形注意力机制(Multi-ScaleDeformableAttention)、多头自注意力机制(Multi-Head Attention)和前馈神经网络(Feed-Forward Neural Network),如图5所示。

多尺度可变形注意力机制模块可以通过注意力机制聚合多尺度特征图,而无需借助特征金字塔网络。其利用多尺度可变形注意力模块处理特征映射,可以更好地捕捉图像中不同尺度的特征,从而增强了目标检测的适用性和鲁棒性。多头自注意力机制旨在协助模型捕获不同位置序列之间的依赖关系和相互作用。

该机制通过并行地计算多个注意力头,每个头可以关注输入序列的不同部分,从而捕获更丰富和复杂的信息。前馈神经网络(Feedforward Neural Network, FFN)是全连接的前馈网络,用于处理从多头自注意力机制得到的特征表示。每个注意力头得到的输出会被独立地送入前馈神经网络进行非线性变换和特征映射,因此能够捕获和处理更复杂的特征模式。




Fig. 5 RTdecoder network architecture

图5 RTdecoder网络结构

2 实验与分析

2.1 实验环境与数据集

本文实验软硬件平台的详细信息如表1所示,实验采

用实地采集的绝缘子图像作为实验数据。

本文数据集来源于Insulator Dataset、CPLID公开数据集以及部分自建数据集,其中包括2 256张图片,涵盖4个类别:绝缘子、掉串绝缘子、闪络绝缘子和破损绝缘子,部分图片如图6所示。为了确保训练和评估的准确性,将数

Table 1 Experimental environment	
表 1 实验环境	
环境	配置
GPU	NVIDIA GeForce RTX3080
CPU	Intel Core i5-11400H@2.7GHz
Operating system	Windows 10
Framework	PyTorch 1.9.0
CUDA	Cuda 11.3

数据集划分为训练集(train)、验证集(val)和测试集(detect),比例为7:2:1。实地采集的图像涵盖了不同环境条件下的绝缘子缺陷情况,以更好地模拟实际场景。




Fig. 6 Partial dataset images
图 6 部分数据集图片

2.2 实验设置与评价指标

检测网络性能的评估主要基于两个指标:检测速度和检测精度。检测速度通常用FPS(Frames Per Second)来测量,检测精度通常用平均精度均值(Mean Average Precision, mAP)来测量。在目标分类预测过程中,通常会出现 4 种可能的情况,分别是 TP(True Positive)、FP(False Positive)、FN(False Negative)和 TN(True Negative)。具体预测样本分类如表 2 所示。其中,TP 表示真正例,FP 表示假正例,FN 表示假负例,TN 表示真负例。

Table 2 Predictive sample classification		
表 2 预测样本分类		
真值	预测值	
	正类	负类
True	TP	FN
False	FP	TN

准确率表示所有预测为正例的结果中预测正确的比例,如式(3)所示。

$$P = \frac{TP}{TP + FP}$$
 (3)

召回率表示所有原始样本中正样本被预测正确的比例,如式(4)所示。

$$R = \frac{TP}{TP + FN}$$
 (4)

AP(Average Precision)表示单类目标在不同召回率条件下精确率的均值。然而,对于多分类问题,必须将平均值应用于 N 个类别的 AP,即 mAP。因此,本文采用 mAP 对

所有方法进行评价。mAP 计算公式如式(5)所示。

$$mAP = \frac{\sum AP_c}{N(classes)}$$
 (5)

FPS 是指每秒处理的图像数或处理每张图像所需的时间,使用 FPS 作为评价指标的前提是在同一硬件设备上进行比较。目前有许多应用场景需要实时预测结果,因此对检测速度有着极高的要求。

2.3 不同算法实验结果比较

为了全面比较改进后算法的性能,在配置环境等因素相同的条件下将本文的 ACR-YOLO 算法与 SSD、DSSD、Faster R-CNN、R²CNN、YOLOv5、YOLOX 和 YOLOv8s 7 种算法进行了全面比较。检测结果如表 3 所示。

Table 3 Experimental results comparison of different algorithms				
表 3 不同算法实验结果比较				
模型	主干网络	mAP@0.5/%	Modelsize/MB	FPS
SSD	VGG16	85.10	169.2	61
DSSD	ResNet101	86.57	221.6	53
FasterR-CNN	VGG16	87.04	214.3	21
R ² CNN	ResNet101	88.21	227.6	18
YOLOv5s	CSPDarknet-53	87.09	33.8	93
YOLOX	CSPDarknet-53	86.85	57.6	83
YOLOv8s	CSPNet	87.34	39.7	90
ACR-YOLO	Improved CSPDarknet-53	91.46	31.4	117

从表 3 观察得到,ACR-YOLO 的性能最优。其在检测精度上达到了 91.46%,能够有效减少漏检和误检的概率;模型大小为 31.4 MB,从而减少了模型的存储需求,缩短了模型加载时间,便于部署在无人机等硬件设备中;推理速度高达 117 FPS,保证了巡检的实时性和效率。相较于双阶段的 R²CNN,虽然 R²CNN 在精度和稳定性上表现优异,但由于其计算量较大,推理速度明显受限,只有 18 FPS。SSD 算法虽然推理速度较快(63 FPS),但在处理复杂纹理和小目标时性能受限,易受背景干扰。单阶段基线模型 YOLOv5 在精度上有所提升,但难以在保持高检测精度的同时实现较快的推理速度,可能会出现漏检或误检的情况。相比最新的 YOLOv8 算法,本文模型无论是在检测精度、模型大小还是检测速度上都有明显提升,特别是针对复杂场景和小目标,检测更为准确和高效。

2.4 消融实验

在测试环境等因素相同的条件下,通过消融实验可更加直观体现 AKconv、P2 层、CARAFE 算子以及 RTDecoder 头部网络对模型性能的影响。实验结果如表 4、表 5 所示。

通过表 4 可以看出,改进主干网络中的卷积模块后,平均精度均值提升了 2.42%,引入 CARAFE 算子后的平均精度均值提升了 1.48%。更改头部网路后,模型的检测速度得到大幅提升。由表 5 数据可知,改进后模型的平均精度均值达到 91.46%,相比原始网络提升了 4.37%,且检测速度达到了 117 FPS。综上所述,这一系列综合改进策略

Table 4 Results of ablation experiments

表 4 消融实验结果

基础模型	AKconv	P2	CARAFE	RTdecoder	mAP /%	FPS
√					87.09	93
√	√				89.51	85
√		√			87.90	89
√			√		88.57	97
√				√	88.14	124

Table 5 Performance comparison after adding each module

表 5 各模块添加后性能比较

模型	mAP /%	FPS
Yolov5	87.09	93
Yolov5+AKconv	89.51	85
Yolov5+AKconv+P2	89.79	83
Yolov5+AKconv+P2+CARAFE	90.14	92
Yolov5+AKconv+P2+CARAFE+RTdecoder	91.46	117

有效提升了绝缘子缺陷检测的准确性以及复杂环境下模型的整体性能。

AKconv 机制提供了多样化的特征描述,可准确捕捉各种缺陷。如表 6 所示,对 Conv、DWConv 和 Deformable Conv 模块进行比较。AKconv 可以根据偏移量灵活调整样本形状,为卷积采样形状带来更多选择,而且能在保持参数量和 FLOPs 基本不变的前提下有效增强模型的检测能力,特别是在复杂场景下的性能。

Table 6 Comparison of convolution modules

表 6 卷积模块比较

方法	mAP/0.5%	Params/ 10^6	FLOPs/ 10^9
YOLOv5s	87.09	7.02	15.8
+Deformable Conv	88.15	7.04	16.0
+DWConv	87.19	7.01	15.6
+AKconv	89.51	7.03	15.8

在 YOLOv5s 模型中采用不同上采样模块的特征可视化结果如图 7 所示。最近邻插值因其计算简单而被广泛使用,但在细节恢复上存在明显不足,导致特征图的边缘和细节模糊。而 CARAFE 上采样算子通过引入动态内核生成和内容感知重组机制,显著提升了上采样效果。该机制可有效保留复杂场景中的细微信息,克服了传统方法的局限性。

2.5 可视化分析


图 8 为 YOLOv5 基础模型与改进后 ACR-YOLO 模型的 mAP 对比。从图中可以看出,因为 ACR-YOLO 网络结构复杂,所以 ACR-YOLO 的收敛速度比 YOLOv5 慢。在 100 轮时 ACR-YOLO 的 mAP 开始高于 YOLOv5,并在 200 轮时趋于收敛,其最终的 mAP 提高了 4.37%。

为更加直观地查看 ACR-YOLO 模型与基线模型的检测效果,在 3 种复杂场景下进行了详细比较。如图 9(a) 所示,在复杂背景干扰的场景下,改进后模型的检测结果更为准确,显著提升了模型在复杂纹理和形状特征提取方面的能力,使模型在检测时对复杂背景的干扰程度明显降低。如图 9(b) 所示,在小目标场景中,改进后模型能够更




(a) Original drawing

(a) 原图



(b) The nearest interpolation

(b) 最近邻插值



(c) CARAFE

(c) CARAFE

Fig. 7 Comparison of feature maps of upsampled modules

图 7 上采样模块特征图对比




Fig. 8 mAP comparison of ACR-YOLO and YOLOv5

图 8 ACR-YOLO 与 YOLOv5 的 mAP 对比

细致地分析图像中的局部特征,并更敏锐地响应细微的缺陷变化。如图 9(c)所示,在多尺度场景中,ACR-YOLO 模型能够有效地扩展感受野,增强图像特征的代表能力,并能够在不同尺度下更准确地捕捉目标的详细信息。




Fig. 9 Visual comparison of test results
图 9 检测结果可视化比较

3 结语

本文提出一种基于改进 ACR-YOLO 绝缘子的缺陷检测算法,旨在解决绝缘子缺陷检测中检测精度与实时性无法平衡的问题。该算法利用 C3_AKConv 重构特征提取网络,提高了 ACR-YOLO 算法的特征提取能力。为了更充分地利用上下文信息进行特征融合,在颈部网络中采用 CARAFE 算子替换了原有的上采样算子,并且增加了 P2 小目标检测层,从而提高了算法对小缺陷目标的检测能力。头部网络创新性地使用了 RTdecoder 层,避免了 NMS 后处理对网络推理速度的延迟。实验结果表明,本文算法相较于基础 YOLOv5 算法的 mAP 提升了 4.37%,达到 91.46%,检测速度提高了 25.8%,在保证较高检测实时性的同时,检测精度也得到了大幅提升。

在未来的研究中,将进一步优化和完善当前的模型结构,特别是针对极端环境下缺陷的检测。计划引入更多数据增强技术和先进的特征提取方法,以提高检测精度并降

低误判率,同时简化网络结构,避免增加不必要的计算量。

参考文献:

[1] REN H Y. Research on application of UAV intelligent inspection of power transmission line[J]. Computer Fans, 2021(5): 224-225.
任红义. 输电线路无人机智能巡检应用研究[J]. 电脑爱好者, 2021(5): 224-225.

[2] LI K, YUAN Z, LI J D. Key technologies of UAV power line safety inspection [J]. China High and New Science and Technology, 2022(5): 48-49.
李科,袁智,李建东. 无人机电力线路安全巡检的关键技术[J]. 中国高科技, 2022(5): 48-49.

[3] ZUO D, HU H, QIAN R, et al. An insulator defect detection algorithm based on computer vision [C]//Proceedings of 2017 IEEE International Conference on Information and Automation, 2017: 361-365.

[4] ZHAO Z B, JIANG Z G, LI Y X, et al. Review on visual defect detection of transmission line components [J]. Journal of Image and Graphics, 2021, 26(11): 2545-2560.
赵振兵,蒋志钢,李延旭,等. 输电线路部件视觉缺陷检测综述[J]. 中国图象图形学报, 2021, 26(11): 2545-2560.

[5] CAO Y, XU H, SU C, et al. Accurate glass insulators defect detection in

- power transmission grids using aerial image augmentation[J]. IEEE Transactions on Power Delivery, 2023, 38(2):956-965.
- [6] LIU C Y, WU Y Q. Research progress of transmission line visual inspection method based on deep learning[J]. Proceedings of the CSEE, 2023, 43(19):7423-7446.
- 刘传洋, 吴一全. 基于深度学习的输电线路视觉检测方法研究进展[J]. 中国电机工程学报, 2023, 43(19):7423-7446.
- [7] MENÉNDEZ O, PÉREZ M, CHEEIN F A. Visual-based positioning of aerial maintenance platforms on overhead transmission lines[J]. Applied Sciences, 2019, 9(1):165.
- [8] ZHANG J R, WEI X, ZHANG L X, et al. Improving detection and positioning of insulators in YOLOv7[J]. Journal of Computer Engineering & Applications, 2024, 60(4):183-191.
- [9] ZHENG W C, LI X W, LIU H Z. Survey of object detection algorithms based on deep learning[C]//Suzhou: The 22nd Annual Conference on New Network Technologies and Applications of the Network Application Branch of the China Computer Users Association in 2018, 2018.
- 郑伟成, 李学伟, 刘宏哲. 基于深度学习的目标检测算法综述[C]//苏州: 中国计算机用户协会网络应用分会2018年第二十二届网络新技术与应用年会, 2018.
- [10] LI K C, WANG X Q, LIN H, et al. Review of one-stage small object detection methods in deep learning [J]. Computer Science and Exploration, 2022, 16(1):41-58.
- 李科岑, 王晓强, 林浩, 等. 深度学习中的单阶段小目标检测方法综述[J]. 计算机科学与探索, 2022, 16(1):41-58.
- [11] LIU J M, MENG W H. A survey of one-stage object detection algorithms based on deep learning [J]. Aero Weaponry, 2020, 27(3):44-53.
- 刘俊明, 孟卫华. 基于深度学习的单阶段目标检测算法研究综述[J]. 航空兵器, 2020, 27(3):44-53.
- [12] LI R N. A target detection method and system based on two-stage convolutional neural network[P]. China, CN202111226029. 8, 2022-01-21.
- 李若楠. 一种基于双阶段卷积神经网络的目标检测方法及其系统[P]. 中国, CN202111226029. 8, 2022-01-21.
- [13] ZHAO Z B, XIONG J, XU H D, et al. Transmission line hardware and defect detection with depth model based on fusion structure reasoning [J]. High Voltage Technology, 2023, 49(8):3346-3353.
- 赵振兵, 熊静, 徐厚东, 等. 融合结构推理的深度模型输电线路金具及其缺陷检测[J]. 高电压技术, 2023, 49(8):3346-3353.
- [14] ZHAO Z B, WANG R, WANG Y H, et al. Bolt defect identification method of transmission line based on joint structure-semantic graph knowledge inference [J/OL]. Journal of Intelligent Systems, 2024-08-18. <http://kns.cnki.net/kcms/detail/23.1538.tp.20240719.1123.002.html>.
- 赵振兵, 王睿, 王艺衡, 等. 联合结构-语义关系图知识推理的输电线路螺栓缺陷识别方法[J/OL]. 智能系统学报, 2024-08-18. <http://kns.cnki.net/kcms/detail/23.1538.tp.20240719.1123.002.html>.
- [15] LIU C, WU Y, LIU J, et al. Improved YOLOv3 network for insulator detection in aerial images with diverse background interference [J]. Electronics, 2021, 10(7):771.
- [16] 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.
- [17] RU C Y, ZHANG S H, ZHANG Z M, et al. Insulator fault identification method based on lightweight MobileNet-SSD and MobileNetV2-DeeplabV3+ [J]. High Voltage Technology, 2022, 48(9):3670-3679.
- 汝承印, 张仕海, 张子森, 等. 基于轻量级 MobileNet-SSD 和 MobileNetV2-DeeplabV3+ 的绝缘子故障识别方法[J]. 高电压技术, 2022, 48(9):3670-3679.
- [18] HAO S, ZHANG X, MA X, et al. Small target fault detection method of transmission line based on PKAMNet [J]. High Voltage Technology, 2023, 49(8):3385-3394.
- 郝帅, 张旭, 马旭, 等. 基于 PKAMNet 的输电线路小目标故障检测方法[J]. 高电压技术, 2023, 49(8):3385-3394.
- [19] ZHAI Y J, WANG L Y, GUO C B. Insulator target detection in complex background based on Faster R-CNN [J]. Electronic Measurement Technology, 2023, 46(16):187-194.
- 翟永杰, 王璐瑶, 郭聪彬. 基于 Faster R-CNN 的复杂背景下绝缘子目标检测[J]. 电子测量技术, 2023, 46(16):187-194.
- [20] SHI T, DING Y, ZHU W. YOLOv5s_2E: improved YOLOv5s for aerial small target detection[J]. IEEE Access, 2023, 11:80479-80490.
- [21] ZHANG H, ZHOU X, SHI Y, et al. Object detection algorithm of transmission lines based on improved YOLOv5 framework[J]. Journal of Sensors, 2024(1):5977332.
- [22] ZHANG X, SONG Y, SONG T, et al. AKConv: convolutional kernel with arbitrary sampled shapes and arbitrary number of parameters [DB/OL]. <https://arxiv.org/abs/2311.11587v1>.
- [23] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks [C]//Proceedings of 2017 IEEE International Conference on Computer Vision, 2017:764-773.
- [24] TANG J, LIU S, ZHAO D, et al. PCB-YOLO: an improved detection algorithm of PCB surface defects based on YOLOv5 [J]. Sustainability, 2023, 15(7):5963.
- [25] WANG J, CHEN K, XU R, et al. CARAFE: content-aware reassembly of features [C]//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision, 2019:3007-3016.
- [26] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]//Proceedings of European Conference on Computer Vision, 2020:213-229.
- [27] ZHAO Y, LV W, XU S, et al. DETRs beat YOLOs on real-time object detection [C]//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024:16965-16974.
- [28] ZHANG H, LI F, LIU S, et al. DINO: DETR with improved denoising anchor boxes for end-to-end object detection [DB/OL]. <https://arxiv.org/abs/2203.03605>.

(责任编辑:黄健)