

基于改进 CenterNet 的输电线路绝缘子缺陷检测方法

任欢¹, 苏涛², 李朋², 周凯³

(1. 国网河南省电力公司电力科学研究院, 郑州 450099; 2. 国网河南省电力公司商丘供电公司, 河南 商丘 476005;
3. 新能源电力系统国家重点实验室(华北电力大学), 北京 102206)

摘要: 缺陷绝缘子检测是智能电网运行维护中的关键任务之一。针对航拍绝缘子图像中存在的多目标、多尺度检测难题, 提出了一种基于改进 CenterNet 架构的缺陷绝缘子检测方法。该方法以无锚点检测器为基础框架, 创新性地集成了三项关键技术: 首先, 设计了扩展特征增强模块, 通过引入扩展卷积有效扩展特征感受野, 显著提升了模型对多尺度目标特征的捕捉能力; 其次, 在网络中嵌入卷积块注意力机制, 动态优化特征通道权重分布, 既提高了检测精度又优化了计算效率; 最后, 采用多尺度特征金字塔结构, 实现了多层次特征的融合与互补。实验验证显示, 该方法在复杂场景下的缺陷绝缘子检测中表现卓越, 平均精度达到 95.17%, 各项指标均显著优于现有主流算法, 充分证明了其在电力巡检实际应用中的优势。

关键词: 绝缘子; 缺陷检测; CenterNet; 特征金字塔; 扩展卷积; CBAM

Detection Method for Insulator Defects of Transmission Lines Based on Improved CenterNet

REN Huan¹, SU Tao², LI Peng², ZHOU Kai³

(1. Electric Power Science Research Institute of State Grid Henan Electric Power Company, Zhengzhou 450099, China;
2. Shangqiu Power Supply Company of State Grid Henan Electric Power Company, Shangqiu, Henan 476005, China; 3. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China)

Abstract: Defective insulator detection is one of the critical tasks in the operation and maintenance of smart grids. To address the challenges of multi-target and multi-scale detection in aerial insulator images, a defective insulator detection method is proposed based on an improved CenterNet architecture. The method adopts an anchor-free detector as the foundational framework and innovatively integrates three key technologies. Firstly, an expanded feature enhancement module is designed, which effectively enlarges the feature receptive field through dilated convolutions, significantly improving the model's ability to capture multi-scale target features. Secondly, a convolutional block attention mechanism is embedded into the network to dynamically optimize the weight distribution of feature channels, enhancing both detection accuracy and computational efficiency. Finally, a multi-scale feature pyramid structure is employed to achieve the fusion and complementarity of multi-level features. Experimental validation demonstrates that this method excels in defective insulator detection under complex scenarios, achieving an average precision of 95.17%, with all metrics significantly outperforming existing mainstream algorithms, fully proving its advantages in practical applications for power line inspection.

Key words: insulator; defect detection; CenterNet; feature pyramid; extended convolution; CBAM

0 引言

随着社会的持续发展与电力系统的不断完善,输电线路作为电力传输的关键通道,其安全稳定运行对社会经济发展至关重要。然而,受外界环境的复杂性及长期使用导致的劣化影响,输电线路绝缘子可能出现自爆、掉串、裂纹破损、闪络放电、异物附着等各类缺陷^[1-4]。这些缺陷不仅可能造成绝缘子失效,甚至引发安全事故,对电力系统的安全运行构成严重威胁。因此,对输电线路绝缘子进行及时且精准的缺陷检测,具有重要的理论意义与实际应用价值。

传统的绝缘子缺陷检测主要依赖人工识别,通常由工作人员沿输电线路通过人眼或望远镜观察,判断绝缘子是否存在故障或破损。这种方法要求工人长时间高强度作业,导致识别质量不稳定、检测效率低下。无人机技术的应用为线路巡检提供了新途径,与人工巡检相比,无人机巡检具有成本低、周期短、机动性强、安全性高等优势,近年来已逐渐开始替代人工巡检^[5]。尽管无人机航拍可传回大量输电线路绝缘子图像,但依靠人工判断图像中的缺陷显然不现实,因此迫切需要一套高效率、高性能、高智能的图像处理系统,对无人机传回的海量图像数据中的输电线路绝缘子缺陷进行检测。

近年来,计算机视觉方法已被广泛应用于输电线路绝缘子缺陷的自动检测。例如,文献[6]提出了一种专门用于绝缘子缺陷检测的局部强度周期估计算法。文献[7]提出了基于计算机视觉的绝缘子缺陷检测方法,通过特征提取与模型训练获得可识别并定位绝缘子的分类器,再通过一系列数字图像处理手段对绝缘子进行分割,最后分析分割后得到的绝缘子像素信息,判断其是否存在缺失。计算机视觉检测过程主要包含特征提取与分类两部分^[8],但特征提取环节过度依赖人工设计的算法,导致缺陷检测方法的鲁棒性与泛化能力较弱^[9]。

卷积神经网络(convolutional neural network, CNN)的出现解决了人工特征提取的难题^[10]。通过对大量图像样本的训练, CNN能够借助卷积层、池化层与全连接层,从输入的航拍图像中提取不同层级的特征,并通过信息分类与位置回归实现对绝缘体目标的精准检测。例如,文献[11]提出一种基于Faster R-CNN的深度卷积神经网络方法,用于定

位断裂的绝缘子与鸟巢;文献[12]则提出基于U-net与YOLOv4的绝缘子图像分割及缺陷检测方法。然而,这些检测器需设置大量锚点以预测目标边框,导致计算量庞大且运算速度缓慢。为解决这一问题,无锚点目标检测器(anchor-free object detector)^[13]应运而生,其原理是通过关键点确定目标位置,并在关键点上进行回归以完成目标检测。不过,无锚点目标检测器仍存在一定局限性:首先,基于锚点的检测器通常可在多尺度特征上检测缺陷,而无锚点检测器仅能在单一特征上预测缺陷,这导致其在检测不同尺度缺陷时存在局限;其次,仅以关键点作为正样本可能造成正负样本失衡。此外,实例分割方法也可应用于表面缺陷检测^[14],该方法在像素级执行检测过程,能更精准地分割目标,但实例分割方法仍存在明显不足,如分割结果不够精确、计算过程复杂等,这会导致检测速度较慢,且分割的标记成本高于缺陷检测方法。

为解决上述问题,本文提出一种基于改进CenterNet的输电线路绝缘子缺陷检测方法。该方法以无锚点目标检测器CenterNet模型为基础,通过基于扩展卷积的扩展特征增强模型扩大多尺度缺陷的感受野,实现对缺陷绝缘子的准确、快速识别;同时在不同通道引入卷积块注意力机制模块,进一步提升模型检测精度。此外,结合特征金字塔方法处理不同尺度与复杂度的绝缘子特征。通过上述改进,CenterNet网络能够更精准地检测复杂绝缘子图像中多尺度、多目标的缺陷绝缘子。

1 材料与方法

1.1 数据集获取

本文研究所用的输电线路绝缘子缺陷数据集包含两部分:第一部分基于文献[15]提供的CPLID数据集,共848张图像;第二部分为自建数据集,涵盖10 152张无人机巡查图像,以及通过数据增强方式获取的435张绝缘子缺陷图像。绝缘子缺陷数据集中的部分图像如图1所示,包含多目标、多尺度的绝缘子图像——多目标指待检测图像中存在多个绝缘子目标,多尺度则指待检测图像中绝缘子目标的尺度差异较大。此外,从图1中可见,输电线路及绝缘子的背景信息复杂,涉及多种不同场景。

该数据集包含11 435张图像,其中绝缘子缺陷类型涵盖自爆缺陷、伞裙缺失缺陷等,在训练及测




图1 输电线路绝缘子缺陷数据集示例

Fig. 1 Examples of insulator defect dataset for transmission lines

试过程中统一标注为“缺陷绝缘子”。所有图像均通过LabelImg图像标注工具完成正常绝缘子目标与缺陷绝缘子目标的标记。在后续研究中,为降低数据集来源对研究结果的影响,将上述数据集进行混合并随机打乱顺序,再按照70%:15%:15%的比例划分为训练集、测试集和验证集。

1.2 改进的CenterNet网络模型

CenterNet是基于CornerNet算法^[16]改进的单级目标检测模型,通过预测目标中心点位置及对应目标的长、宽实现目标检测。该网络无需预先设置锚点,大幅减少了网络参数与计算量。CenterNet通常以ResNet-50^[17]作为主干网络提取特征,将特征图传递至检测模块后,通过3个卷积块分别完成目标相关预测:包括中心点与类别的预测、目标宽高的预测,以及中心点偏移的预测。

CenterNet模型主要由两部分构成:一是从边界框到点的预测模块,二是从点到边界框的预测模块。在边界框到点的预测模块中,主干网络通过卷积操作完成待检测目标的中心点预测与尺寸预测。具体而言,所采用的ResNet-50是经典的深度残差网络结构,拥有50层深度与残差连接,能有效解决深度神经网络训练中的梯度消失和梯度爆炸问题,具备较强的特征提取与表示能力。在输电线路绝缘子缺陷检测任务中,ResNet-50作为CenterNet

的主干网络,可有效识别复杂的绝缘子缺陷,提升检测精度,且在处理大规模数据集时具有较快的处理速度。

从点到边界框的预测模块则根据中心点位置与预测尺寸,进一步预测目标的边界框,包含边界框位置回归和置信度预测两个子模块。边界框位置回归是在确定中心点与尺寸的基础上,通过回归方式预测目标边界框的位置(通常为相对于中心点的偏移量);边界框置信度预测则针对每个预测的边界框,判断其是否包含目标并给出置信度得分,该得分可用于衡量边界框是否为有效的目标检测结果。

与传统目标检测方法相比,CenterNet作为单阶段检测器,将检测任务简化为目标中心定位与目标属性预测,通过“中心-宽度-高度”的表示形式直接从图像中预测目标的位置与尺寸信息。凭借轻量级的网络结构与高效的损失函数设计,CenterNet在保持高检测精度的同时具备较快的推理速度,且在密集目标检测与小目标检测等场景中表现出色。

传统的CenterNet网络仅能对单一特征的缺陷进行预测,在检测不同尺度的缺陷或多特征缺陷时,准确度会显著下降;同时,仅以关键点作为正样本可能导致正负样本失衡,进而引发错检或漏检^[18]。为解决上述问题,本文对传统CenterNet网络结构进行了改进,改进后的网络结构如图2所

示。具体而言,首先结合扩展卷积提出扩展特征增强模块,以扩大感受野并强化特征表达;其次,将卷积块注意力模块(convolutional block attention module, CBAM)嵌入网络,通过为特征图的不同通道分配差异化权重,提升检测准确度与计算效率;最后,在主干网络中融入特征金字塔方法,实现对不同尺度特征的提取与融合。

1.3 扩展特征增强模块

在 CenterNet 的主干网络中,图像下采样过程会伴随语义信息的增加,但分辨率会随之降低。基于这一特性,高级特征图虽包含丰富的语义信息,却因分辨率较低只能覆盖有限的尺度范围,而待检测的绝缘子缺陷可能具有较大的像素跨度。当主干网络完成对输入图像的特征提取与上采样后,网络输出的单尺度特征图,其感受野仅能匹配部分缺陷,这将导致缺陷检测性能欠佳。为扩大感受野并增强特征表达,本文将结合扩展卷积对 CenterNet 网络模型进行改进。如图 3 所示的扩展卷积^[19]能够在不增加额外计算成本的前提下有效扩大特征的感受野。

例如,当卷积核大小设为 3×3 、步长为 1 时,其工作原理与感受野为 3 的常规卷积一致;而若将步长调整为 3,卷积核大小会扩展为经零填充的 7×7 ,因此 3×3 扩展卷积的感受野可扩大至 7×7 。基于这一原理,扩展卷积能显著提升感受野范围。

由于主干网络生成的最后一个特征图已包含足够丰富的语义信息以支持缺陷检测,无需与其他层的特征进行集成;但这种方式可能引发信息冗余。基于上述分析,本文提出一种嵌入扩展卷积的扩展

特征增强模块,以有效扩大特征的感受野。该模块的结构原理如图 4 所示,由多个扩展卷积块构成。首先,通过 1×1 卷积与 3×3 卷积对特征图中的语义信息进行细化;其次,为在避免冗余消耗的前提下获取包含不同感受野的特征,采用单次聚合结构堆叠扩展卷积块^[20],并确保每个输出层均与扩展卷积块相连。扩展卷积块的结构扩展后,特征的通道数量增加,每个通道都包含具有不同感受野的多尺度信息。随后,利用 1×1 卷积层减少特征图的通道数量,并通过包含全局平均池化层与全连接层的通道注意力模块,增强不同通道间的语义信息关联。最后,通过残差连接将扩展卷积块的输入特征与输出特征相加,确保扩展特征增强模块能够输出覆盖缺陷全尺度的特征。

扩展卷积模块包含 3 个部分:首先是 1×1 卷积层,将通道数量压缩至输入通道数的四分之一;接着是扩展率为 3 的 3×3 扩展卷积,用于扩大感受野;最后再次通过 1×1 卷积层调整通道数量,使输入与输出的通道数保持一致。

1.4 卷积块注意力模块

卷积块注意力模块^[21]作为一种轻量级通用模块,能够在不显著增加网络参数的前提下有效提升网络的表征能力。其核心功能是自动学习不同通道与空间维度上的注意力分布,从而优化特征图的质量并突出关键信息的重要性。CBAM 主要由通道注意力(channel attention)和空间注意力(spatial attention)两部分组成,具体结构如图 5 所示。其中,通道注意力的目标是为每个通道分配权重,常用的实现方法包括全局平均池




图2 CenterNet 网络结构图

Fig. 2 CenterNet network architecture




图 3 扩展卷积示意图

Fig. 3 Schematic diagram of extended convolution

化(global average pooling, GAP)和全局最大池化(global maximum pooling, GMP)。

对于输入特征图 F 的大小为 $H \times W \times C$ (其中 H 和 W 分别为高和宽, C 为通道数量)。

$$F_{\text{GAP}}(c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F(i, j, c) \quad (1)$$

$$F_{\text{GMP}}(c) = \max_{i,j} F(i, j, c) \quad (2)$$

式中: $F_{\text{GAP}}(c)$ 为全局平均池化得到的特征图; $F_{\text{GMP}}(c)$ 为全局最大池化得到的特征图; $F(i, j, c)$ 为输入特征图在第 c 个通道、第 i 行第 j 列位置处的特征响应值。

随后通过一个或两个全连接层来学习通道之间的关系, 从而得到相应的权重。而空间注意力的目标则在于为特征图的每个位置分配一个权重, 通常通过使用小型卷积核(例如 1×1 卷积)来实现。

$$M = \sigma(W_k * (F_{\text{GAP}} + F_{\text{GMP}})) \quad (3)$$

式中: M 为空间主力图; $*$ 为卷积操作; W_k 为卷积核; σ 为 sigmoid 激活函数。

最后使用这些权重来更新原始特征图, 对于空




图 4 扩展特征增强模块示意图

Fig. 4 Schematic diagram of expanding feature enhancement model




图 5 卷积块注意力模块结构图

Fig. 5 Convolutional block attention module structure

间注意力,有:

$$F' = F \times M \quad (4)$$

式中 F' 和 F 分别为经过空间注意力加权后的特征图和输入特征图。

对于通道注意力, C_k 为学习到的通道权重,有:

$$F'' = F \times C_k \quad (5)$$

式中 F'' 为经过通道注意力加权后的特征图。

在输电线路绝缘子缺陷检测过程中, CBAM 模块被嵌入 CenterNet 的主干网络, 通过学习为特征图的不同通道分配差异化权重, 以突出对绝缘子缺陷检测更为关键的特征。CBAM 不仅能通过增强目标特征通道提升特征图质量, 还可减少特征图中的冗余信息, 使网络更聚焦于核心特征, 这有助于提高计算效率, 降低不必要的计算开销。

1.5 特征金字塔

为确保网络模型在不同尺度下均具备出色的检测性能, 本文采用特征金字塔方法——这是一种经典且有效的多尺度信息处理技术^[22]。在实际应用中, 待检测图像中的绝缘子目标可能呈现多种尺度与大小: 对于尺寸较小或结构简单的目标, 浅层特征图已能捕捉足够信息以实现有效检测; 但当目标更为复杂或尺寸较大时, 即便已通过相关方法去除背景噪声, 仍需从深层特征图中获取更精细、更丰富的特征来保障预测准确性, 这正是采用特征金字塔方法的必要性所在。该方法能够在不同尺度下提取并融合特征, 从而更精准地检测各类尺度的绝缘子目标。




图6 特征金字塔结构

Fig. 6 Feature pyramid structure

特征金字塔的结构如图6所示, 其原理基于一个核心思想: 从深层特征出发, 逐步进行上采样, 并与浅层特征相融合。具体而言, 特征金字塔网络可分为两个主要部分: 前半部分依托主干网络的卷积层开展前向传播计算, 主要作用是通过整合不同尺度的特征图, 生成一张包含更丰富特征的特征图。

特征金字塔的主要目的就是从中层到浅层形成一系列融合的特征图 P_i 。

$$P_i = U_{d-i} + F_{s-i} \quad (6)$$

式中: U_{d-i} 为深层特征图; F_{s-i} 为浅层特征图; d 和 s 分别为深层特征和浅层特征的层级编号; i 为当前融合阶段的层级索引编号。

本文以 CenterNet 为基础, 构建了基于特征金字塔的网络模型, 以更好地实现绝缘子缺陷检测。具体而言, 特征金字塔网络主要分为两部分。第一部分是基于主干网络的卷积层进行前向传播运算, 将不同尺度的特征图组合为新的特征图。第二部分则是基于卷积网络产生的原始特征图, 从深层到浅层进行上采样, 并建立新的特征图序列, 使得具有深层特征信息的特征图获得更高的分辨率, 进一步增强了图像特征。

1.6 损失函数

改进 CenterNet 模型的损失函数由关键点损失函数、宽度高度预测损失函数以及中心点偏移预测损失函数组成^[23]。其中关键点损失函数 L_k 定义如下。

$$L_k = -\frac{1}{N} \sum_{x=1}^X \sum_{y=1}^Y \sum_{z=1}^Z \begin{cases} (1 - \bar{Y}_{xyz})^\alpha \log(\bar{Y}_{xyz}), & \text{如果 } Y_{xyz} = 1 \\ (1 - Y_{xyz})^\beta (\bar{Y}_{xyz})^\alpha \log(1 - \bar{Y}_{xyz}), & \text{其他} \end{cases} \quad (7)$$

$$Y_{xyz} = \exp\left(-2 \frac{(x - \bar{p}_x)^2 + (y - \bar{p}_y)^2}{\sigma^2}\right), Y_{xyz} \in [0, 1] \quad (8)$$

式中: (x, y) 为关键点位置; z 为目标类型, 即正常绝缘子和缺陷绝缘子; $\bar{Y}_{xyz}$ 为预测的关键点热图(heatmap); Y_{xyz} 为对应标签的地面真值的热图; N 为关键点的数量; α 、 β 为超参数, 分别被设置为 2 和 4; $(\bar{p}_x, \bar{p}_y)$ 为热图预测的绝缘子关键点的坐标; σ 为标准差。

中心点偏移预测损失函数 L_{off} 定义如下。

$$L_{\text{off}} = \frac{1}{N} \sum_p |\bar{O}_p - (p - \bar{p})| \quad (9)$$

式中: p 为待检测图像中目标中心点的坐标; $\bar{O}_p$ 为预测位置偏移; $\bar{p}$ 为地面真值图像中心点的坐标; N 为目标中心点的数量。

宽度(或高度)预测损失函数 L_{size} 定义如下。

$$L_{\text{size}} = \frac{1}{N} \sum_k |\bar{S}_{p_k} - S_k| \quad (10)$$

式中: p_k 为预测框的中心点; $\bar{S}_{p_k}$ 为目标 k 的中心点

相对应的预测框的宽度(或高度); S_k 为与对象 k 的中心点相对应的标签框的宽度(或高度)。

因此,最终的损失函数 L_{oss} 为:

$$L_{\text{oss}} = L_k + \lambda L_{\text{off}} + \eta L_{\text{size}} \quad (11)$$

式中: λ 为 L_{off} 的权重; η 为 L_{size} 的权重; λ 和 η 分别设置为 0.1 和 1。

2 结果与分析

2.1 实验环境

实验在一台搭载了 Windows 10 的笔记本电脑上完成,深度学习框架为 pytorch,运行环境为 CUDA 11.3 和 CuDNN 7.6.3,电脑的硬件环境为 NVIDIA GeForce RTX 3070 显卡及 Intel 酷睿 i7 11 800 H。编译环境和语言分别为 Pycharm 和 python 3.7。

2.2 模型训练

图7给出了随着训练过程的损失下降曲线图。




图7 Epoch-Loss 曲线图

Fig. 7 Epoch Loss curve

在模型训练过程中使用了 8 004 张包含了不同缺陷的绝缘子图像作为训练集,以及 1 715 张图像作为验证集。训练参数方面, batch size 设置为 16,初始学习率设置为 0.02,在训练过程中学习率会逐渐降低以获得更精细的检测结果。如图7所示,在 60 个 epoch 以后损失下降趋于平缓,在 120 个 epoch 以后模型趋于收敛。

2.3 评价指标

为了对模型的性能进行定量评估,本文采用平均准确率(average precision, AP)、准确率和召回率(precision recall, PR)曲线作为评价指标。首先,需要对交并比(intersection over union, IoU)进行介绍,它表示模型所预测的检测框与真实(ground truth)的检测框的交集与并集之间的比例。通常情

况下, IoU 的结果是两个检测框交集像素数与它们的并集像素数之比。当 IoU 大于一个通常设定的阈值(一般为 0.7)时,通常认为检测结果是正确的,否则被视为错误的检测。

对于检测问题,预测结果通常被分为 4 个类别:真正例(true positive, TP)、真反例(true negative, TN)、假正例(false positive, FP)、假反例(false negative, FN)。本文中以 T_p 表示模型正确预测为目标的样本数量,以 F_p 表示模型错误地将非目标样本预测为目标的样本数量,以 T_n 表示模型正确预测为非目标的样本数量,以 F_n 表示模型错误地将目标样本预测为非目标的样本数量。基于这 4 个类别的关系,可以定义两个关键指标:准确率(precision)和召回率(recall),其中准确率表示了模型正确预测为目标的样本与模型总共检测出的目标样本之间的比值,而召回率表示了模型正确预测为目标的样本与总共应该检测出的目标样本之间的比值^[24],这两个指标可以帮助量化评估模型的性能。

准确率和召回率的定义分别如下。

$$P = \frac{T_p}{T_p + F_p} \quad (12)$$

$$R = \frac{T_p}{T_p + F_n} \quad (13)$$

式中: P 为准确率; R 为召回率。

召回率和准确率通常呈相互对立的关系,提高准确率往往会降低召回率,反之亦然。在目标检测任务中, P - R 曲线被用来反映模型在所有样本上的准确率和召回率之间的权衡关系。 P - R 曲线通常以准确率为纵轴、召回率为横轴,通过绘制多组不同召回率和准确率值的坐标,展示了模型在不同工作点下的性能表现。然而, P - R 曲线并不能提供目标检测模型的准确度的具体数值。为了定量衡量算法的性能,通常使用 AP 作为指标。AP 是召回率从 0 到 1 的范围内对精确度的积分,即 P - R 曲线下的面积,记作 A_p 。 A_p 越靠近 1,表明模型的检测精度越高,性能越好。而平均准确率(mAP)则是在所有类别上平均 AP 值,用于评估在多类别目标检测中的整体性能,记作 R_{mAP} 。

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

$$R_{\text{mAP}} = \frac{\sum_{i=1}^N A_{p_i}}{N} \quad (15)$$

式中： $P(R)$ 为当召回率为 R 时对应的精确率； A_{p_i} 为第 i 个类别对应的平均精确率； N 为参与评价的目标类别数量。

2.4 消融实验

本文提出了一种改进 CenterNet 的输电线路绝缘子缺陷检测模型，为了验证其可以更有效、更准确地对缺陷绝缘子目标进行检测，分别对加入扩展特征增强模型，加入卷积块注意力模块以及加入特征金字塔进行 3 组消融实验验证。实验结果如表 1 所示。

表 1 消融实验及结果

Tab. 1 Ablation experiment and results

模型	扩展特征增强模型	卷积块注意力模块	特征金字塔	$P/\%$	$R/\%$	$R_{\text{mAP}}/\%$
				88.43	89.17	89.29
	√			93.24	93.45	93.59
CenterNet		√		92.91	93.82	93.27
			√	90.77	91.74	91.05
	√	√	√	95.35	95.12	95.17

经过训练使得模型收敛后，用未参与训练过程的测试集对模型的性能进行验证，结果表明，提出的改进 CenterNet 模型对于输电线路绝缘子目标及缺陷检测的准确率分别达到 99.33 %、92.48 %，平均准确率为 95.17 %。根据表 1 的结果，当仅添加扩展特征增强模型时，准确率从 89.29 % 提高到了 93.59 %，提升了 4.30 %，这表明扩展特征增加感受野并提高多尺度特征的理解能力对提高模型的性能具有较强的积极影响。而单独加入 CBAM 后，准确率提高到 93.27 %，提升了 3.98 %，这表明多尺度的注意力机制对于改进模型性能非常有效。而当单独结合特征金字塔后，mAP 值达到了 91.05 %，也进一步提高了模型的性能，这表明多尺度的特征提取有助于提高缺陷检测的准确率。当将这 3 个改进模块都结合应用到模型中后，相较于传统的 CenterNet，改进模型的准确率提高了 6.92 %，召回率提高了 5.95 %，模型的平均准确率达到 95.17 %，提升了 5.88 %。这进一步证明了通过增加感受野及多尺度特征提取、融合的组合对于模型性能的提升至关重要。

2.5 对比实验

为了全面评估本文提出的改进 CenterNet 的输电线路绝缘子缺陷检测模型的性能，在相同的数据集和相同的硬件环境下，与多种主流的基于深度学习的目标检测模型进行了对比实验。对比的模型包括 YOLOv5^[25]、Faster R-CNN^[26]、SSD^[27]、RetinaNet^[28]、CornerNet^[16]等模型。实验结果如表 2 所示。

表 2 对比实验及结果

Tab. 2 Comparative experiments and results

模型	$P/\%$	$R/\%$	$R_{\text{mAP}}/\%$
本文提出的方法	95.35	95.12	95.17
YOLOv5	91.82	91.08	91.37
Faster R-CNN	91.07	92.18	91.79
SSD	92.24	92.43	92.33
RetinaNet	92.97	91.84	92.61
CorNerNet	91.49	91.80	91.75

实验结果表明，本文提出的改进 CenterNet 网络结构对输电线路绝缘子缺陷检测效果具有显著提升。具体而言，改进后的 CenterNet 模型在 mAP 指标上达到 95.17 %，相较于 YOLOv5(91.37 %)、Faster-RCNN(91.79 %)、SSD(92.33 %)、Retina-Net(92.61 %)及 CorNerNet(91.75%)模型，分别提升了 3.8 %、3.38 %、2.84 %、2.56 %和 3.35 %，充分证实了改进 CenterNet 模型的优越性。除 mAP 指标表现突出外，改进后的 CenterNet 模型在准确率和召回率上也取得最优检测性能，分别为 95.35 %和 95.12 %，较其他方法分别提升 2.38 %~4.28 %和 2.69 %~4.04 %。这一显著性能提升得益于本研究引入的扩展特征增强模块、特征金字塔方法与卷积块注意力模块——这些创新性设计不仅增强了模型对多尺度多目标绝缘子特征的检测能力，也为复杂背景下的检测提供了更高鲁棒性。综上所述，本文提出的方法在各项指标上明显优于 YOLOv5、SSD 等一系列常用于目标检测任务的传统模型，尤其在处理复杂背景、不同尺度或多目标的绝缘子特征时展现出极高检测准确度，实验结果充分证明了该方法在绝缘子缺陷检测场景中的有效性与优越性。

2.6 可视化实验结果

对于输电线路绝缘子目标及缺陷检测的部分可视化结果如图 8 所示，其中 insulator 代表正常绝缘子，defect 代表缺陷绝缘子，数字为置信度得分。




图8 输电线路绝缘子缺陷检测的可视化结果

Fig. 8 Visualization results of insulator defect detection in transmission lines

从图 8 可以看到, 对比组图 8(b) 中传统的 CenterNet 未检测出绝缘子缺陷, 而改进的 CenterNet 完成了缺陷绝缘子的检测。另外, 在对比组图 8(c) 和对比组图 8(d) 中传统的 CenterNet 在面对多尺度多目标的时候有时会出现漏检的现象, 而本文提出的改进方法可以较好的应对这种挑战, 更准确地检测多尺度多目标绝缘子图像中的绝缘子目标及缺陷。综上所述, 提出的方法相较于传统的 CenterNet 网络对于多尺度多目标图像中的缺陷绝缘子检测更为准确, 漏检或错检更少。

3 结论

为实现输电线路绝缘子缺陷的精准高效检测, 特别是针对多尺度多目标图像的任务需求, 本文成功构建了一种基于改进 CenterNet 网络的先进检测方法。该方法以无锚点目标探测器为基础, 结合嵌入扩展卷积的扩展特征增强模型, 可有效扩大特征感受野, 提升模型对多尺度多目标对象的检测能力。同时, 将卷积块注意力模块嵌入网络, 通过为特征图不同通道分配差异化权重, 进一步提高检测精度与计算效率。此外, 在 CenterNet 主干网络中融入特征金字塔方法, 实现对不同尺度特征的提取与融合。

实验结果显示, 相较于传统 CenterNet 模型, 改进模型的平均精度均值(mAP)提升了 5.88%, 准确率和召回率分别提升了 6.92% 和 5.95%; 与其他主流检测模型相比, 也展现出显著的性能优势。

综合而言, 本文提出的改进 CenterNet 模型具备出色的特征提取能力与缺陷检测性能, 尤其在处理多尺度多目标图像时, 检测精度表现突出, 十分适用于实际场景中的输电线路绝缘子缺陷检测。该方法不仅推动了绝缘子缺陷检测技术的进一步发展, 也为电气行业相关领域的检测任务提供了有价值的参考。

参考文献

- [1] 刘悦, 黄新波, 刘天娇. 基于深度学习的架空输电线路绝缘子缺陷检测方法研究综述[J]. 电力电容器与无功补偿, 2024, 45(3): 167 – 177.
LIU Yue, HUANG Xinbo, LIU Tianjiao. Research review of insulator defect detection methods for overhead transmission lines based on deep learning[J]. Power Capacitors and Reactive
- [2] 李新海, 曾令诚, 卢泳茵, 等. 一种小样本条件下的绝缘子外套裂纹缺陷图像识别方法[J]. 南方电网技术, 2021, 15(12): 86 – 94.
LI Xinhai, ZENG Lingcheng, LU Yongyin, et al. An image recognition method for insulator jacket crack defects under small sample conditions[J]. Southern Power System Technology, 2021, 15(12): 86 – 94.
- [3] 伍箴燎, 吴正平, 孙水发. 基于改进 YOLOv5 算法的绝缘子多缺陷检测[J]. 高压电器, 2024, 60(12): 95 – 102.
WU Zhenliao, WU Zhengping, SUN Shuifa. Multiple defect detection of insulators based on improved YOLOv5 algorithm[J]. High Voltage Apparatus, 2024, 60(12): 95 – 102.
- [4] 尹向雷, 解永芳, 屈少鹏, 等. 基于动态蛇形卷积和非跨步卷积的绝缘子缺陷检测[J]. 电力系统保护与控制, 2024, 52(20): 177 – 187.
YIN Xianglei, XIE Yongfang, QU Shaopeng, et al. Insulator defect detection based on dynamic snake convolution and space-to-depth convolution[J]. Power System Protection and Control, 2024, 52(20): 177 – 187.
- [5] 王超, 魏良才, 张振. 无人机输电线路自主摄像技术研究[J]. 江西电力, 2024, 48(2): 24 – 30.
WANG Chao, WEI Liangcai, ZHANG Zhen. Research on autonomous camera technology for drone transmission lines[J]. Jiangxi Electric Power, 2024, 48(2): 24 – 30.
- [6] HAN Y, LIU Z, LEE D, et al. Computer vision-based automatic rod-insulator defect detection in high-speed railway catenary system[J]. International Journal of Advanced Robotic Systems, 2018, 15(3): 1 – 15.
- [7] ZUO D, HU H, QIAN R, et al. An insulator defect detection algorithm based on computer vision [C]//2017 IEEE International Conference on Information and Automation (ICIA), July 18 – 20, 2017, Macao, China. New York: IEEE, 2017: 361 – 365.
- [8] 谢新文. 基于计算机视觉的电气化铁路绝缘子识别技术的研究[D]. 成都: 西南交通大学, 2016.
- [9] 熊杰. 航拍图像的绝缘子自爆特征识别研究[D]. 成都: 电子科技大学, 2016.
- [10] WEI Y, XIA W, HUANG J, et al. CNN: Single-label to Multi-label [DB/OL]. (2014 – 06 – 22) [2014 – 07 – 09]. <https://arxiv.org/abs/1406.5726>.
- [11] LEI Xusheng, SUI Zhehao. Intelligent fault detection of high voltage line based on the Faster R-CNN [J]. Measurement, 2019, 138: 379 – 385.
- [12] 唐小煜, 黄进波, 冯洁文, 等. 基于 U-net 和 YOLOv4 的绝缘子图像分割与缺陷检测[J]. 华南师范大学学报(自然科学版), 2020, 52(6): 15 – 21.
TANG Xiaoyu, HUANG Jinbo, FENG Jiewen, et al. Insulator image segmentation and defect detection based on U-net and YOLOv4 [J]. Journal of South China Normal University (Natural Science Edition), 2020, 52(6): 15 – 21.
- [13] LI Y, YU W, GUAN X. Current-aided multiple-AUV cooperative localization and target tracking in anchor-free environments [J]. IEEE/CAA Journal of Automatica Sinica, 2023, 10(3): 792 – 806.
- [14] 高熠, 田联房, 杜启亮. 基于 Mask R-CNN 的复合绝缘子过热缺陷检测[J]. 中国电力, 2021, 54(1): 135 – 141.
GAO Yi, TIAN Lianfang, DU Qiliang. Detection of overheating defects in composite insulators based on Mask R-CNN[J].

- Electric Power, 2021, 54(1): 135 – 141.
- [15] 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, 2020, 50 (4): 1486 – 1498.
- [16] LAW H, DENG J. CornerNet: detecting objects as paired keypoints [J]. International Journal of Computer Vision, 2020, 128(3): 642 – 656.
- [17] AKIBA T, SUZUKI S, FUKUDA K. Extremely large minibatch SGD: training ResNet-50 on ImageNet in 15 Minutes [DB/OL]. (2017 – 11 – 12). <https://arxiv.org/abs/1711.04325>.
- [18] SHI X, SU Y, TI Y, et al. A_centernet: object as a point by attention [J]. International journal of pattern recognition and artificial intelligence, 2022, 36(7): 1 – 17.
- [19] 徐姗姗. 卷积神经网络的研究与应用[D]. 南京: 南京林业大学, 2013.
- [20] 萧嘉乐, 梁东宝, 陈弟虎, 等. 基于FPGA的高效可伸缩的MobileNet加速器实现[J]. 计算机工程与科学, 2021, 43(4): 628 – 633.
- XIAO Jiale, LIANG Dongbao, CHEN Dihui, et al. Implementation of an efficient and scalable MobileNet accelerator based on FPGA [J]. Computer Engineering and Science, 2021, 43(4): 628 – 633.
- [21] 陈森楸, 刘文波, 张弓. 嵌入双尺度分离式卷积块注意力模块的口罩人脸姿态分类[J]. 中国图象图形学报, 2022, 27(4): 1125 – 1136.
- CHEN Senli, LIU Wenbo, ZHANG Gong. Facial pose classification for masks with embedded dual scale separated convolutional block attention modules [J]. Chinese Journal of Image and Graphics, 2022, 27(4): 1125 – 1136.
- [22] 曹晓明. 基于多图像特征金字塔的车辆检测[D]. 北京: 北京交通大学, 2016.
- [23] KIM C Y, LEE D H, KIM H J, et al. Designing of loss function for 3D pedestrian detection using CenterNet [C]//AICCC 2020: 2020 3rd Artificial Intelligence and Cloud Computing Conference, December 18, 2020, Kyoto, Japan. New York: ACK, 2020: 110 – 123.
- [24] 曹玉娟, 牛振东, 赵堃, 等. 基于概念和语义网络的近似网页检测算法[J]. 软件学报, 2011, 22(8): 1816 – 1826.
- CAO Yujuan, NIU Zhendong, ZHAO Kun, et al. An approximate webpage detection algorithm based on concept and semantic networks [J]. Journal of Software Science, 2011, 22(8): 1816 – 1826.
- [25] 何锦强, 李锐海, 李昊, 等. 基于Yolov5与Grabcut的架空线路绝缘子可见光图像自动识别与分割方法[J]. 南方电网技术, 2023, 17(6): 128 – 135.
- HE Jinqiang, LI Ruihai, LI Hao, et al. Visible light image automatic recognition and segmentation method for overhead power line insulators based on Yolov5 and Grabcut [J]. Southern Power System Technology, 2023, 17(6): 128 – 135.
- [26] GIRSHICK R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision, December 7 – 13, 2015, Santiago, Chile. New York: IEEE, 2015: 1440 – 1448.
- [27] 阎光伟, 王婷. 基于平衡特征融合SSD的绝缘子检测方法[J]. 中国科技信息, 2021(10): 99 – 100.
- YAN Guangwei, WANG Ting. Insulator detection method based on balanced feature fusion SSD [J]. China Science and Technology Information, 2021(10): 99 – 100.
- [28] WANG Y, WANG C, ZHANG H, et al. Automatic ship detection based on RetinaNet using multi-resolution Gaofen-3 imagery [J]. Remote Sensing, 2019, 11(5): 531 – 540.

收稿日期: 2024-04-13; 网络首发日期: 2024-11-12

作者简介:

任欢(1983), 女, 通信作者, 高级工程师, 硕士, 研究方向为高电压与绝缘技术、变压器故障诊断分析, AONYAYBM233@163.com;

苏涛(1970), 男, 高级工程师(教授级), 学士, 研究方向为变压器管理及故障诊断分析;

李朋(1982), 男, 高级工程师, 学士, 研究方向为电气试验及绝缘油诊断分析。