

基于多尺度特征融合的输电线路故障检测算法

尤敏¹, 徐祥海¹, 田易之², 商佳宜¹, 赵天煜¹

(1. 国网浙江省电力有限公司杭州供电公司, 杭州 310016; 2. 新疆大学电气工程学院, 乌鲁木齐 830000)

摘要: 针对输电线路故障检测中存在的小目标、漏检和图像分辨率低等问题, 提出了一种基于多尺度特征融合的输电线路故障检测算法。为了获得不同尺度的输入特征, 首先将图像输入给预先训练的共享残差网络。然后, 利用特征融合注意力机制来学习不同尺度下的显著特征, 整合大尺度特征图上的详细信息和小尺度特征图上的场景信息。此外, 受语义分割中密集空间金字塔池的启发, 构建多尺度特征融合密集金字塔, 进一步提高特征提取的能力。最后, 利用尺度不变误差损失来预测对数空间中的深度映射。在输电线路故障检测数据集上的实验数据表明, 所提方法具有较高的检测准确度, 平均精度均值(mean average precision, mAP)评分达到 97.50%, 检测速度可达 56 帧/s, 具有较高的鲁棒性和准确性, 为输电线路故障的智能监测提供有效的解决方案。

关键词: 输电线路; 深度学习; 小目标故障检测; 多尺度; 注意力机制

Transmission Line Fault Detection Algorithm Based on Multi-Scale Feature Fusion

YOU Min¹, XU Xianghai¹, TIAN Yizhi², SHANG Jiayi¹, ZHAO Tianyu¹

(1. State Grid Zhejiang Electric Power Co., Ltd. Hangzhou Power Supply Company, Hangzhou 310016, China; 2. School of Electrical Engineering, Xinjiang University, Urumqi 830000, China)

Abstract: To address the challenges of small targets, missed detections, and low image resolution in transmission line fault detection, a multi-scale feature fusion-based algorithm for transmission line fault detection is proposed. To obtain input features at different scales, images are first fed into a pre-trained shared residual network. Then, a feature fusion attention mechanism is used to learn salient features at different scales, integrating detailed information from large-scale feature maps and contextual information from small-scale feature maps. Additionally, inspired by dense spatial pyramid pooling in semantic segmentation, a multi-scale feature fusion dense pyramid is constructed to further enhance feature extraction capabilities. Finally, a scale-invariant error loss is utilized to predict depth mapping in logarithmic space. Experimental results on a transmission line fault detection dataset demonstrate that the proposed method achieves the highest detection accuracy, with a mean average precision (mAP) score of 97.50% and a detection speed of up to 56 frames per second. It exhibits high robustness and accuracy, providing an effective solution for intelligent monitoring of transmission line faults.

Key words: transmission line; deep learning; small target fault detection; multi-scale; attention mechanism

0 引言

绝缘子和螺栓扣是输电线路的重要元件, 其作用是保证输电线路的可靠运行, 对整个电力系统的安全稳定至关重要^[1-2]。我国电网具有规模大、输

电线路覆盖面广、自然条件复杂等特点。由于输电线路全年接触阳光和降雨, 一些关键部分容易存在安全隐患, 导致输电线路出现故障, 对人们的生活和社会的稳定造成危害。因此, 有必要对输电线路进行准确、及时、有效的检查。

输电线路的最早检查方法是人工检查^[3-4], 但是这种方法工作强度高、效率低, 特别是对于崎岖山区、大河跨越地区或在地震、滑坡、洪水和冰灾期间的输电线路检查工作。在这种不利条件下, 线

基金项目: 新疆维吾尔自治区自然科学基金资助项目(2022D01C364)。

Foundation item: Supported by the Natural Science Foundation of Xinjiang Uygur Autonomous Region (2022D01C364).

路检查人员不得不使用地面车辆或步行,在检查电力线路时使用普通仪器或肉眼处理设备缺陷,这需要很长时间并且劳动成本高。

与手工线路检查相比,直升机或无人机线路巡检有效提高效率^[5-6],但线路检查人员仍然需要承担大量的人力工作。在直升机线路检查中,线路检查人员需要乘坐直升机并在直升机上完成传输线路的图像采集。在无人机检查中,飞行员远程控制无人机并使用无人机上的设备进行图像采集。然而,对采集到的图片中缺陷的识别仍需要由检查人员完成。这种方式下,缺乏智能的缺陷识别,人员的工作效率较低。

随着深度学习和人工智能的发展,输电线路智能检测受到广泛关注^[7-8]。在电力智能检测方法中,首先将无人机投入到传输线路的检查中,收集大量的视觉图像数据。将图像数据传输到服务器后,通过基于卷积神经网络(convolutional neural network, CNN)的目标检测技术进行自动处理和智能检测,极大地节省人力成本并提高工作效率。Zhai 等人^[9]提出一种基于混合知识区域的 CNN 方法,用于检测传输线路航空图像中的多个配件。Zhao 等人^[10]提出一种基于改进的快速区域卷积神经网络(faster region convolutional neural network, Faster R-CNN)^[11]的绝缘子识别和故障检测模型,以提高准确性。然而,他们的方法的检测速度需要改进。许多研究采用轻量级网络来提高检测速度。Zhen 等人^[12]将 MobileNetv2 和 CSP 结合到一个轻量级的 CSPMobileNet-v2 中,并将其引入到 YOLOv4 中^[13],实现了对传输线路关键部件的实时检测。Ma 等人^[14]采用 MobileNetv3 和单阶段多盒检测器(single shot multibox detector, SSD)^[15]进行传输线路的结冰监测。然而,轻量级网络往往以低准确性为代价实现高检测速度。

上述方法从不同角度对输电线路故障检测算法进行探索优化,但是这些方法更关注大尺度图像的细节,并倾向于观察小尺度图像的全局信息。鉴于上述背景,本文提出了一种基于多尺度信息融合策略的输电线路故障检测方法。首先,使用具有共享权重的 ResNeXt 网络构建一个多尺度网络,可以获得更多的全局特征信息。然后,基于注意力机制融合不同尺度的特征图,使得网络有效提取不同尺度的特征信息。此外,构建一种新的网络架构,其中

包含多尺度特征融合密集金字塔,用于端到端的输电线路故障检测。该模块可以自适应地融合不同尺度的特征,同时只增加少量的学习参数。所提出的方法不仅可以从大尺度特征图中获取全局和整体信息,还可以从小尺度特征图中提取局部和详细信息。最后,在输电线路故障检测数据集上进行实验评估,以验证本文所提方法的性能。

1 数据集

1.1 InsPLAD 数据集

InsPLAD 是第一个用于输电线路检测的大型真实数据集和基准,包含 10 607 张高分辨率无人机彩色图像,涵盖了 17 种独特的电力线路资产类别,累计 28 933 个资产实例^[16]。对其中 5 类资产标注了故障问题,包括绝缘子缺失盖帽、避雷针腐蚀、绝缘子腐蚀、可调夹具腐蚀、架式悬挂腐蚀和鸟巢,部分故障实例如图 1 所示。



图 1 InsPLAD 数据集示例

Fig. 1 Examples of InsPLAD dataset

1.2 自制输电线路故障检测数据集

InsPLAD 中故障类别多为组件腐蚀问题,而实际输电线路的组件中还会存在绝缘子自爆、异常、螺栓缺失等问题,鉴于此,本文自主采集更多类别的故障图像,其中包括国网浙江电力公司提供的 2 972 张输电线路图片,这些图片为无人机在不同角度、不同照明条件、不同功率检查场景下拍摄。训练数据、测试数据和验证数据的比例设置为 8 : 1 : 1。使用 LabelImg 标记绝缘子自爆、绝缘子异常、

螺栓扣、异物。同时,应用随机翻转、平移、随机高斯模糊等策略扩展数据,数据集示例如图 2 所示。



图 2 输电线路故障检测数据集示例

Fig. 2 Examples of transmission line fault detection dataset

2 多尺度特征融合检测方法

本文所提算法的总体框架如图 3 所示。该架构主要包括特征提取器、多尺度特征融合密集金字塔和深度上采样等几部分。其中一些流行的卷积架构,如 ResNet、ResNeXt 和 DenseNet 等都可用作特征提取器,本文以 ResNeXt 为例,深度上采样模块使用多个上采样和卷积运算符来逐步恢复原始分辨率,并采用跳过连接方式来保留更多的原始特征信息。所提算法的主要设计思路是利用注意力机制和

金字塔结构来自适应地融合不同尺度输入图像中的全局信息和局部信息。

2.1 特征注意力融合

特征注意力融合策略在输电线路故障检测任务中可以有效增强对关键特征的注意和重视,相较于传统注意力机制,特征注意力融合策略可以对不同的特征图进行自适应的加权融合,并且在多个层次上进行特征融合,从低层到高层逐渐提取更加抽象和语义丰富的特征,从而提高检测的准确性和鲁棒性。鉴于此,本文基于扩张卷积提出一种特征注意力融合策略嵌入到网络中,以增强模型的整体特征提取能力。设 l 是一个具有扩张系数 l 的卷积操作符, X 是一个特征图。则扩张卷积 D_{*l} 可以定义为:

$$D_{*l}(X) = f_a(W_l X) \quad (1)$$

式中: W_l 为具有 l 个膨胀因子的卷积核; $f_a(\cdot)$ 为激活函数,通常为 ReLU、Sigmoid 和 ELU。

基于共享权重网络,假设输入图像被调整为两个尺度 $s \in \{1, 2\}$, 其中每个尺度通过主干网络(如 ResNet 或 ResNeXt)传递,并预测尺度 s 的特征图 F^s 。通过最近邻插值,将每个特征图 F^s 调整为相同的大小。用 G 表示所有尺度的特征图的加权和,即:

$$G = \sum_{s=1}^S \alpha^s D_{*l}(F^s) \quad (2)$$

式中: 权重 $\alpha^s = \exp(H^s) / \sum_{s=1}^S \exp(H^s)$ 为通过 SoftMax 函数计算; H^s 为通过 S 个滤波器对 F^s 进行 1×1 卷积获得的特征图。

然而,这个权重只使用大尺度的特征图,缺少不同尺度之间的关联。因此,本文提出一种新颖的




图 3 所提方法整体框架

Fig. 3 Overall framework of the proposed method

特征注意力融合方法以改进不同尺度特征之间的交互作用, 如图 4 所示。所提出方法的权重 α^s 可以表示为:

$$\begin{cases} \alpha^1 = f_{\text{sig}} \left(f^{7 \times 7} \left(\text{Avgpool} \left(D_{*1}(F^1) \right) \Lambda \text{Maxpool} \left(D_{*1}(F^1) \right) \right) \right. \\ \left. \Lambda \text{Avgpool} \left(D_{*1}(F^2) \right) \Lambda \text{Maxpool} \left(D_{*1}(F^2) \right) \right) \\ \alpha^2 = 1 - \alpha^1 \end{cases} \quad (3)$$

式中: $f^{7 \times 7}(\cdot)$ 为卷积层, 其卷积核大小为 7×7 ; $f_{\text{sig}}(x) = 1/(1 + \exp(-x))$ 为 Sigmoid 激活函数; $\text{AvgPool}(\cdot)$ 和 $\text{MaxPool}(\cdot)$ 分别为沿通道维度的平均池化和最大池化; Λ 为拼接操作符。




图 4 特征注意力融合模块

Fig. 4 Feature attention fusion module

通过特征注意力机制, 可以选择性地增强对具有重要信息的特征的关注度, 如线路断裂、绝缘子破损等故障相关的特征。特征注意力融合策略还可

以使模型在不同层次的特征之间进行自适应加权融合, 从而更好地利用各层次的信息, 提升特征的表征能力。引入特征注意力融合策略可以使模型有选择性地关注不同层次的特征, 通过学习的注意力权重来控制信息传递的强度和方向, 从而改善信息传递的效率, 使模型更加灵活地利用不同层次的特征。

2.2 多尺度特征融合密集金字塔

通常情况下, 随着扩张率的增加, 扩张卷积的建模能力会逐渐降低。为了提高特征的感受野并避免核降解问题, 本文采用一种多尺度特征融合密集金字塔方法将具有不同扩张率的卷积特征密集连接起来, 采用扩张卷积构建的密集金字塔可以在金字塔的每个层级上进行特征提取和融合, 从而实现密集的特征融合。这种密集的特征融合可以更好地利用不同层次特征的信息, 提升特征的多样性和表达能力。提出的方法的连接原则示意图如图 5 所示。

首先使用扩张率为 $l=3$ 的扩张卷积计算两个尺度的特征图, 然后将特征图通过一个注意力融合模块。接下来, 通过类似的操作实现 3 个具有不同扩张率 ($l=6$ 、 12 、 18) 的模块。最后, 使用 1×1 卷积来减少特征的通道维度。所提方法连接一组密集的卷积层, 而不显著增加模型的大小, 从而生成具有更大尺度范围的多尺度特征。

多尺度特征融合密集金字塔在输电线路故障检测中可以提供更准确和全面的深度信息, 从而帮助检测和定位故障。该方法通过利用不同尺度的特征




图 5 多尺度特征融合密集金字塔结构

Fig. 5 Multi-scale feature fusion dense pyramid structure

图获取全局和局部特征信息。全局特征信息可以揭示线路的整体结构和形状,而局部特征信息有助于检测细微的故障和异常。通过多尺度特征融合可以提高深度估计的准确性,减少深度估计误差,并更好地还原场景的三维结构。此外,多尺度特征融合密集金字塔可以在保持高检测速度的同时,减少学习参数,降低模型复杂度。搭配特征注意力融合方法,模型可以自适应地融合不同尺度输入图像中的全局信息和局部信息。

2.3 损失函数

在输电线路故障检测中,深度值通常表示目标物体或故障距离相机的远近,而深度值的绝对数值并不是最重要的,重要的是深度值之间的相对关系。在先前的工作中,一些训练损失被用来预测更准确的深度图,例如尺度不变误差损失^[16]、berHu损失^[17]和序数损失^[18]。本文使用尺度不变误差损失来计算预测深度图 $F_{d'}$ 和真实深度图 F_d 在对数空间中的差异,其中 d 表示真实深度(depth), d' 表示预测深度。尺度不变误差损失函数可以有效地消除预测深度值的尺度差异,它基于相对比例误差,而不是绝对差异,将预测值和真实值之间的误差标准化,即使整个深度图的数值被缩放或偏移,模型仍然可以学习到正确的深度顺序和关系。所提出方法的训练损失构建如下。

$$\begin{cases} S(g) = \frac{1}{T} \sum_i g_i^2 - \left(\frac{1}{T} \sum_i g_i \right)^2 + (1 - \lambda) \left(\frac{1}{T} \sum_i g_i \right)^2 \\ \Gamma = \beta \sqrt{S(g)} \end{cases} \quad (4)$$

式中: λ 为超参数,设定为0.85; g 为 $F_{d'}$ 和 F_d 的对数空间差异, $g_i = \log F_{d'} - \log F_d$, i 为第 i 个像素点; T 为具有有效真实值的像素数量; β 为超参数,设定为10; $S(\cdot)$ 为尺度不变误差; Γ 为最终训练损失。

采用尺度不变误差损失函数还能提高模型的鲁棒性。由于输电线路故障检测中存在不同距离的目标物体或故障,这些目标物体的深度范围可能相差较大。尺度不变误差损失函数可以使模型对不同尺度范围内的深度值都敏感,从而提高模型在不同距离下的检测能力。因此,采用尺度不变误差损失函数可以使模型在输电线路故障检测中具有尺度不变性,更好地学习深度值之间的相对关系,并提高模型的鲁棒性。

3 实验与分析

3.1 实验配置

实验所用深度学习算法运行的环境是Ubuntu 18.04操作系统,CPU英特尔酷睿i9-9920X,两个GPU NVIDIA RTX 2080Ti, CUDA 10.1, Cudnn 7.6.0, Pytorch 1.6.0和Python 3.7。输入图像分辨率被归一化为512×512,批量大小被设置为4,使用Adam优化器优化模型,将初始学习率设置为0.000 01,并采用余弦退火的方法来调整学习速率。在输电线路故障检测数据集上,权重衰减被设置为0.000 1。

3.2 评估指标

实验采用多个性能指标来评估算法的性能,包括平均精度均值(mean average precision, mAP)、参数量(params)、浮点操作次数(floating point operations per second, FLOPS)和每秒帧数(frames per second, FPS)。精度(precision, 其值用 P 表示)为所有阳性样本结果中正确预测的百分比,如式(5)所示;查全率(recall, 其值用 R 表示)为所有正样本中正确预测的百分比,如式(6)所示;平均精度(average precision, AP)为以 R 为横轴, P 为纵轴的曲线下面积,如式(7)所示;mAP为数据集中所有类别的平均精度的均值,如式(8)所示。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (5)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (6)$$

$$N_{AP} = \sum_{i=1}^{n-1} (R_{i+1} - R_i) P(R_{i+1}) \quad (7)$$

$$N_{mAP} = \frac{\sum_{j=1}^M N_{AP_j}}{M} \quad (8)$$

式中: N_{TP} 为正确分配的阳性样本; N_{FP} 为错误分配的阳性样本; N_{FN} 为不正确分配的阴性样本; M 为类别数量。

3.3 结果分析

3.3.1 特征注意力融合性能验证

实验首先验证所提特征注意力融合策略的有效性,将4种主流注意力机制(挤压与激励网络(squeeze and excitation network, SENet)^[20]、坐标注意力(coordinate attention, CA)^[21]、卷积块注意力模块(convolutional block attention module,

CBAM)^[22]、高效通道注意力(efficient channel attention, ECA)^[23]嵌入到金字塔模块中进行对比,在自制故障检测数据集上进行训练和验证,结果如表 1 所示。

表 1 特征注意力融合策略性能验证

Tab. 1 Performance verification of feature attention fusion strategy

方法	mAP 值/%	FPS 值/ (帧·s ⁻¹)	Params 值/M	FLOPS 值/G
SENet	85.65	51	15.35	32.57
CA	87.02	58	16.43	35.69
CBAM	87.79	67	17.53	38.08
ECA	89.33	65	11.74	28.65
特征注意力融合	97.50	56	13.42	33.21

注: M 为 10⁶ 个, G 为 10⁹ 次, 下同。

从表 1 的数据可以看出, 采用特征注意力融合方法的模型 mAP 达到了 97.50%, 高于其他注意力方法。这是由于本文模型采用了多尺度特征融合的基本原理构建, 特征注意力融合策略可以搭配所提模型对检测目标的多个不同层级的尺度进行提取和融合, 从低层到高层逐渐提取更加抽象和语义丰富的特征。而传统的注意力方法更倾向于增强模型对特定位置的关注程度, 可能会导致模型的忽略重要的上下文信息、缺乏全局一致性。

在模型复杂度和计算量方面, 采用特征注意力融合方法构建的模型参数量为 13.42 M、计算量为 33.21 G, 仅比 ECA 高 1.68 M、4.56 G, 但仍远低于其他 3 类方法。这是因为特征注意力融合策略可以通过一些轻量级的操作来实现特征的加权融合, 从而在保持较高性能的同时减少计算开销。传统的注意力方法通常需要计算权重分布, 特别是在大规模的目标检测任务中, 需要处理大量的特征图, 影响模型的实时性和效率。

3.3.2 特征融合性能测试

本文所提出的多尺度特征融合方法通过结合不同尺度的特征信息来加强模型的特征提取能力, 以增强输电线路故障检测精度, 其主要核心为多尺度特征融合密集金字塔。为了验证本文所提的多尺度特征融合密集金字塔在多尺度特征融合方面的有效性, 分别将所提出的方法与其他先进的特征融合方法进行实验对比。为了保证实验的严谨性, 骨干网络均使用 ResNeXt, 将特征融合网络分别用特征金字塔网络(feature pyramid network, FPN)、双向特征金字塔网络(bi-directional feature pyramid network, BiFPN)、路径聚合网络(path aggregation network, PANet)替换^[24-26], 其余部分均基于本文模型架构, 在输电线路异物检测数据集上进行测试, 结果如表 2 所示。

由表 2 数据可知, 针对多种不同的故障类型, 所提方法的 AP 评分优于其他特征融合方法。其中所提方法在绝缘子自爆、绝缘子异常、螺栓扣和异物上的 AP 值分别高于比较模型中评分最高的 PANet 方法 2.19%、5.52%、3.91% 和 6.08%; 与 FPN 相比分别高出 6.79%、11.89%、4.26% 和 9.98%; 与 BiFPN 相比分别高出 4.15%、7.19%、5.47% 和 8.19%。这是由于本文采用的多尺度特征融合密集金字塔方法采用更密集的连接方式, 将具有不同扩张率的卷积连接起来, 进而增强对较小故障目标的检测准度, 整体提高检测精度。同时嵌入特征注意力模块, 进一步加强模型的特征提取, 得以学习到特征更多的信息。加之, 所提方法的 mAP 评分达到 97.50%, 高于所有对比方法。此外, 所提方法的 FPS 为 56, 这意味着该方法可以每秒检测到 56 帧图像, 满足实时性的需求。但是密集的连接方式导致更复杂的特征融合过程, 其中 BiFPN 是基于 PANet 精简得到, 所以 FPS 相较于 FPN、BiFPN 分别降低 3、10, 高于 PANet。综上

表 2 特征融合能力验证结果

Tab. 2 Feature fusion ability verification results

模型	AP 值/%				mAP 值/%	FPS 值/ (帧·s ⁻¹)	Params 值/M	FLOPS 值/G
	绝缘子自爆	绝缘子异常	螺栓扣	异物				
ResNeXt-FPN	90.56	85.12	94.68	86.45	89.20	66	9.63	25.45
ResNeXt-BiFPN	93.20	89.82	93.47	88.24	91.18	59	12.44	30.78
ResNeXt-PANet	95.16	91.49	95.03	90.35	93.00	53	15.87	40.12
所提模型	97.35	97.01	98.94	96.43	97.50	56	13.42	33.21

所述,所提方法在检测精度方面取得显著的提升,并且拥有实时性能。

所提模型的参数量达到 13.42 M,相较于 FPN 和 BiFPN 结构的模型分别提高 3.79 M、0.98 M,比 PANet 减少 2.45 M。计算量达到 33.21 G,相较于 FPN 和 BiFPN 结构的模型分别提高 7.76 G 和 2.43 G,比 PANet 减少 6.91 G。整体而言,所提模型的复杂度和计算量只有略微的增加,但仍然具有一定的优势,且检测精度得到了显著的提升,整体上表现出了优越的检测性能。

3.3.3 与先进算法对比测试

为了验证所提方法在输电线路故障检测任务上的有效性,采用多种目标检测模型在输电线路故障检测数据集上进行对比测试,结果如表 3 所示。

表 3 数据表明所提方法在 mAP 指标上达到 97.50%,高于其他主流检测模型。鉴于 mAP 值可以反映模型在检测所有目标类别上的平均准确度,这说明所提方法在故障检测任务上的整体检测精度最高。具体地,绝缘子自爆的检测任务中,Faster RCNN 的 AP 评分达到 97.44%,优于其他模型,与所提方法相比高 0.09%。但是其检测速度 FPS 只有 15,远低于其他模型,这是因为 Faster RCNN 是一个两阶段算法,其繁琐的先验框预设过程在有效提升精度的同时会大幅降低检测效率。此外,所提方法的 F1 分数在不同故障类型上分别为 0.94、0.93、0.92 和 0.91,相较于 SSD 分别提高 0.05、0.04、0.02 和 0.02;相较于 CenterNet 分别提高 0.12、0.09、0.08、0.10;相较于 YOLOv5 分别提高 0.04、0.04、0.01、0.04;相较于 YOLOv7 分别提高 0.06、0.02、0.02、0.01;相较于 YOLOv8 分别

提高 0.03、0.03、0.00、0.03。除了绝缘子自爆中比 Faster RCNN 略低于 0.01 外,整体评分高于其他对比算法。这表明所提方法识别假阳性样本和假阴性样本问题的能力得到显著提升,进一步证明其有效性和鲁棒性。

在模型复杂度方面,所提模型的参数量仅有 13.42 M,远低于 Faster RCNN、SSD、CenterNet 以及 YOLOv7,较低的参数量意味着模型更适合于边缘计算或移动式设备的部署。此外,所提模型只需要 33.21 G 次 FLOPS 即可完成高精度输电线路故障检测,这一优势在需要实时检测的电力巡检任务中尤为重要。

FPS 可以反映模型的检测效率,在输电线路故障检测任务中对模型的实时性能要求较高,所以较大的 FPS 是模型开发的优先挑战。由表 3 可知,CenterNet 模型得益于其简洁、无锚框的网络架构,检测效率远超其他对比模型,达到 67。本文所提模型的 FPS 达到 56,分别比 Faster RCNN 和 SSD 高 51、35,比 CenterNet、YOLO 系列分别低 11、5、3、1。这主要由于模型融入多尺度特征融合密集金字塔,其结构大幅增加模型的计算量 and 处理过程,导致效率降低。但是,这个结构可以提升检测的准确性并减少漏检,尤其是输电线路故障检测任务中,其目标大多具有较小尺寸,传统的检测模型对其关注较少,容易造成漏检和错检。而所提方法关注目标多个尺度的特征,有效提升模型的检测性能。总体而言,所提方法在检测准确性和效率之间达到最佳平衡。

为了直观地展示所提方法的优势,选取经典输电线路故障图像进行验证,结果如图 6 所示。

表 3 与先进算法对比结果

Tab. 3 Comparison results with advanced algorithms

方法	AP 值/%				mAP 值 /%	F1 值				FPS 值/ (帧·s ⁻¹)	Params 值 /M	FLOPS 值 /G
	绝缘子 自爆	绝缘子 异常	螺栓扣	异物		绝缘子 自爆	绝缘子 异常	螺栓扣	异物			
Faster RCNN	97.44	96.62	93.84	93.62	95.38	0.95	0.92	0.89	0.86	15	145.53	155.43
SSD	92.87	93.89	96.17	92.85	93.94	0.89	0.89	0.90	0.89	31	40.34	83.61
CenterNet	88.09	91.28	93.18	83.69	89.06	0.82	0.84	0.84	0.81	67	21.35	46.35
YOLOv5	94.40	95.82	94.54	89.86	93.65	0.90	0.89	0.91	0.87	61	7.23	16.51
YOLOv7	95.43	94.79	97.84	93.65	95.42	0.88	0.91	0.90	0.90	45	36.9	104.78
YOLOv8	96.22	95.51	97.35	95.33	96.10	0.91	0.90	0.92	0.88	57	11.18	28.54
所提模型	97.35	97.01	98.94	96.43	97.50	0.94	0.93	0.92	0.91	56	13.42	33.21




图6 可视化结果对比

Fig. 6 Comparison of visualization results

从图6可以看出, 所提方法在复杂背景、小目标和遮挡的情况下, 可以有效检测出故障目标, 而其他算法如 SSD、CenterNet 和 YOLOv8 等均存在漏检现象, 无法准确地识别目标故障, 并且检测置信度低于本文方法。这是由于本文的方法嵌入特征注意力融合模块, 使得模型更关注有效信息并抑制无效信息, 加强模型的特征提取能力, 从背景复杂的场景中识别并定位目标。此外, 多尺度特征融合密集金字塔架构显著提升模型的特征融合能力, 深度处理不同尺度的信息, 在小目标检测挑战中具有明显优势。这一实验结果充分证明所提方法的优越性和鲁棒性。

3.3.4 消融实验

本节进行消融实验来分析模型的单个部分对整体性能的贡献以及所提方法的有效性, 具体而言, 采用 ResNeXt 作为骨干网络, 在输电线路故障检测数据集上进行验证, 结果如表4所示。

特征注意力融合模块使得 mAP 评分提高 1.62 %, 各故障检测 F1 评分分别提高 0.03、0.05、0.02、0.04, 这意味着该模块增强模型特征提取能力, 有助于加强模型的整体检测性能。多尺度特征融合密集金字塔模块增加 2.62 % 的 mAP, F1 评分分别提高 0.09、0.06、0.04、0.07, 显著提高模型的整体性能。这种特征融合模块促进网络对各个尺度特征的融合学习, 丰富模型的特征表示。通过尺度不变误差损失函数训练后的模型进一步增加 1.37 % 的 mAP, 其充分利用不同尺度的特征信息进一步加强模型的检测精度。

在检测效率方面, 特征注意力融合和尺度不变误差损失对模型整体的参数量和计算量影响较小, FPS 均下降 1。多尺度特征融合密集金字塔由于其更为复杂的特征融合过程, 对速度有较大影响, 降低 60 的 FPS。尽管如此, 模型的检测速度仍能达到 56 FPS, 这充分满足实时性检测的要求, 与其相对

表 4 消融实验结果

Tab. 4 Ablation experimental results

骨干	改进方法			mAP 值/%	F1 值				FPS 值/ (帧·s ⁻¹)
	特征注意力融合	多尺度特征融合	尺度不变误差损失		绝缘子自爆	绝缘子异常	螺栓扣	异物	
√				92.17	0.81	0.82	0.84	0.80	72
√	√			93.79	0.84	0.87	0.86	0.84	71
√		√		94.79	0.89	0.88	0.88	0.87	60
√	√	√		96.13	0.93	0.92	0.92	0.87	59
√		√	√	95.52	0.92	0.91	0.90	0.91	59
√	√	√	√	97.50	0.94	0.93	0.92	0.91	56

的是准确度 mAP 评分提高 5.33 %，避免了误检和漏检问题。综合考虑检测精度和检测速度，本文所提方法能够更好地满足实时和准确检测的要求。

3.3.5 模型鲁棒性验证

电力配电线路多处于野外场景，野外场景常常伴随不确定的天气因素影响，图像的亮度也会随之改变，进而影响模型的检测准确度。鉴于此，比较所提模型与 Faster RCNN、YOLOv7 以及 YOLOv8 模型在低亮度条件下的检测性能，结果如图 7 所示。

由图 7 可知，在低亮度条件下，部分故障问题与背景之间区分不明显，Faster RCNN、YOLOv7 以及 YOLOv8 在检测故障时，无法精准地定位故障位置，且检测准确度较低。相比之下，所提模型仍能较为精确的定位故障位置，且检测准确度在对比算法中达到最优，这得益于所提模型采用多尺度特征融合的策略，有效地区分了有效故障位置以及无关背景信息，充分验证了所提模型的鲁棒性。

3.3.6 InsPLAD 数据集性能测试

为了验证所提模型的泛化能力，在 InsPlad 数

据集上验证所提模型的检测性能，将模型与主流目标检测算法进行对比，结果如表 5 所示。

表 5 InsPLAD 数据集测试结果

Tab. 5 Testing results on InsPLAD dataset

方法	mAP 值/%	FPS 值	Params/值 M	FLOPS 值/G
Faster RCNN	89.53	18	145.53	155.43
SSD	84.21	43	40.34	83.61
CenterNet	87.56	67	21.35	46.35
YOLOv5	85.33	80	7.23	16.51
YOLOv7	90.21	45	36.92	104.78
YOLOv8	89.78	72	11.18	28.54
所提模型	91.02	69	13.42	33.21

根据表 5 数据，在 InsPLAD 数据集上，所提模型的 mAP 指标达到了 91.02 %，在所有对比算法中达到最优的检测准确度。模型复杂度方面，所提模型的参数量达到了 13.42 M，远低于 Faster RCNN、SSD、CenterNet 和 YOLOv7，仅比 YOLOv5 和 YOLOv8 高 6.19 M、2.24 M，具有相对较低的模型复杂度。此外，所提模型需要 33.21 G 浮点运算次数即可完成高精度的输电线路故障检测，具有较



图 7 模型鲁棒性验证

Fig. 7 Validation of model robustness

大的运算优势。同时,所提模型推理速度达到69帧/s,略低于YOLOv5和YOLOv8,但仍超过其他对比模型。

综上,在InsPLAD数据集中,所提模型表现出优越性能,其展现出最高的检测准确度,在模型复杂度、计算量和推理速度方面也表现出明显优势,具有较高的泛化能力。

4 结论

本文提出了一种基于多尺度特征融合的输电线路故障检测方法。该方法基于多尺度特征融合思想,在网络中构建多尺度特征融合密集金字塔,并嵌入特征注意力融合策略,增强模型对不同尺度特征的学习能力和整体特征提取能力,同时提高了对目标信息的关注程度,有效地加强了模型的鲁棒性和检测准确性。通过实验测试,主要结论如下。

1)加深多尺度特征的融合可以使检测模型较好的应对目标尺度变化不一的问题,确保网络能够学习到不同深度的特征映射,覆盖更大的尺度范围,进而提高模型的预测性能,该方法在输电线路故障检测数据集上的mAP分别较FPN、BiFPN、PANet高8.30%、6.32%、4.50%,优于其他先进的特征融合策略。

2)与其他先进目标检测算法的实验对比结果显示,所提方法在绝缘子自爆、绝缘子自爆、异常、螺栓口脱离、异物上的AP指标分别达到了97.35%、97.01%、98.94%、96.43%,且mAP达到了97.50%,整体优于SSD、CenterNet以及YOLO系列算法,FPS达到了56,具有良好的实时性能。

3)InsPLAD公开数据集上的结果显示所提模型mAP达到了91.02%,优于其他对比算法,在模型复杂度、计算量和推理速度方面也表现出明显的优势,具有较强的泛化能力。

综上,本文所提的输电线路故障检测方法可以良好地权衡检测准确度和效率,满足实时电力巡检要求。在未来的工作中,将进一步探索一种更高效的多尺度融合框架,并且在确保准确度的同时调整和优化模型以适应硬件限制,实现在计算资源受限的嵌入式设备中的部署。

参考文献

[1] 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.

[2] 李婷,张孝军,潘华,等.基于运检管控平台多源信息融合的输电线路故障类型诊断方法[J].南方电网技术,2023,17(12):109-118.

LI Ting, ZHANG Xiaojun, PAN Hua, et al. Fault type diagnosis method of transmission lines based on multi-source information fusion of operation inspection and control platform [J]. Souther Power System Technology, 2023, 17(12): 109-118.

[3] KATRASNIK J, PERCUS F, LIKAR B. A survey of mobile robots for distribution power line inspection [J]. IEEE Transactions on Power Delivery, 2010, 25(1): 485-493.

[4] DAI L, QI J, HAN J, et al. Camera selection for unmanned helicopter power line inspection [C]// IEEE PES Innovative Smart Grid Technologies, May 21-23, 2012, Tianjin, China. New York: IEEE, 2012: 1-4.

[5] 彭向阳,陈驰,饶章权,等.基于无人机多传感器数据采集的电力线路安全巡检及智能诊断[J].高电压技术,2015,41(1):159-166.

PENG Xiangyang, CHEN Chi, RAO Zhangquan, et al. Safety inspection and intelligent diagnosis of transmission line based on unmanned helicopter of multi sensor data acquisition [J]. High Voltage Engineering, 2015, 41(1): 159-166.

[6] 付晶,谈家英,周立玮,等.输电线路无人机巡检图像缺陷智能识别方法分析[J].高电压技术,2023,49(S1):103-110. FU Jing, TAN Jiaying, ZHOU Liwei, et al. Analysis of intelligent defect recognition method for UAV inspection images of transmission lines [J]. High Voltage Engineering, 2023, 49(S1): 103-110.

[7] 顾超越,李喆,史晋涛,等.基于改进Faster-RCNN的无人机巡检架空线路销钉缺陷检测[J].高电压技术,2020,46(9):3089-3096.

GU Chaoyue, LI Zhe, SHI Jintao, et al. Detection for pin defects of overhead lines by UAV patrol image based on improved Faster-RCNN [J]. High Voltage Engineering, 2020, 46(9): 3089-3096.

[8] ZHAO Z, QI H, QI Y, et al. Detection method based on automatic visual shape clustering for pin-missing defect in transmission lines [J]. IEEE Transactions on Instruments and Measurements, 2020(69): 6080-6091.

[9] ZHAI Y, YANG X, WANG Q, et al. Hybrid knowledge R-CNN for transmission line multifitting detection [J]. IEEE Transactions on Instrument and Measurement, 2021(70): 1-12.

[10] 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 Instrument and Measurement, 2021(70): 1-8.

[11] REN S, HE K, 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.

[12] ZHEN W. Real-time inspection model for key components of transmission lines based on improved YOLOv4 [J]. Scientific

- Technology Engineering, 2021, 21(24): 10393 – 10400.
- [13] QIU Z, ZHU X, LIAO C, et al. A lightweight YOLOv4-EDAM model for accurate and real-time detection of foreign objects suspended on power lines [J]. IEEE Transactions on Power Delivery, 2023, 38(2): 1329 – 1340.
- [14] 马富齐, 王波, 董旭柱, 等. 面向输电线路覆冰厚度辨识的多感受野视觉边缘智能识别方法研究[J]. 电网技术, 2021, 45(6): 2161 – 2169.
MA Fuqi, WANG Bo, DONG Xuzhu, et al. Receptive field vision edge intelligent recognition for ice thickness identification of transmission line [J]. Power System Technology, 2021, 45(6): 2161 – 2169.
- [15] 屈志坚, 张博语, 杨行, 等. 基于MFDC-SSD网络的接触网定位线夹缺陷识别[J]. 铁道学报, 2024, 46(5): 48 – 57.
QU Zhijian, ZHANG Boyu, YANG Hang, et al. Fault identification of overhead contact system steady ears based on MFDC-SSD network [J]. Journal of the China Railway Society, 2024, 46(5): 48 – 57.
- [16] SILVA A, FELIX H, SIMOES F, et al. InsPLAD: a dataset and benchmark for power line asset inspection in UAV images [J]. International Journal of Remote Sensing, 2023, 44(23): 7294 – 7320.
- [17] LEE J, HAN M, KO D, et al. From big to small: multi-scale local planar guidance for monocular depth estimation [R/OL]. [2021-9-23]. <https://arxiv.org/abs/1907.10326>.
- [18] LAINA I, RUPPRECH C, BELAGIANNIS V, et al. Deeper depth prediction with fully convolutional residual networks [C]// International Conference on 3D Vision, October 25 – 28, 2016, Stanford, CA, USA. New York: IEEE, 2016: 238 – 249.
- [19] FU H, GONG M, WANG C, et al. Deep ordinal regression network for monocular depth estimation [C]// IEEE Conference on Computer Vision and Pattern Recognition, June 18 – 23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 2002 – 2011.
- [20] 陈乾, 洪征, 司健鹏. 融合SENet和Transformer的应用层协议识别方法[J]. 计算机科学与探索, 2024, 18(3): 805 – 817.
CHEN Qian, HONG Zheng, SI Jianpeng. Application layer protocol recognition incorporating SENet and Transformer [J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(3): 805 – 817.
- [21] GUO R, WANG G, SONG T, et al. CA-Net: comprehensive attention convolutional neural networks for explainable medical image segmentation [J]. IEEE Transactions on Medical Imaging, 2021, 40(2): 699 – 711.
- [22] 闫宇楠, 刘智康, 徐佳文, 等. 基于CBAM-CNN和压电悬臂梁的温度解耦质量感知方法[J]. 仪器仪表学报, 2024, 45(4): 113 – 126.
YAN Yunan, LIU Zhikang, XU Jiawen, et al. Temperature decoupled mass sensing based on CBAM-CNN and piezoelectric cantilever beam [J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 113 – 126.
- [23] 张顺, 邓艾东, 徐硕, 等. 基于DFT与ECA的滚动轴承故障诊断[J]. 振动. 测试与诊断, 2024, 44(4): 754 – 760, 830.
ZHANG Shun, DENG Aidong, XU Shuo, et al. Fault diagnosis of rolling bearing based on discrete fourier transform and efficient channel attention [J]. Journal of Vibration, Measurement and Diagnosis, 2024, 44(4): 754 – 760, 830.
- [24] 周晓欣, 陈俊谕, 卢焕冲, 等. 基于超声图像FPN-SENet-FL深度卷积神经网络模型鉴别乳腺良、恶性肿瘤及预测乳腺癌分子分型[J]. 中国医学影像技术, 2024, 40(3): 372 – 377.
ZHOU Xiaoxin, CHEN Junyu, LU Huanchong, et al. FPN-SENet-FL deep convolutional neural network model for differentiating benign and malignant breast tumors and predicting molecular subtypes of breast cancers based on ultrasonic images [J]. Chinese Journal of Medical Imaging Technology, 2024, 40(3): 372 – 377.
- [25] 张姝瑾, 许兴时, 邓洪兴, 等. 基于YOLO v8n-seg-FCA-BiFPN的奶牛身体分割方法[J]. 农业机械学报, 2024, 55(3): 282 – 289, 391.
ZHANG Shujin, XU Xingshi, DENG Hongxing, et al. Segmentation model of cow body parts based on YOLOv8n-seg-FCA- BiFPN [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(3): 282 – 289, 391.
- [26] 陈亚芳, 廖飞, 黄新宇, 等. 多尺度YOLOv5的太阳能电池缺陷检测[J]. 光学精密工程, 2023, 31(12): 1804 – 1815.
CHEN Yafang, LIAO Fei, HUANG Xinyu, et al. Multi-scale YOLOv5 for solar cell defect detection [J]. Optics and Precision Engineering, 2023, 31(12): 1804 – 1815.

收稿日期: 2024-03-21; 网络首发日期: 2024-09-30

作者简介:

尤敏(1985), 男, 高级工程师, 硕士, 研究方向为电力系统及其自动化;

徐祥海(1979), 男, 通信作者, 高级工程师, 硕士, 研究方向为电气工程及自动化, manus2023@163.com;

田易之(1983), 男, 副教授, 博士, 研究方向为电力系统稳定与控制。