

DOI: 10.19650/j.cnki.cjsi.J2614881

基于 BDEA-VFNet 的架空线路涉鸟故障边端 轻量级检测方法^{*}

缪希仁, 胡邵程, 刘欣宇, 江 灏, 贺 浩

(福州大学电气工程与自动化学院 福州 350108)

摘 要:随着架空输电线路巡检规模与频次持续提升,海量航拍图像对云端计算与通信带宽提出挑战,而现有的涉鸟故障检测方法在复杂背景与密集小目标场景下的精度与实时性仍难以兼顾。为此,提出了一种面向边缘端涉鸟故障的轻量级目标检测方法(BDEA-VFNet),该方法首先在 VFNet 的基础上,提出全卷积掩码自编码器预训练策略,引入全局响应归一化层,在加速模型收敛、降低复杂度的同时增强对小目标特征的提取能力;其次,提出神经架构搜索优化的特征金字塔结构,提升多尺度融合效率并减少跨层计算损失;最后,设计基于 SimOTA 的动态软标签分配策略,提出改进的 FCOS 无锚框机制生成候选目标,强化难例学习并降低复杂背景下涉鸟故障漏检风险。所提算法在架空输电线路涉鸟故障数据集及无人机边缘设备上进行了实验验证,结果表明,BDEA-VFNet 能在边端快速有效地检测出涉鸟故障,相较 VFNet 算法,mAP 精度提升了 5.20%,参数量降低了 77.37%,计算量削减了 83.19%,有效平衡了检测精度与边端部署的轻量化需求。

关键词: 输电线路;涉鸟故障;VFNet;边缘计算;轻量级目标检测

中图分类号: TP391.41 TH183.3 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Lightweight edge-side detection of bird-related outages in overhead transmission lines with BDEA-VFNet

Miao Xiren, Hu Shaoheng, Liu Xinyu, Jiang Hao, He Hao

(College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

Abstract: As the scale and frequency of overhead transmission line inspections continue to increase, the massive volume of aerial imagery poses significant challenges to cloud computing resources and network bandwidth. Meanwhile, existing bird-related outage detection methods still struggle to balance accuracy and real-time performance in scenarios involving complex backgrounds and densely distributed small objects. To address this issue, this paper proposes a lightweight object detection method for bird-related fault detection on edge devices, termed BDEA-VFNet. First, based on the VFNet architecture, a fully convolutional masked autoencoder pre-training strategy is introduced together with a global response normalization layer, which accelerates model convergence and reduces model complexity, and enhances the feature extraction capability for small objects. Second, a feature pyramid structure optimized via neural architecture search is employed to improve the efficiency of multi-scale feature fusion and reduce cross-layer information loss. Finally, a dynamic soft label assignment strategy based on SimOTA is designed, and an improved FCOS anchor-free mechanism is proposed to generate candidate targets, thereby enhancing hard example learning and reducing the risk of missed detection of bird-related fault in complex backgrounds. Experimental results on an overhead transmission line bird-related outage dataset and UAV edge devices demonstrate that BDEA-VFNet can rapidly and effectively detect bird-related outages on edge devices. Compared with the original VFNet, BDEA-VFNet improves mAP by 5.20%, while reducing the number of parameters by 77.37% and the computational cost by 83.19%, effectively balancing detection accuracy and the lightweight requirements of edge deployment.

Keywords: transmission lines; bird-related fault detection; VFNet; edge computing; lightweight object detection

0 引言

电网是保障国民经济和能源安全的重要基础设施,其中输电线路作为电能传输的核心通道^[1-3],其安全稳定运行至关重要^[4-6]。近年来,随着架空输电线路覆盖范围的不断扩大以及自然环境的持续改善,鸟类活动与输电线路运行空间高度重叠,涉鸟故障已成为仅次于雷害和外力破坏的第三大故障来源^[7]。鸟类在杆塔上的筑巢和频繁活动,易引发绝缘下降、短路接地及断电跳闸等故障,严重威胁电力系统的安全稳定运行^[8]。因此,定期开展输电线路巡检工作,及时发现并消除输电线路涉鸟故障及相关隐患,对保障电力系统安全稳定运行具有重要意义^[9-10]。

近年来,随着无人机技术的迅速发展^[11-12],无人机等智能巡检方式逐渐取代传统人工巡检,成为输电线路巡检的主要手段^[13-16],显著提升了作业效率和覆盖范围。Qiu 等^[17]将检测有无鸟类的常规任务精细为多种鸟类的类别检测,并采用分段式训练、余弦退火方法改进 YOLOv4-Tiny,在构建 20 种高危鸟类数据集的基础上初步实现对多类鸟种的同时检测。张烨等^[18]解析了鸟类、鸟巢、鸟粪、鸟啄在内的常见涉鸟故障成因,并设计了一种结合多尺度卷积核运算与传统图像处理的信息融合模块,巧妙解决了训练集信息失衡带来的模型过拟合问题。为减少复杂背景的干扰,邱志斌等^[19]采用类激活映射进行图像预处理,并借鉴 Delphi 法提高鸟类分类准确率。但该方法需要同时运行 4 种深度学习模型并对结果加权,运行效率过低。而且在实际巡检的任务中,输电线路巡检范围广、频次高,航拍图像数据量庞大,基于图片回传的主要研究将导致传输成本高昂,对云端存储与计算资源造成巨大负担,难以保证故障排查的实时性^[20]。传统的“无人机采集—图像回传—云端分析”模式已难以满足智能运维对高效性与实时性的需求^[21]。为此,电力领域逐步引入边缘计算技术,通过在边端设备直接部署深度学习模型,以实现巡检图像的快速检测^[22]。

边缘计算可将计算与存储资源部署在无人机等边端设备侧,无需将数据传输至云端,从而获得更高实时性的计算能力和响应能力,极大降低了网络开销和云计算的资源压力^[23-24]。目前,已有学者开展了边缘计算在电力领域的应用研究^[25]。针对电力物联网的异构接入问题,崔恒志等^[26]构建包含物模型、规则引擎的通用边缘计算框架。Hou 等^[27]验证了边缘计算在输电线路远程监测系统通信中的通信适配性。由于边端设备具有体积小、功耗低的特点,难以满足常规深度学习模型的部署,Liu 等^[28]通过简化模型结构以得到可边缘部署的轻量化模型 RepYOLO。张鋆等^[29]借助深度可分离

卷积和通道剪枝对 YOLOv3 进行轻量化压缩以检验吊车等目标,但对山火、导线异物这类形态复杂目标的检测精度仅为 50% 左右,且仅在树莓派上进行验证,忽视了常见边缘设备的验证。胡晨龙等^[30]在模型轻量化的基础上,采用 DeepStream 显存复用技术调用 Tensor RT 模块实现模型重构与边缘端加速,并在实际巡检中验证了无人机边缘计算在输电线路领域的可行性。尽管现有研究已奠定坚实基础,但由于鸟类、鸟巢等目标形态多变且尺度较小,参数量较大的传统高精度检测模型难以通过知识蒸馏等方式在降低规模的同时维持精度。而有关涉鸟故障边端检测的研究占比也相对较少,轻量化模型大多因追求参数压缩,导致其对深层特征的提取能力不足,易造成复杂背景干扰下涉鸟故障的漏检。

本文针对输电线路涉鸟故障检测中存在的云端负担大、精度速度难平衡、边端部署困难等问题,提出一种基于 BDEA-VFNet (bird defect edge assigner-varifocalnet) 的边端涉鸟故障轻量级检测方法。该方法以 VFNet (varifocalnet) 为基础^[31],选用经全卷积掩码自编码器 (fully convolutional masked autoencoder, FCMAE) 预训练的 ConvNeXt V2-femto 作为骨干网络,并引入全局响应归一化层 (global response normalization, GRN),在降低模型复杂度的同时增强对小目标涉鸟故障特征的提取;其次,利用神经架构搜索重构特征金字塔,提升多尺度特征表征能力,并通过压缩输出通道减少跨层连接产生的计算损耗;最后为加强难例挖掘,引入基于 SimOTA (simplified optimal transport assignment) 的动态软标签分配策略,减少对小目标鸟类的误分配。最后用 TensorRT 重构优化,并部署在边缘计算设备 Jetson Xavier NX 上进行检验。实验结果表明,基于 BDEA-VFNet 的架空线路涉鸟故障边端轻量级检测方法适合部署在边缘设备中,可实现对输电线路涉鸟故障的高效检测。

1 算法原理

1.1 VFNet 算法

VFNet 是一种基于 FCOS (fully convolutional one-stage object detection)^[32] 和自适应训练样本选择 (adaptive training sample selection, ATSS)^[33] 的一阶段目标检测算法。该算法通过引入 IoU (intersection over union) 感知分类分数 (IoU-aware classification score, IACS),实现了目标置信度与定位精度的联合表征,有效缓解了 NMS (non-maximum suppression) 排序过程中分类置信度和定位精度失配的问题。并基于此设计了用于训练模型并预测 IACS 的 VFL (varifocal loss) 损失函数与用于增强几何特征表示的星形边界框 (star dconv)。其中, VFL 的计算表达式如式(1)所示。

$$\text{VFL}(p, q) =$$

$$\begin{cases} -q(q \log(p)) + (1-q) \log(1-p), & q > 0 \\ -\alpha p^\gamma \log(1-p), & q = 0 \end{cases} \quad (1)$$

式中: p 为 IoU 感知分类分数; 正样本的 q 为 IoU 值, 负样本的 q 为 0; γ 为调节因子。

星形的边框特征表示使用 9 个固定采样点的特征, 与现有密集目标检测器中的点特征相比, 能更好地捕捉到边框的几何信息和相邻区域的语义信息。VFL 损失函数则通过把 IoU 检测框定位信息融入分类分支, 缓解了检测过程中密集目标定位不准的问题, 适用于复杂背景干扰严重、目标尺寸小且密集的输电线路涉鸟故障场景。然而, VFNet 使用 ATSS (adaptive training sample selection) 方法对正负样本进行硬性分配, 且用于划分判据的 IoU 阈值依赖于物体的统计数据, 没有很好的考虑被检测物形态尺寸的不同分布。在涉鸟故障这类检测目标多

变不固定且大小差异较大的任务中, 容易忽略 IoU 阈值的临界样本, 无法很好的同时诊断所有缺陷目标, 容易造成漏检等严重问题。且相较于主流轻量级骨干网络, VFNet 模型的参数量与计算复杂度仍过高, 导致推理速度比较慢, 难以满足算力受限情况下无人机边端的部署要求。但其总体结构相对简单, 具有较大的模型压缩空间, 便于轻量化改进后的无人机边端部署。

1.2 BDEA-VFNet 算法

为解决 VFNet 在输电线路涉鸟故障检测任务中存在的推理开销大、特征融合冗余、多变目标难定位等局限性, 本文提出了 BDEA-VFNet 算法, 结构由骨干网络 (backbone)、颈部网络 (neck) 和检测头 (head) 组成。整体框架如图 1 所示, 主要分为输入与特征提取、特征融合与优化、目标生成与分配、识别与分类 4 个阶段, 具体检测过程如下。




图1 BDEA-VFNet 算法原理

Fig. 1 Architecture of the BDEA-VFNet algorithm

BDEA-VFNet 模型输入为输电线路巡检图像, 输出为类别、坐标和置信度 3 部分。在具体的模型运行方面, 首先将图像输入至 ConvNeXt V2-femto^[34] 骨干网络中进行特征提取。具体结构如图 2 所示, 该网络舍去了通道间特征交互, 改用 Depthwise Conv2d 对各输入通道进行深度卷积, 在保证特征表达能力的同时降低参数量。同时, 选用 7×7 的大卷积核使其在空间结构上与预训练模型保持一致, 确保了特征迁移的有效性; 且可扩大感受野以弥补大尺度缺陷的特征信息和空间上下文联系。为了更好的在图像中找到并学习涉鸟故障的相关局部特征, 采用多尺度掩码技术引导模型进行自监督重建, 该方法可将输入图像分割成离散状态, 用掩码来迫使模型可以在较强干扰情况下学习到缺陷的语义信息。此外, 网络

还引入全局响应归一化层, 通过自适应调节通道权重增大对鸟类、鸟巢等检测目标的特征响应, 更好地区分图像背景与鸟类、鸟巢等关键异常目标。

其次, 在颈部网络的选取方面, 常见的特征金字塔网络虽能提升目标检测算法的小目标检测能力, 但其固定的层级连接模式难以适应输电线路涉鸟故障检测复杂背景下的多尺度目标分布, 且其自顶向下的单向传播方式会导致跨层交互效率偏低、浅层细节信息衰减不足。因此本模型改用经神经架构搜索重构的 NAS-FCOS FPN (neural architecture search for fully convolutional one-stage object detection feature pyramid network)^[35] 实现对多尺度特征的高效聚合。如图 3 所示, 该网络在 FCOS 框架下构建包含横向连接、跳跃连接及可变形卷积的搜索空间, 利




图2 ConvNeXt V2 结构

Fig. 2 Structure of ConvNeXt V2




图3 NAS-FCOS FPN 结构

Fig. 3 Structure of NAS-FCOS FPN

用 NAS 策略自动搜索最佳 FPN 拓扑。此外, NAS-FCOS FPN 还通过跳跃连接和双向特征传递提升了跨层特征的交互效率,进一步丰富了融合特征的细节信息,更适用于输电线路涉鸟故障检测这类密集小目标的检测场景。

为更好的适配无人机边缘应用,本模型借鉴 Transformer 网络架构,根据骨干网络 ConvNeXt V2 的输出通道配置[48, 96, 192, 384],将 NAS-FCOS FPN 的输出通道数从 256 压缩至 96,减少了跨层连接时的计算损耗。此外,由于涉鸟故障中的鸟种体态不一、鸟巢形状多变,本模型将模型中的算子替换为具有调制机制(modulation mechanism)的 DConv V2。该算子可根据各采样点的调

制标量自适应调节位置注意力权重,赋予模型对目标形状变化的适应能力。

针对识别与分类任务,采用 IACS 来构建目标存在性与定位精度的联合度量体系。这样得到的分类得分不再只反映类别置信度,也能同步体现预测框的定位质量,因此避免了传统检测器中分类置信度高但定位不准的问题,提高检测的可靠性。最终模型可依据 IACS 过滤掉低质量的候选框,输出鸟类与鸟巢的类别及其空间位置,实现低漏检前提下的高可靠实时检测。

1.3 正负样本分配策略优化

在目标检测领域,通常根据预测边界框与真实标注框(ground truth, GT)的匹配程度来划分正负样本。Anchor-based 目标检测算法常根据数据集统计信息,设定 IoU 阈值来决定样本类别。但在涉鸟故障检测任务中,检测目标包含体量较大的鸟巢和微小鸟类目标,呈现出较大的尺度差异,这会导致检测目标的锚框与真实框的 IoU 均值低于常规目标,可用正样本数量不足,进而影响模型训练与精度。

VFNet 算法虽然引入了 ATSS 正负样本分配策略,将原先的静态阈值改为根据 IoU 阈值和中心点的距离动态设置阈值,从而可以自适应确定正负样本。然而,ATSS 策略需要计算多个候选框的中心距离和 IoU 均值,计算量较大。并且这种基于统计特征的阈值划分方式易使正样本更倾向于大尺度目标而降低小目标的检测能力。

针对 VFNet 正负样本分配策略的不足,本模型在 FCOS 目标生成的基础上,引入基于 SimOTA 的动态软标签分配策略^[36],以替换原模型中的 ATSS 目标生成方式和正负样本分配策略。动态软标签分配策略的核心思想是利用真实框和候选框间的匹配程度来动态计算标签权重,并分配给对应的候选框。与其他动态分配策略将候选框直接划分正负样本不同,该策略通过在区间[0, 1]分配标签权重的方式,使样本匹配更加精细。当权重值越接近 1 时,表示该样本为正样本的概率越高。这样做减少了硬阈值截断带来的量化误差,避免当处理小目标或边缘目标时带来的正负样本误分配问题,使模型能准确学到物体的细粒度特征。

动态软标签分配策略的代价函数如式(2)所示。

$$C = \lambda_1 C_{cls} + \lambda_2 C_{reg} + \lambda_3 C_{center} \quad (2)$$

式中: C_{cls} 、 C_{reg} 和 C_{center} 分别为分类代价、回归代价和区域代价;权重 λ_1 、 λ_2 和 λ_3 设置为 1、3 和 1。

C_{cls} 引入了标签得分 Y_{soft} ,避免其他分配策略中因明确分配样本,造成的高分类得分但边界框不准的样本使得分类代价偏低问题。计算公式如式(3)所示。

$$C_{cls} = CE(P, Y_{soft}) \times (Y_{soft} - P)^2 \quad (3)$$

式中:CE 代表交叉熵损失函数; P 代表模型预测的概率值。

回归代价的计算公式如式(4)所示。

$$C_{\text{reg}} = -\log(IoU) \quad (4)$$

区域代价的计算公式如式(5)所示。

$$C_{\text{center}} = \alpha^{|x_{\text{pred}} - x_{\text{gt}}| - \beta} \quad (5)$$

式中: x_{pred} 为预测框中心点坐标; x_{gt} 为真实框中心点坐标; α 、 β 为软中心区域超参数。

改进后的正负样本分配策略为:首先,在经 NAS 优化的 FPN 上按 FCOS 范式构建多层级特征图并生成密集特征点,结合真实标注为其生成相应的类别标签与候选框。随后,引入动态软标签分配策略,依据候选框与真实框的匹配质量自适应确定正负样本。最后,在动态分配结果上分别计算分类损失与回归损失。在不同批次的训练过程中,动态软标签分配会随当前预测结果实时调整样本分配,使模型持续聚焦高质量匹配并学习到更具判别力的特征。

2 实验分析

2.1 实验环境配置

本实验采用的平台操作系统为 Ubuntu 22.04, CPU 为 128 核心/256 线程的 AMD EPYC 9754 128-Core Processor, GPU 为 24 GB 显存的 NVIDIA GeForce RTX 3090, CUDA 版本 11.8, 编程语言为 Python 3.8.20, 深度学习框架 Pytorch 版本为 2.1.0。

模型的训练迭代轮次(epoch)为 36, 学习率(lr)初始值为 0.001, 并在第 27 和第 33 个 Epoch 时乘以系数 0.1 进行衰减。优化器采用 AdamW, 权重衰减率(weight decay)为 0.05, 批次尺寸(batch size)为 8。输入图像会被随机缩放为两种分辨率之一, 分别为 1 333×480 和 1 333×960。数据增强策略包括图像随机水平翻转(翻转概率为 50%)和图像尺寸随机缩放。为保证实验的客观性与公平性, 本文所有模型均在同一硬件平台、数据集划分情况下采用相同的数据增强、输入分辨率与训练轮次下训练。

2.2 数据集与评估指标

本文构建了涵盖鸟巢和涉鸟故障常见高危鸟种两大类目标的输电线路涉鸟故障数据集。其中, 输电线路鸟巢图像均源自国家电网实际巡检过程中的航拍图像, 输电线路涉鸟故障常见高危鸟种来自国家电网巡检航拍图像和网络爬虫数据。

数据集所有图像均由专业人员使用 LabelImg 标注工具进行矩形框标注, 采用三级人工校验确保标注精度。总数共 3 450 张, 按照 8:2 的比例划分为训练集和测试集, 类型分布均衡, 具体数量如图 4 所示。

其中, 鸟巢类目标共 1 360 张, 涵盖不同航拍位置(塔头、塔身和横担)、不同航拍角度(俯拍、仰拍和正拍)以及不同背景(森林、山川和城镇)的输电线路鸟巢图




图4 数据集中各类样本数量统计

Fig. 4 Statistics of sample quantities for each category

像, 如图 5(a) 所示; 鸟类目标共 2 090 张, 涵盖黑鹇、东方白鹇、白鹭、夜鹭、大鸛、喜鹊、珠颈斑鸠和家燕等八种高危鸟类, 如图 5(b) 所示, 其中白鹭类包含大白鹭、中白鹭和白鹭, 珠颈斑鸠类还包含鸽子。

为客观地评估本文的涉鸟故障检测模型, 选择平均精确率(mean average precision, mAP)、平均召回率(mean average recall, mAR)、模型参数量(parameters, Params)、浮点计算量(floating point operations, FLOPs)作为评价指标, 其中 IoU 阈值从 0.5 ~ 0.95 按步长 0.05 取平均。mAP 与 mAR 的具体计算公式如式(6)~(7)所示。

$$mAP = \frac{1}{N_{\text{cls}}} \sum_{i=1}^{N_{\text{cls}}} \left(\frac{1}{|T|} \sum_{t \in T} AP_i(t) \right) \quad (6)$$

$$mAR = \frac{1}{N_{\text{cls}}} \sum_{i=1}^{N_{\text{cls}}} \left(\frac{1}{|T|} \sum_{t \in T} AR_i(t) \right) \quad (7)$$

式中: TP 为正确正样本数; FP 为错误正样本数; FN 为正确负样本数; $AP_i(t)$ 、 $AR_i(t)$ 为 i 类目标的平均精确率、平均召回率; T 为 IoU 阈值集合; $|T|$ 为阈值个数; t 为特定的 IoU 阈值; N_{cls} 为总类别数。

2.3 实验结果与分析

为验证算法的有效性, 探讨不同改进模块对 BDEA-VFNet 性能提升的贡献, 本文将模型在输电线路涉鸟故障数据集集中进行消融实验, 共选取以下 4 个改进模块进行分析:

- 1) 模块 A: FCMAE 预训练的 ConvNeXt V2;
- 2) 模块 B: GRN 模块;
- 3) 模块 C: NAS-FCOS FPN;
- 4) 模块 D: 动态软标签分配策略。

其中, 所有模型均采用 2.1 节所述的超参数配置与数据增强策略进行训练, 以排除训练策略差异对实验结果的干扰。表 1 展示了消融实验结果, 表中“√”表示该模型加载了对应的改进模块, 括号内的数值表示模型相较 VFNet 在该评价指标上的增幅。



(a) 输电线路鸟巢图像
(a) Transmission line bird nest images



(b) 输电线路常见高危鸟种
(b) Common high-risk bird species on transmission lines

图 5 输电线路涉鸟故障数据集

Fig. 5 Dataset samples for nests and hazardous bird species

表 1 BDEA-VFNet 消融实验
Table 1 Ablation experiments on BDEA-VFNet

模型名称	算法模块				评价指标			
	A	B	C	D	<i>mAP</i> /%	<i>mAR</i> /%	<i>Params</i> /M	<i>FLOPs</i> /G
VFNet					71.2	77.7	32.7	166
模型 A1	√				72.6(+1.4)	77.9(+0.2)	6.1(−26.6)	27.0(−139.0)
模型 A2		√			73.6(+2.4)	78.8(+1.1)	32.7(+0.0)	166.0(+0.0)
模型 A3			√		74.6(+3.4)	79.4(+1.7)	39.5(+6.8)	162.0(−4.0)
模型 A4				√	73.6(+2.4)	78.7(+1.0)	32.7(+0.0)	166.0(+0.0)
模型 B1	√	√			74.1(+2.9)	79.4(+1.7)	6.1(−26.6)	27.0(−139.0)
模型 B2	√		√		72.8(+1.6)	78.0(+0.3)	7.4(−25.3)	27.9(−138.1)
模型 B3	√			√	71.8(+0.6)	77.9(+0.2)	6.1(−26.6)	27.0(−139.0)
模型 B4		√	√		74.8(+3.6)	79.6(+1.9)	39.6(+6.9)	162.0(−4.0)
模型 B5		√		√	73.5(+2.3)	79.3(+1.6)	32.7(+0.0)	166.0(+0.0)
模型 B6			√	√	74.4(+3.2)	79.5(+1.8)	39.5(+6.8)	162.0(−4.0)
模型 C1		√	√	√	75.0(+3.8)	80.2(+2.5)	39.6(+6.9)	162.0(−4.0)
模型 C2	√		√	√	72.3(+1.1)	78.5(+0.8)	7.4(−25.3)	27.9(−138.1)
模型 C3	√	√		√	73.2(+2.0)	78.7(+1.0)	6.1(−26.6)	27.0(−139.0)
模型 C4	√	√	√		73.9(+2.7)	79.4(+1.7)	7.4(−25.3)	27.9(−138.1)
BDEA-VFNet	√	√	√	√	74.9(+3.7)	79.7(+2.0)	7.4(−25.3)	27.9(−138.1)

由表 1 可知,模块 A 引入 FCMAE 对 ConvNeXt V2 进行预训练,该网络用各通道深层卷积替代通道间的交互卷积的方式减少参数量。在 mAP 与 mAR 检测精度稳步提升的情况下,大幅降低了模型的参数量与计算量,这表明自监督学习增强了预训练后骨干网络的特征提取能力,有利于边端轻量化部署与实时检测;模块 B 在保持计算量与参数量不变的情况下,进一步提升精度,说明 GRN 模块通过对各通道的特征图进行归一化处理,缓解了不同尺度与不同层级特征幅值差异,可有效增强特征竞争与检测精度;模块 C 作为单模块添加时会带来最高的精度涨幅,较 VFNet 模型 mAP 提升 3.4%,但在 RenNet-50 骨干网络架构中的 256 通道数约束下会增加一定的模型大小,说明单独增强多尺度特征融合需要消耗较大的算力资源。而其与 ConvNeXt V2 模块形成了较好的协同作用,在通道数从 256 降至 96 的情况下,采用模块 C 在增加了 1.3 M 的参数量和 0.9 G 的计算量的同时使检测精度得到进一步提升。模块 D 在 FCOS 目标分配的基础上,用动态软标签分配替代硬标签分配,提升正负样本分配的细粒度,减少了复杂输电线路背景下涉鸟故障目标的误检和漏检,提升了模型的检测能力。最终,融合所有模块的 BDEA-VFNet 相较基线模型 VFNet,精度 mAP 提升 5.20%,召回率 mAR 提升 2.57%,同时实现了 77.37%的参数量压缩和 83.19%的计算量削减,有效平衡了检测性能和计算效率。

为进一步研究 Depthwise Conv2d 中卷积核尺寸对特征提取能力的影响,在其余实验设置均保持不变的情况下,仅改变深度卷积模块卷积核的尺寸大小进行实验,结果如表 2 所示。7×7 的卷积核可扩大感受野,弥补大尺度缺陷信息;且大小与鸟类故障相匹配,可在不引入过多背景噪声的情况下提取涉鸟故障的空间位置关系,在保持模型基本不变的情况下取得最佳的检测效果。

表 2 卷积核尺寸对检测性能的影响

Table 2 Effect of kernel size on detection performance

卷积核大小	边缘填充	mAP/%	mAR/%	Params/M	FLOPs/G
3×3	1	64.4	73.2	7.312	27.435
5×5	2	63.1	71.5	7.347	27.640
7×7	3	74.9	79.7	7.400	27.948
9×9	4	61.5	69.0	7.471	28.357

此外,本文选取现有的主流二阶段检测算法 Faster R-CNN(faster region-based convolutional neural network)、Cascade R-CNN(cascade region-based convolutional neural network)、Double-Head R-CNN(double-head region-based convolutional neural network),一阶段检测算法 ATSS、

YOLOX(you only look once X)、TOOD(task-aligned one-stage object detection)、YOLOv8(you only look once version 8)与轻量级骨干网络 ShuffleNet V2、MobileNet V3、EfficientNet V2、EdgeNeXt 进行实验对比,并选取典型算法进行可视化,实验结果如表 3 与图 6 所示。对比算法包括二阶段算法及一阶段算法。此外,考虑边缘设备算力受限的特性,将多种主流轻量级骨干网络部署于同一 VFNet 基准框架下进行对比,在控制其他超参数一致的前提下,分析骨干网络对涉鸟故障检测性能的影响。

表 3 主流目标检测算法对比

Table 3 Comparison of object detection algorithms

	检测算法	mAP/%	mAR/%	Params/M	FLOPs/G
二阶段 算法	Faster RCNN	68.1	73.0	41.3	183.0
	Cascade RCNN	70.9	75.4	69.2	211.0
	Double-Head RCNN	70.0	75.1	46.9	457.0
一阶段 算法	ATSS	70.9	77.4	32.1	177.0
	YOLOX	57.3	64.9	8.9	31.6
	TOOD	70.6	77.0	32.0	173.0
	YOLOv8	70.6	75.8	11.1	33.9
轻量级 网络	Shufflenet V2	62.7	69.8	10.0	29.6
	MobileNet V3	68.0	74.5	6.3	19.2
	EfficientNet V2	71.1	77.4	16.1	44.3
	EdgeNeXt	72.7	78.5	8.6	52.6
本文 算法	BDEA-VFNet	74.9	79.7	7.4	27.9

由图 6 可知,Cascade R-CNN、YOLOv8 与 EdgeNeXt 等模型针对多目标、小目标等典型涉鸟故障场景中,均出现了一定程度的漏检与误检,且检测框贴合度低,受外界环境干扰较大;而本文所提 BDEA-VFNet 模型能实现较为理想的检测效果,更适合输电线路涉鸟故障检测任务。由表 3 可知,与主流一阶段和二阶段目标检测算法相比,BDEA-VFNet 在保持轻量级特性的前提下取得了最优精度。二阶段算法 Faster RCNN、Cascade RCNN、Double-Head RCNN 的 FLOPs 与 Params 均远超一阶段算法与本文算法,因过大的模型体量与过高的推理延迟无法满足无人机边端检测的要求。与一阶段算法相比,BDEA-VFNet 在模型复杂度更低的情况下,将检测精度 mAP 和召回率 mAR 较 YOLOv8 模型提高 4.3%和 3.9%。进一步地,在替换轻量级骨干网络的对比实验中,BDEA-VFNet 通过简化架构保持轻量化,在各轻量化网络中保持次优的 Params 和 FLOPs。MobileNet V3 的参数量和计算量虽然最少,但其过度简化的特征提取层难以捕捉到涉鸟故障的细粒度特征,导致检测精度 mAP 和召回率




图 6 不同算法的涉鸟故障检测结果可视化对比

Fig. 6 Visual comparison of bird-related fault detection results across different algorithms

mAR 比 BDEA-VFNet 低 9.21% 和 6.52%。主流边缘端算法 EdgeNeXt 的检测精度 mAP 和 mAR 在涉鸟故障检测中取得了次优的效果,但模型计算量接近本文算法的两倍。综合对比可知,BDEA-VFNet 以次低的 7.4 M 参数和 27.9 G 计算量取得了最高检测精度,兼顾性能与边缘轻量化部署需求。

为验证正负样本动态软标签分配策略的有效性,以 BDEA-VFNet 为基础,在相同的目标检测框架中改用其他常见的样本分配策略进行对比分析。改进模块和超参数情况等实验其余设置均保持一致,并将构建的所有模型在输电线路涉鸟故障数据集上评估和对比分析,图 6 展示了具体实验结果。其中,ATSS 为基线模型 VFNet 采用的方案,属于依靠 IoU 统计特征的目标分配方式;SimOTA、TaskAligned 和本文的动态软标签分配为基于几何位置的目标分配方式。

如图 7 所示,本文提出的动态软标签分配方法在 mAP 和 mAR 上均取得最优,分别达 74.9% 和 79.7%,相比 VFNet 原方案 ATSS 共提升 1% 的检测精度和 0.3% 的召回率。ATSS 过度依赖检测目标的 IoU,但在涉鸟故障中,鸟巢等物体的边缘相对不规则,且容易受

到图像环境中树枝等物体纹理的干扰,IoU 和其置信度往往偏低,故在对比实验中的检测精度最低。而 SimOTA 和 TaskAligned 虽引入全局优化和对齐度量的目标分配方法,在精度上有一定提升。但其受限于正负样本二值划分的硬标签分配,忽略了临界状态的样本,且在硬标签划分的过程中丢失了部分特征信息。




图 7 正负样本分配策略对比实验

Fig. 7 Comparison of label-assignment strategies

相比之下,本文采用的动态软标签策略通过 $[0,1]$ 区间内的连续软标签权重,赋值偏离中心,但特征匹配度高的边缘样本一定的正样本权重,使得模型够学习到鸟巢不规则边缘的细粒度特征,避免误分配和漏检的情况,更适用于输电线路涉鸟故障检测场景。

2.4 边端部署验证

在实际输电线路巡检场景中,通常会面临多目标和小目标巡检的场景。此外,无人机航拍图像常受到光照、角度和天气的影响,使输电线路巡检和涉鸟故障检测具有较高的多变性。为验证 BDEA-VFNet 在边缘侧实际应用中的有效性,本文将其部署到边缘计算设备 Jetson Xavier NX 上。通过 TensorRT 推理引擎进行模型量化、层间融合,并生成适配边端设备的 CUDA 优化方案进行部署与检测。图 8 展示了不同巡检场景下模型在 NX 上的实际检测结果。




图 8 涉鸟故障检测模型实际检测结果

3 结 论

本文提出了一种面向输电线路边缘端涉鸟故障的轻量级目标检测模型 BDEA-VFNet,通过在框架结构和训练策略上的多重优化,兼顾了检测精度与实时性,为提升输电线路巡检的智能化水平和运行效率提供了有力支撑。主要结论为:

1) 采用自监督预训练策略与全局响应归一化可提高涉鸟故障的特征表征能力。在此基础上简化模型结构、利用动态软分配策略能够学习到形态多变的不规则样本,可在提高检测精度的同时减少 77.37% 的参数量和 83.19% 的计算量。

2) BDEA-VFNet 模型相较于 VFNet 模型提升 5.20% 的检测精度和 2.57% 的召回率,更适配在边缘设备中进行部署,可实现对输电线路涉鸟故障的边端高效检测。

参考文献

- [1] 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.
LIU CH Y, WU Y Q. Research progress of vision detection methods based on deep learning for transmission lines[J]. Proceedings of the CSEE, 2023, 43(19): 7423-7446.
- [2] 赖东阳, 邱志斌, 杨泽鼎, 等. 基于 YOLOv9-SOEP 与双目立体视觉的输电线路山火火焰高度测量[J]. 电子测量与仪器学报, 2025, 39(8): 258-268.
LAI D Y, QIU ZH B, YANG Z D, et al. Flame height measurement of transmission lines wildfire based on YOLOv9-SOEP and binocular stereo vision[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(8): 258-268.
- [3] 苏怡萱, 李智, 盘书宝. 基于改进 YOLOv8 的输电线路绝缘子缺陷检测方法[J]. 电子测量与仪器学报, 2025, 39(1): 14-23.
SU Y X, LI ZH, PAN SH B. Improved YOLOv8-based insulator defect detection method for transmission lines[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(1): 14-23.
- [4] LIU X Y, MIAO X R, JIANG H, et al. Tower masking MIM: A self-supervised pretraining method for power line inspection[J]. IEEE Transactions on Industrial Informatics, 2024, 20(1): 513-523.
- [5] 刘敏, 陈明, 武明虎, 等. GAE-YOLO: 全局感知增强

由图 8 可知,无论是图 8(a)中的多目标巡检场景,还是图 8(b)中的小目标巡检场景下,基于 BDEA-VFNet 的边端涉鸟故障检测模型均能实现较为理想的检测效果。其中,标签 bird 代表模型所检测出的输电线路高危鸟种;标签 bird_nest 代表模型所检测出的输电线路鸟巢,检测框贴合度高且无漏检。同时,边端部署实验中还采用 TensorRT 技术,以加速实际边端部署的模型检测效率,在相同图像分辨率下,经 TensorRT 优化后部署在边端设备上的模型 mAP 与 mAR 分别达 74.7% 和 79.5%, FPS 由 Pytorch 框架下的 2.7 提高至 7.8,模型大小由 31 MB 降低为 21 MB。在精度保持不变的情况下,使现场推理速度提高约 188.89%,模型体积缩减 32.26%,更满足低延时、轻量化的实际需求。

- 的输电线路外破隐患目标检测方法[J]. 仪器仪表学报, 2025, 46(2): 267-278.
- LIU M, CHEN M, WU M H, et al. GAE-YOLO: Global awareness enhanced method for detecting external force damage in power transmission lines[J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 267-278.
- [6] 尚秋峰, 谷元宇, 樊小凯, 等. 基于LCPSO与异构集成学习模型的输电线路覆冰等级预警方法[J]. 仪器仪表学报, 2024, 45(9): 157-165.
- SHANG Q F, GU Y Y, FAN X K, et al. A transmission line icing level warning method based on LCPSO and heterogeneous ensemble learning model[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 157-165.
- [7] 吴洋铭, 洪翠, 高伟. 基于雷达点云与视觉图像融合的输电线路探鸟驱鸟技术[J]. 高电压技术, 2023, 49(8): 3446-3457.
- WU Y M, HONG C, GAO W. Bird detecting and bird repel-ing technology for transmission lines based on the fusion of radar point cloud and visual image[J]. High Voltage Engineering, 2023, 49(8): 3446-3457.
- [8] LIAO J W, XU H T, FANG X, et al. Quantitative assessment framework for non-structural bird's nest risk information of transmission tower in high-resolution UAV images[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-12.
- [9] 肖海, 毕瀚文, 董乃臻, 等. 架空线路鸟类活动分布式声学监测技术研究[J/OL]. 中国电机工程学报, 1-12[2025-10-10].
- XIAO H, BI H W, DONG N ZH, et al. Research on distributed acoustic monitoring technology of bird activity in overhead lines[J/OL]. Proceedings of the CSEE, 1-12[2025-10-10].
- [10] 王亚茹, 屈卓, 杨春旺, 等. 少样本跨域混合迁移输电线路绝缘子缺陷检测方法[J]. 仪器仪表学报, 2025, 46(8): 63-74.
- WANG Y R, QU ZH, YANG CH W, et al. Few-shot cross-domain hybrid transfer learning method for transmission[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 63-74.
- [11] 刘传洋, 吴一全, 刘景景. 基于视觉的输电线路金具锈蚀缺陷检测方法研究进展[J]. 仪器仪表学报, 2024, 45(3): 286-305.
- LIU CH Y, WU Y Q, LIU J J. Research progress of vision-based rust defect detection methods for metal fittings in transmission lines[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 286-305.
- [12] 刘志颖, 缪希仁, 陈静, 等. 电力架空线路巡检可见光图像智能处理研究综述[J]. 电网技术, 2020, 44(3): 1057-1069.
- LIU ZH Y, MIAO X R, CHEN J, et al. Review of visible image intelligent processing for transmission line inspection[J]. Power System Technology, 2020, 44(3): 1057-1069.
- [13] 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.
- ZHAO ZH B, JIANG ZH G, LI Y X, et al. Overview of visual defect detection of transmission line components[J]. Journal of Image and Graphics, 2021, 26(11): 2545-2560.
- [14] 刘航, 李明, 刘志坚, 等. 基于轻量化改进YOLOv8n绝缘子自爆缺陷检测方法[J]. 电子测量与仪器学报, 2025, 39(1): 57-69.
- LIU H, LI M, LIU ZH J, et al. Self-explosion defect detection method of insulator based on lightweight and improved YOLOv8n[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(1): 57-69.
- [15] 张吉祥, 方东. 基于YOLOv8-SPH的防震锤缺失检测[J]. 电子测量与仪器学报, 2025, 39(2): 251-261.
- ZHANG J X, FANG D. Detection of missing shockproof hammers based on YOLOv8-SPH[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(2): 251-261.
- [16] 陈哲煊, 高雪莲, 宋佳宇, 等. 融合双编码与元学习的小样本输电线路异物检测[J]. 仪器仪表学报, 2025, 46(3): 193-205.
- CHEN ZH X, GAO X L, SONG J Y, et al. Small sample foreign body detection in power lines based on double coding and meta-learning[J]. Chinese Journal of Scientific Instrument, 2025, 46(3): 193-205.
- [17] QIU ZH B, ZHU X, LIAO C B, et al. Detection of bird species related to transmission line faults based on lightweight convolutional neural network[J]. IET Generation, Transmission & Distribution, 2022, 16(5): 869-881.
- [18] 张烨, 高玉菡, 黄新波, 等. 基于Fine Mask RCNN的110~220 kV输电铁塔涉鸟故障识别与评估[J]. 电网技术, 2022, 46(6): 2132-2144.
- ZHANG Y, GAO Y H, HUANG X B, et al. Fault

- identification and evaluation of tower wading in 110 ~ 220 kV transmission line with Fine Mask RCNN[J]. Power System Technology, 2022, 46(6): 2132-2144.
- [19] 邱志斌, 石大寨, 况燕军, 等. 基于深度迁移学习的输电线路涉鸟故障危害鸟种图像识别[J]. 高电压技术, 2021, 47(11): 3785-3794.
- QIU ZH B, SHI D ZH, KUANG Y J, et al. Image recognition of harmful bird species related to transmission line outages based on deep transfer learning[J]. High Voltage Engineering, 2021, 47(11): 3785-3794.
- [20] FU J F, NUNEZ A, DE SCHUTTER B. Real-time UAV routing strategy for monitoring and inspection for postdisaster restoration of distribution networks[J]. IEEE Transactions on Industrial Informatics, 2022, 18(4): 2582-2592.
- [21] 江灏, 贺浩, 刘欣宇, 等. 基于多模态融合的输电线路鸟巢精细化检测方法[J]. 高电压技术, 2025, 51(11): 5435-5447.
- JIANG H, HE H, LIU X Y, et al. Fine-grained detection method for bird nest on transmission lines based on multimodal fusion[J]. High Voltage Engineering, 2025, 51(11): 5435-5447.
- [22] 仝杰, 齐子豪, 蒲天骄, 等. 电力物联网边缘智能: 概念、架构、技术及应用[J]. 中国电机工程学报, 2024, 44(14): 5473-5496.
- TONG J, QI Z H, PU T J, et al. Edge intelligence to power internet of things: Concept, architecture, technology and application[J]. Proceedings of the CSEE, 2024, 44(14): 5473-5496.
- [23] 董裕民, 张静, 谢昌佐, 等. 云边端架构下边缘智能计算关键问题综述: 计算优化与计算卸载[J]. 电子与信息学报, 2024, 46(3): 765-776.
- DONG Y M, ZHANG J, XIE CH Z, et al. A survey of key issues in edge intelligent computing under cloud-edge-terminal architecture: Computing optimization and computing offloading [J]. Journal of Electronics & Information Technology, 2024, 46(3): 765-776.
- [24] 吴启航, 丁晓喜, 何清波, 等. 齿轮箱故障边缘智能诊断方法及应用研究[J]. 仪器仪表学报, 2024, 45(1): 70-80.
- WU Q H, DING X X, HE Q B, et al. Edge intelligent fault diagnosis method in the application of gearbox[J]. Chinese Journal of Scientific Instrument, 2024, 45(1): 70-80.
- [25] 余涛, 梁敏航, 罗庆全, 等. 新型电力系统专用传感与边缘智能关键技术及其展望[J]. 高电压技术, 2024, 50(8): 3324-3338.
- YU T, LIANG M H, LUO Q Q, et al. Key technologies and perspectives of specialized sensing and edge intelligence for new power systems [J]. High Voltage Engineering, 2024, 50(8): 3324-3338.
- [26] 崔恒志, 蒋承伶, 缪巍巍, 等. 基于边缘计算的电力智慧物联系统设计与实现[J]. 电力信息与通信技术, 2020, 18(4): 33-41.
- CUI H ZH, JIANG CH L, MIAO W W, et al. Design and implementation of power intelligent IoT system based on edge com-puting[J]. Electric Power Information and Communication Technology, 2020, 18(4): 33-41.
- [27] HOU J X, GUO H, WANG SH W, et al. Design of a power transmission line monitoring system based upon edge computing and Zigbee wireless communication[J]. Mobile Information Systems, 2022, 2022(1): 9379789.
- [28] LIU M, LI Z, LI Y CH, et al. A fast and accurate method of power line intelligent inspection based on edge computing[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-12.
- [29] 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.
- ZHANG J, WANG J Y, SONG R, et al. Research on efficient detection technology of transmission line abnormal target based on edge intelligence[J]. Power System Technology, 2022, 46(5): 1652-1661.
- [30] 胡晨龙, 裴少通, 刘云鹏, 等. 基于 LEE-YOLOv7 的输电线路边缘端实时缺陷检测方法[J]. 高电压技术, 2024, 50(11): 5047-5057.
- HU CH L, PEI SH T, LIU Y P, et al. Real-time edge end defect detection method for transmission line based on LEE-YOLOv7[J]. High Voltage Engineering, 2024, 50(11): 5047-5057.
- [31] ZHANG H Y, WANG Y, DAYOUB F, et al. Varifocalnet: An IoU-aware dense object detector[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 8514-8523.
- [32] TIAN ZH, SHEN CH H, CHEN H, et al. Fcos: Fully convolutional one-stage object detection [C]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 9627-9636.
- [33] ZHANG SH F, CHI CH, YAO Y Q, et al. Bridging the gap between anchor-based and anchor-free detection via

adaptive training sample selec-tion[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 9759-9768.

[34] WOO S, DEBNATH S, HU R, et al. ConvNeXt V2: Co-designing and scaling ConvNets with masked autoencoders [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 16133-16142.

[35] WANG N, GAO Y, CHEN H, et al. NAS-FCOS: Fast neural architecture search for object detection[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11943-11951.

[36] LYU CH Q, ZHANG W W, HUANG H AN, et al. RTMDet: An empirical study of designing real-time object detectors[J]. ArXiv preprint arXiv:2212.07784, 2022.

作者简介



缪希仁,1986 年于北京航空航天大学获得学士学位,1989 年和 2000 年于福州大学获得硕士学位与博士学位,现为福州大学、福建理工大学电气学院教授,主要研究方向为电器及其系统智能化技术、电气设备在线监测与诊断。

E-mail:miaoxr@163.com

Miao Xiren received his B.Sc. degree from Beihang University in 1986, his M.Sc. and Ph.D. degrees both from Fuzhou University in 1989 and 2000, respectively. He is currently a professor in the College of Electrical Engineering at Fuzhou University and Fujian University of Technology. His main research interests include intelligent technologies for electrical apparatus and systems, and online monitoring and diagnosis of electrical equipment.



刘欣宇(通信作者),2016 年、2019 年和 2024 年于福州大学获得学士、硕士与博士学位,现为福州大学电气工程与自动化学院讲师,主要研究方向为人工智能和输电线路无人机巡检。

E-mail:Xinyu_Liu@fzu.edu.cn

Liu Xinyu (Corresponding author) received his B.Sc. , M.Sc. , and Ph.D. degrees all from Fuzhou University in 2016, 2019, and 2024, respectively. He is currently a lecturer in the College of Electrical Engineering and Automation at Fuzhou University. His main research interests include artificial intelligence and UAV inspection of transmission lines.