

基于改进YOLOv7的输电线路外破隐患检测算法

孟军英^{1,2}, 杨佳莉¹, 王建超¹, 赵晓东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 300401)

摘要: 针对现有输电线路外破隐患检测模型存在的检测精度、实时性较差等问题, 提出一种基于YOLOv7的输电线路外破隐患目标检测算法。首先, 使用特征提取网络UniRepLKNet模块替换Backbone的E-ELAN模块, 增大感受野、实现模型轻量化; 其次, 在Backbone后增加多尺度轴向注意力机制(MCA), 使改进后的模型能全局识别目标区域的模糊边界; 最后, 结合归一化损失函数(NWD)与CIoU作为定位回归损失函数, 在不下降中大型目标检测精度的同时提升小目标检测精度。实验表明, 所提方法在输电线路外破隐患目标识别中的物体总类别平均检测精度为94%, 相较于YOLOv7算法提升3.2%, 模型参数量、大小分别减少15.8%、15.4%, 有利于部署到输电线路系统中。

关键词: 目标检测; 输电线路; YOLOv7; 轻量化

DOI: 10.11907/rjtk.241800

扫描二维码阅读全文: 

中图分类号: TP391.4

文献标识码: A

文章编号: 1672-7800(2026)001-0142-07

Detection Algorithm for External Hidden Dangers of Transmission Lines Based on Improved YOLOv7

MENG Junying^{1,2}, YANG Jiali¹, WANG Jianchao¹, ZHAO Xiaodong¹, SU He³

(1. College 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. College of Electrical Engineering, Hebei University of Technology, Tianjin 300401, China)

Abstract: Aiming at the problems of poor detection accuracy and real-time performance of existing detection models for external damage hazards of transmission lines, a YOLOv7 based target detection algorithm for external damage hazards of transmission lines is proposed. Firstly, replace Backbone's E-ELAN module with the UniRepLKNet feature extraction network module to increase the receptive field and achieve model lightweighting; Secondly, a multi-scale axial attention mechanism (MCA) is added after Backbone to enable the improved model to globally recognize the fuzzy boundaries of the target area; Finally, by combining the Normalized Loss Function (NWD) and CIoU as the localization regression loss function, the detection accuracy of small targets can be improved without compromising the detection accuracy of medium and large targets. The experiment shows that the proposed method has an average detection accuracy of 94% for the total category of objects in the recognition of hidden dangers outside transmission lines, which is 3.2% higher than the YOLOv7 algorithm. The model parameter quantity and size are reduced by 15.8% and 15.4% respectively, which is conducive to deployment in transmission line systems.

Key Words: target detection; transmission line; YOLOv7; lightweight

收稿日期: 2024-09-14

基金项目: 河北省教育厅青年基金项目(QN2023185)

作者简介: 孟军英(1974-), 男, 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, 研究方向为人工智能、模式识别; 杨佳莉(1999-), 女, 河北科技大学信息科学与工程学院硕士研究生, 研究方向为智能检测、自动目标识别; 王建超(1990-), 男, 河北科技大学信息科学与工程学院讲师, 研究方向为智能信息处理; 赵晓东(1973-), 男, 博士, 河北科技大学信息科学与工程学院研究员、硕士生导师, 研究方向为人工智能、网络安全; 苏鹤(1994-), 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: 王建超。

0 引言

输电线路是电力系统的重要组成部分,关系到电力系统的安全与稳定。据国家电力企业联合会统计,国家输电线路回路总长为 215×10^4 km,多数高压输电线路因输送距离长、与主干道路距离远,通常会面临因塔吊、吊车、挖掘机等大型施工机械造成的人为外力破坏问题^[1]。由吊车、挖掘机等大型机械在线路附近施工所导致的线路损坏或故障,属于机械外破。数据表明,机械外破占总外破的半数以上,已成为输电线路安全的重大隐患,给输电线路运行造成了极大影响^[2]。

为此,如何实时监控机械外破,预警外力破坏行为的发生就显得尤为重要。传统输电线路监测系统将视频、图像数据传回监控平台,通过人工筛选的方式识别施工机械等外破隐患发生,存在工作效率低、无法实时识别并预警的问题^[3]。随着卷积神经网络算法在图像识别中的应用越来越广泛,基于深度学习的图像识别技术为输电线路机械外破智能巡检提供了新思路 and 解决办法^[4-9]。魏业文等^[10]将改进的 Faster-RCNN 算法应用到输电线路巡检图像识别中,提升了目标检测速度和精度,但面对对比度低的目标时检测精度仍然较低。闫春江等^[11]针对输电线路周边工程机械外力入侵的自动检测问题,提出一种基于 VGGNet-16 的工程车辆入侵检测方法,能准确检测输电线路周边的工程车辆入侵,但模型计算时间有所增加。欧进永等^[12]为快速、准确地检测输电线路杆塔中的鸟窝,提出一种基于 RetinaNet 深度学习模型的鸟窝识别方法,检测效果优秀,但检测速度较慢。周鹏杰等^[13]针对基于深度学习的输电线路外力隐患检测模型无法满足边缘部署实时性需求的问题,提出一种轻量化 YOLOv4 的输电线路防外力隐患检测方法,提升了运算速度、检测精度,但在检测尺寸变化较大的微小目标时仍存在错检。Li 等^[14]提出一种基于 YOLOv5s 的轻量化模型以检测起重机、塔式起重机、工程机械、烟雾、火焰和异物,检测精度较高,但在检测复杂环境下受遮挡的目标时效果还有待提升。

综上,输电线路外破隐患目标检测算法在提升模型识别准确率、检测效率方面都取得了一定的成果,但面对相互遮挡和尺寸变化大的微小目标时仍存在漏检、错检等问题,且难以满足输电线路系统的实时性要求。为此,本文选择检测速度较快、准确率较高、易于实现和部署的 YOLOv7 算法,并通过添加注意力机制、大核卷积轻量化、损失函数优化等方面进行改进。主要工作为:①使用特征提取网络 UniRepLKNetBlock 替换骨干网络中的 E-ELAN 模块,以增大感受野、提取更复杂的空间模式,在轻量化模型的同时还能进一步增加深度以增强表示能力;②在骨干网络中增加多尺度交叉轴注意力机制(Multiscale Cross-axis Attention Mechanism, MCA),更好地利用多尺度特征捕获

全局信息,使改进后的模型能全局识别目标区域的模糊边界;③结合 CIoU 与归一化 Wasserstein 距离(Normalized Wasserstein Distance, NWD)作为定位回归损失函数,加快网络模型收敛速度,提升外破隐患小目标的检测能力;④通过人工标注方式,对不同背景下含有塔吊、吊车、挖掘机目标的图片进行标注,通过旋转、平移、镜像、亮度调整、添加噪声等数据增强方法扩充数据集。

1 YOLOv7 算法原理

目前,流行的 YOLOv7 算法是单阶段检测网络模型,相较于 YOLO 在整个预测框架中并未进行非常大的革新,网络模型如图 1 所示。由此可见,模型由输入端 Input、主干网络 Backbone、头部网络 Head 构成,通过扩展高效聚合网络 E-ELAN 结构、基于级联模型的模型缩放模块和模型重参数化模块,实现检测效率与精度间的良好平衡^[15-17]。




Fig. 1 YOLOv7 network structure

图1 YOLOv7网络结构

在预处理阶段,采用自适应锚框计算方法对输入图片进行不失真的缩放,将输入的 RGB 彩色图像统一缩放为 640×640 ,以满足骨干网络对输入尺寸的要求。Backbone 部分主要包括 CBS 模块、扩展高效聚合网络 E-ELAN 结构和多路径卷积 MP 模块,以提取输入对象的特征信息。其中, CBS 模块由卷积、批量归一化和 SiLU 激活函数组成; E-ELAN 模块通过融合不同特征,学习更多样化的特征来增强网络学习能力,还保留了原有的梯度路径; MP 模块由 CBS、MaxPool 组成。

为了在头部网络中加强外破隐患目标特征的提取能力,采用 PANet 设计的路径聚合特征金字塔网络 PAFPN 架构,进行多尺度的特征融合,实现分辨率、高语义信息的融合。Head 部分主要包括:具有上下文空间金字塔卷积的空间金字塔池化 SPPCSPC、扩展高效层聚合网络 ELAN-H、多路径卷积 MP 和特殊残差结构 RepConv。其中,通过 SP-

PCSPC 结构扩大感受野,加强特征提取能力;通过 ELAN-H 层、UP 结构进行多个特征层融合和上采样,传递高层强语义特征,加强特征提取能力;通过 ELAN-H 层、MP 结构进行下采样,传递低层细节特征;预测端是分类器与回归器,通过特殊残差结构 RepConv 辅助训练,在训练时使用残差结构进行优化,预测时将残差结构简化为简单的卷积,以降低网络训练复杂度,实现目标多尺度检测。

2 YOLOv7 网络结构改进

本文针对 YOLOv7 无法很好地克服小目标和复杂背景这两个难点,在原始 YOLOv7 算法的基础上添加注意力机制、大核卷积轻量化、损失函数优化等方法进行改进。首先,在骨干网络中引入大核卷积神经网络 UniRepLKNet 替换 E-ELAN 模块,实现模型轻量化,增大感受野来提取更复杂的空间模式,从而增加模型深度和表示能力^[18];其次,在骨干网络后添加 MCA 注意力机制,以更好地利用多尺度特征捕获全局信息,使改进后的模型能全局识别目标区域的模糊边界^[19];最后,添加 NWD 损失函数,利用高斯分布计算两个目标之间的相似度,并结合 Ciou 与 NWD 作为定位回归损失函数,加快网络收敛速度,提升模型对外破隐患小目标的检测能力^[20]。图 2 为引入大核卷积神经网络 UniRepLKNet 与 MCA 的 YOLOv7 模型具体结构。

2.1 MCA

MCA 是多尺度跨轴注意力,可捕捉长程依赖关系、编码多尺度信息,还不会引入过多的计算复杂度。具体地, MCA 在轴向注意力计算中引入了多尺度特征,还在每个轴向注意力路径中使用多个具有不同内核大小的条形卷积,




Fig. 2 Structure after introducing UniRepLKNet and MCA

图 2 引入 UniRepLKNet 与 MCA 后的结构

以更好地定位目标区域,提升了编码空间信息的效率、检测尺寸变化大的小目标的精度。同时, MCA 基于高效轴向注意力,并未沿着水平、垂直维度依次连接轴向注意力,而是在两个空间轴向注意力之间建立双重交叉注意力,以建立两个空间轴向注意力之间的交互,从而更好地利用多尺度特征捕获全局信息,使改进后的模型能全局识别目标区域的模糊边界。

MCA 解码器包含两个并行路径,每个路径通过多尺度卷积与交叉轴迭代来聚合空间信息,且在解码器中无需添加任何激活函数,具体结构如图 3 所示。




Fig. 3 MCA structure

图 3 MCA 结构

首先,给定形状为 $H \times W \times C$ 的特征图 F , 其中 $H = \frac{\hat{H}}{4}$ 、 $W = \frac{\hat{W}}{4}$, 即编码器最后 3 个阶段的特征图使用 3 个并行的一维卷积来编码 F , 并将输出通过求和融合发送到 1×1 卷积中。

$$F_x = \text{Conv}_{1 \times 1} \left(\sum_{i=0}^2 \text{Conv1D}_i^x(\text{Norm}(F)) \right) \quad (1)$$

式中: $\text{Conv1D}_i^x()$ 表示沿 x 轴维度的一维卷积; $\text{Norm}()$ 为层归一化; F_x 为输出。

其次,按照 SegNeXt 将一维卷积的核大小分别设置为

1×7、1×11 和 1×21, 通过式(2)计算底部分支的输出 F_y 。

$$F_y = \text{Conv}_{1 \times 1} \left(\sum_{i=0}^2 \text{Conv1D}_i(\text{Norm}(F)) \right) \quad (2)$$

再次, 将定顶部分支中的 F_x 传递到 y 轴的注意力中, 通过计算 F_x 、 F_y 之间的交叉注意, 更好地利用两个空间方向的多尺度卷积特征; 对于底部分支, 使用类似的方式沿着 y 轴方向对上下文进行编码, 如式(4)所示。

$$F_T = \text{MHCA}_y(F_y, F_x, F_x) \quad (3)$$

$$F_B = \text{MHCA}_x(F_x, F_y, F_y) \quad (4)$$

式中: $\text{MHCA}_x(\cdot, \cdot, \cdot)$ 表示沿 y 轴的多头交叉注意力; $\text{MHCA}_y(\cdot, \cdot, \cdot)$ 表示沿 x 轴的多头交叉注意力。

最后, 给定 F_T 、 F_B , 即多尺度跨轴注意力的输出公式如式(5)所示。

$$F_{\text{out}} = \text{Conv}_{1 \times 1}(F_T) + \text{Conv}_{1 \times 1}(F_B) + F \quad (5)$$

2.2 UniRepLKNet 大核卷积神经网络

UniRepLKNet 网络结构的重点在于使用 Dilated Reparam Block 与大核指导原则。首先, 使用高效的结构进行通道通讯和空间聚合, 以增加模型深度; 其次, 使用扩张重参数块对大卷积核卷积层进行重新参数化, 在不增加推理成本的基础上提升模型性能; 再次, 根据下游任务决定卷积核大小, 仅在中高层使用大卷积核; 最后, 在扩展模型深度时, 使用 3×3 卷积层而非更多的大卷积核层。

根据这些准则构建的卷积网络具有以下 3 点优势: ①适量的大卷积核能保证大且有效的感受野; ②小卷积核能更高效地提取更复杂的空间模式; ③多个轻量级块能进一步增加深度以增强表示能力。UniRepLKNet 模型结构如图 4 所示。




Fig. 4 UniRepLKNet model structure

图 4 UniRepLKNet 模型结构

2.3 优化损失函数

YOLOv7 采用 CIoU 作为回归损失函数, 以衡量预测框与真实框之间的位置偏差, 从而计算边界框的回归损失,

具体计算公式如式(6)一式(8)所示。

$$L_{\text{CIoU}} = 1 - I_{\text{IoU}} + \frac{\rho^2(b, b_{\text{gt}})}{c^2} + \alpha \nu \quad (6)$$

$$\nu = \frac{4}{\pi^2} \left(\arctan \frac{w_{\text{gt}}}{h_{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (7)$$

$$\alpha = \frac{\nu}{(1 - I_{\text{IoU}}) + \nu} \quad (8)$$

式中: I_{IoU} 表示预测框与真实框的交并比; b 表示预测框; b_{gt} 表示真实框; c 表示预测框与真实框最小外接矩形的对角线距离; α 为权重系数; ν 用来度量长宽比的相似性, w_{gt} 表示真实框中心位置的宽; h_{gt} 表示真实框中心位置的高; w 表示预测框中心位置的宽; h 表示预测框中心位置的高。

CIoU 是一种基于 IoU (Intersection over Union) 的度量方法, 表示预测框与真实框之间的重叠程度。IoU 及其扩展对微小物体的位置偏差十分敏感, 使模型在反向传播过程中更新参数的能力较差, 因此无法适用于检测输电线路外破隐患中的小目标。

为此, 本文引入对不同尺度之间目标不敏感的 NWD 位置回归损失函数, 通过二维高斯分布来度量预测框与真实框之间的相似性。具体地, 将边界框建模为二维高斯分布, 以更好地区分前景像素与背景像素。由于前景像素外破隐患目标主要集中在边界框的中心位置, 因此对边界框中心的外破隐患目标像素赋予最高权重, 权重值从中心到边界依次递减。

对于水平边界框 $R = (cx, cy, w, h)$, (cx, cy) 表示中心点坐标, w 、 h 分别表示边界框的宽和高, 其二维高斯分布 $N(\mu, \Sigma)$ 的计算公式如式(9)、式(10)所示。

$$\mu = \begin{bmatrix} c_x \\ c_y \end{bmatrix} \quad (9)$$

$$\Sigma = \begin{bmatrix} \frac{w^2}{4} & 0 \\ 0 & \frac{h^2}{4} \end{bmatrix} \quad (10)$$

考虑到真实框与预测框没有重叠或重叠区域非常小时, Wasserstein 距离仍能表示真实框与预测框的相似程度。本文通过 Wasserstein 距离计算 $R_a = (cx_a, cy_a, w_a, h_a)$ 与 $R_b = (cx_b, cy_b, w_b, h_b)$ 间的高斯分布距离。

$$W_2^2(N_a, N_b) =$$

$$\left\| \left[\begin{bmatrix} cx_a, cy_a, \frac{w_a}{2}, \frac{h_a}{2} \end{bmatrix}^T, \begin{bmatrix} cx_b, cy_b, \frac{w_b}{2}, \frac{h_b}{2} \end{bmatrix}^T \right] \right\|_2^2 \quad (11)$$

式中: $W_2^2(N_a, N_b)$ 为预测框与真实框的高斯分布距离; (cx_a, cy_a) 为预测框中心点坐标; w_a 、 h_a 分别为预测框的宽和高; (cx_b, cy_b) 为真实框中心点坐标; w_b 、 h_b 分别为真实框的宽和高。

同时, 对高斯分布距离进行指数形式归一化。

$$N_{NWD}(N_a, N_b) = \exp\left(-\frac{\sqrt{W_2^2(N_a, N_b)}}{C}\right) \quad (12)$$

式中: C 为常数, 是数据集中的类别数。

由于 CIoU 更适合检测中大型目标, 而 NWD 在小目标检测中的尺度、定位及目标相似性方面均优先于 IoU。为此, 本文结合 CIoU 与 NWD 来计算边界框的回归损失, 如式(13)所示。

$$Loss = \beta CIoU + (1 - \beta) \cdot NWD \quad (13)$$

式中: $Loss$ 为位置回归损失函数; β 表示 CIoU 的权重。

3 实验结果与分析

3.1 实验数据集

本文数据集是自制的输电线路隐患数据集 DTLHD (Dataset of Transmission Lines Hidden Dangers), 包括吊车 (crane)、塔吊 (tadio)、挖掘机 (excavator) 等 3 种类别的输电线路外破隐患来源。首先, 通过人工标注的方式, 利用 Labelimg 对不同背景下含有塔吊、吊车、挖掘机的图片进行标注, 得到 1 550 张图片; 其次, 将所得 .xml 格式的文件转换为适用于 YOLOv7 算法的 .txt 文件; 最后, 通过旋转、平移、镜像、亮度调整、添加噪声等方法, 将数据扩充到 3 100 张, 按照 8:1:1 的比例将数据集划分为训练集、验证集和测试集, 最终得到训练数据集 2 480 张, 验证数据集 310 张, 测试数据集 310 张。

3.2 实验环境

本文实验的操作系统为 Linux, GPU 采用 GeForce RTX 3090 Ti 的 24 GB, CPU 为 128 核的 AMD EPYC 9754, 系统平台为 Ubuntu 20.04, CUDA 版本为 11.3, Pytorch 版本为 1.11.0, 编程语言为 Python 3.8。

3.3 模型训练

首先, 设置模型训练总迭代次数为 Epoch=300, 批次大小为 Batch-size=8, 统一图片尺寸设置为 640×640, 优化器选择 SGD, 初始学习率 lr=0.01; 其次, 采用余弦退火方式平滑地降低学习率, 既能避免学习率突然变化对模型训练造成影响, 防止模型陷入局部最优解, 还有助于提升模型收敛速度、稳定性和泛化能力; 最后, 设置动量因子 momentum=0.937, 权重衰减参数 weight_decay=0.000 5。

图 5 为训练中的损失变化情况。其中, Box 为边界框损失, 以衡量预测边界框与真实边界框之间的差异; Objectness 为目标存在损失, 以衡量模型预测的目标是否存在; Classification 为分类损失, 以衡量模型分类物体的准确性。

3.4 评估指标

本文采用精确率 P (Precision)、召回率 R (Recall)、0.5 交并比 (IOU) 阈值下的平均准确率 AP (Average Precision)、平均准确率均值 mAP (mean Average Precision)、模型体积




Fig. 5 Loss variation process

图 5 损失变化过程

(Model Size) 和参数量 (Parameters) 来评价模型性能。其中, 平均准确率 AP 为模型预测某类别的准确率均值; 模型体积表示模型训练完成后保存的权重文件大小; 模型参数量表示训练过程中参数量的总和。

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

$$AP = \int_0^1 P(R) dR \quad (16)$$

$$mAP = \frac{\sum_{i=0}^N AP(i)}{N} \quad (17)$$

式中: TP 为正类预测为正类的数量; FP 为负类预测为正类的数量; FN 正类预测为负类的数量; N 为检测的类别数。

图 6 为模型训练指标。其中, 横轴表示训练轮数; 精确率为模型将某类别判定为正例的样本中, 真正为正例的样本比例; 召回率为模型将某类别所有真正为正例的样本中, 正确判定为正例的比例; mAP 为所有的单类别的 AP 求和与类别数的比值。由此可见, 迭代 200 轮次后模型训练效果较好, 整个类别的平均精度逐渐平稳地接近 1。




Fig. 6 Visualized training result

图 6 可视化训练结果

3.5 消融实验结果

为了验证 MCA 的优势, 在 YOLOv7 的基础上分别加入 CBAM、ECA、LSKA、MCA 等注意力机制进行比较, 实验结果如表 1 所示。由此可知, MCA 相较于 CBAM、LSKA 而言, 召回率、模型大小、参数量均有所降低, mAP、精确率分别提升 0.3%、0.4% 和 2.9%、1.1%; MCA 相较于 ECA 而言, 模型大小、参数量略微增加, mAP、精确率分别提升 0.4%、2.2%。在综合考虑模型复杂度和检测精度的情况下, 加入 MCA 后的模型性能最优、检测精度最高, 更适合检测输电

线路的外破隐患。

Table 1 Comparison results of attention mechanisms

表 1 注意力机制比较结果

Network	模型大小/MB	参数量	P	R	mAP@0.5
—	71.3	36 492 560	0.941	0.833	0.908
CBAM	77.3	39 641 654	0.929	0.864	0.922
ECA	71.3	36 492 561	0.936	0.850	0.921
LSKA	77.4	39 690 512	0.944	0.852	0.914
MCA	73.5	37 630 232	0.958	0.850	0.925

为了全面分析各改进模块对输电线路外破隐患目标检测的积极作用,在相同的实验环境下设计了消融实验,以比较 YOLOv7 算法与算法 1、算法 2、算法 3 和本文算法的性能,实验结果如表 2 所示。由此可知,将 MCA 添加在骨干网络后,能增强算法检测外破隐患目标的能力,虽然模型大小、参数量分别增加 2.2 MB、 $1.137\,672\times 10^6$,但 mAP@0.5 值相较于 YOLOv7 提升 1.7%;在骨干网络中嵌入 MCA,可更好地利用多尺度特征捕获全局信息,改进后的模型能全局识别目标区域的模糊边界,更好地定位目标区域,提升了编码空间信息效率和对于小目标的检测精度。

Table 2 Results of ablation experiment

表 2 消融实验结果

算法	MCA	UniRe- pLKNet	NWD	模型 大小/MB	参数量	P	R	mAP@ 0.5
YOLOv7				71.3	36 492 560	0.941	0.833	0.908
算法 1	√			73.5	37 630 232	0.958	0.85	0.925
算法 2		√		59.7	30 437 136	0.954	0.859	0.922
算法 3			√	71.3	36 492 560	0.96	0.856	0.914
本文算法	√	√	√	60.3	30 743 832	0.944	0.891	0.94

虽然,在骨干网络中嵌入 MCA(算法 1)会增加模型大小、参数量,但能捕捉长程依赖关系、编码多尺度信息,提升模型检测精度,不会增加过多的计算复杂度。将骨干网络中的 E-ELAN 模块替换为特征提取网络 UniRepLKNet 模块后(算法 2),模型大小、参数量分别降低 11.6 MB、 $6.055\,424\times 10^6$,mAP@0.5 相较于 YOLOv7 提升 1.4%。实验表明,大卷积核能保证大的有效感受野,可提升模型检测数据集中较大目标的能力;小卷积核可使模型更高效地提取更复杂的空间模式;多个轻量级块可进一步增加模型深度、表示能力和检测精度,极大程度地降低了模型训练参数量。

随后,结合 CIoU 与 NWD 作为定位回归损失函数后(算法 3),模型大小、参数量不变,相较于 YOLOv7 而言,mAP@0.5、精确率、召回率分别提升 0.6%、1.9%、2.3%。由此可知,添加 NWD 后的损失函数检测精度更高,能在极大程度上改善微小目标的漏检、误检问题。

此外,本文模型的性能提升最为显著,相较于原 YO-

LOv7 而言,模型大小、参数量分别减少 11 MB、 $5.748\,728\times 10^6$,mAP@0.5 提升 3.2%,证明了该算法能有效改善像素占比低的微小目标漏检、误检问题,对 3 类检测目标的检测效果优秀,平均精度值提升 3.2%。

表 3 为改进前后 YOLOv7 算法在 3 类输电线路外破隐患上的 AP 值与所有类别的 mAP 值。由此可知,改进后模型的 mAP@0.5、mAP@0.5:0.95 相较于改进前分别提升 3.2%、2.1%,3 种输电线路外破隐患的 AP 值均有不同程度地提升。其中,挖掘机类提升最高,达到 4.4%、3.1%;吊车提升 3.6%、1.7%;塔吊提升 1.6%、1.6%。

Table 3 Comparison of various hidden danger detection results

表 3 各类隐患检测结果比较

类目	mAP@0.5		mAP@0.5:0.95	
	原始	改进后	原始	改进后
吊车	0.912	0.948	0.676	0.693
塔吊	0.949	0.965	0.748	0.764
挖掘机	0.863	0.907	0.549	0.580
all	0.908	0.940	0.658	0.679

综上,改进后的模型定位、识别输电线路外破隐患目标更准确,提升了模型对数据集中较大目标的检测能力,改善了微小目标的漏检、误检问题,验证了所提算法对输电线路外破隐患目标识别的有效性。

为了更充分地证明本文模型的有效性,选取测试集中 4 种不同场景的图片进行目标检测,以直观比较 YOLOv7 改进前后模型的检测效果,如图 7 所示。




Fig. 7 Experimental testing results display

图 7 实验检测结果展示

3.6 比较实验

为了进一步验证算法性能,采用自建的输电线路外破隐患数据集,设置相同的实验参数、硬件和软件环境,将改进后的 YOLOv7 算法与单阶段目标检测算法 SSD、主流两阶段检测算法 Faster R-CNN 和 YOLOv5 算法进行比较,实验结果如表 4 所示。由此可知,在相同的硬件平台下,本文模型的 mAP 值为 94%,优于其他 5 种算法;在模型内存占比方面,改进的 YOLOv7 网络模型大小仅为 60.3 MB。

综上,本文模型在模型大小、检测精度上均优于 SSD、Faster R-CNN 算法,可满足输电线路外破隐患检测轻量化要求,网络检测精度也得到了有效保障。

Table 4 Experimental results of each model

表4 各模型实验结果

算法	模型大小/MB	mAP@0.5
Faster R-CNN	108.00	0.842
SSD	91.60	0.847
YOLOv5	13.70	0.903
YOLOv8	5.97	0.914
YOLOv7	71.30	0.908
改进后的YOLOv7	60.30	0.940

4 结语

本文在原始YOLOv7算法的基础上,从大核卷积轻量化、添加注意力机制、损失函数优化等方面进行改进,提出一种基于YOLOv7的输电线路外破隐患目标检测算法。实验表明,改进后的模型在实现轻量化的同时,有效解决了小目标漏检、误检问题,降低了模型大小、参数量,提升了检测精度,更易于部署。

相较于原始的YOLOv7而言,改进后的YOLOv7算法能较好地满足实际输电线路检测的需求,可直接检测输电线路外破隐患,促进了输电线路沿途隐患检测的智能化发展。后续,将通过数据增强技术扩增数据集,提升数据多样性,使模型在恶劣的天气环境时也能稳定运行,为解决输电线路中的复杂任务提供有效的技术支撑。

参考文献:

- [1] HAO R, WANG H J, LI T R. Deep neural network for defect detection in transmission lines based on dual branch serial mixed attention model[J]. Computer Science, 2024, 51(3): 135-140.
郝然,王红军,李天瑞.基于双分支串行混合注意力的输电线路缺陷检测深度神经网络模型[J].计算机科学,2024,51(3):135-140.
- [2] YANG J F, QIN Z, PANG X L, et al. A method for monitoring and identifying foreign object intrusion in transmission lines based on deep learning networks[J]. Power System Protection and Control, 2021, 49(4): 37-44.
杨剑锋,秦钟,庞小龙,等.基于深度学习网络的输电线路异物入侵监测和识别方法[J].电力系统保护与控制,2021,49(4):37-44.
- [3] TIAN E S, LI C L, ZHU G D, et al. Identification algorithm for external damage hazards of transmission lines based on YOLOv4[J]. Computer Systems & Applications, 2021, 30(7): 190-196.
田二胜,李春蕾,朱国栋,等.基于YOLOv4的输电线路外破隐患识别算法[J].计算机系统应用,2021,30(7):190-196.
- [4] GIRSHICK R. Faster R-CNN[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2015: 1440-1448.
- [5] 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 & Machine Intelligence, 2017, 39(6): 1137-1149.
- [6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[DB/OL]. <https://arxiv.org/abs/1512.02325>.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [8] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2017: 6517-6525.
- [9] HUANG J T, GAO H L, DAI Z K. A semantic segmentation method for mobile power lines based on encoding and decoding structure[J]. Journal of Computer Applications, 2021, 41(10): 2952-2958.
黄巨挺,高宏力,戴志坤.基于编码解码结构的移动端电力线语义分割方法[J].计算机应用,2021,41(10):2952-2958.
- [10] WEI Y W, LI M, XIE Y L, et al. Transmission line inspection image detection based on improved Faster-RCNN[J]. Electric Power Engineering Technology, 2022, 41(2): 171-178.
魏业文,李梅,解国琳,等.基于改进Faster-RCNN的输电线路巡检图像检测[J].电力工程技术,2022,41(2):171-178.
- [11] YAN C J, WANG C, FANG H L, et al. Intrusion detection of transmission line engineering vehicles based on deep learning[J]. Information Technology, 2018, 42(7): 28-33, 38.
闫春江,王闯,方华林,等.基于深度学习的输电线路工程车辆入侵检测[J].信息技术,2018,42(7):28-33,38.
- [12] OU J Y, YANG Y, SHI L, et al. Research on deep learning based bird nest recognition method for transmission line tower[J]. Mechanical and Electrical Information, 2020(24): 22-23.
欧进永,杨渊,时磊,等.基于深度学习的输电线路铁塔鸟窝识别方法研究[J].机电信息,2020(24):22-23.
- [13] ZHOU P J, ZHAO Z Y, YUAN B, et al. A lightweight YOLOv4 transmission line anti external force hidden danger detection method[J]. Electric Engineering, 2023(23): 94-97, 101.
周鹏杰,赵泽宇,袁斌,等.一种轻量化YOLOv4输电线路防外力隐患检测方法[J].电工技术,2023(23):94-97,101.
- [14] LI H, JIANG F, GUO F, et al. A real-time detection method of safety hazards in transmission lines based on YOLOv5s[C]// International Conference on Artificial Intelligence and Intelligent Information Processing, 2022: 283-287.
- [15] NI C S, LI L, LUO W T, et al. Disease detection of asphalt pavement based on improved YOLOv7[J]. Computer Engineering and Applications, 2023, 59(13): 305-316.
倪昌双,李林,罗文婷,等.改进YOLOv7的沥青路面病害检测[J].计算机工程与应用,2023,59(13):305-316.
- [16] WANG C Y, ALEXEY B, MARK L H Y. Scaled-YOLOv4: scaling cross stage partial network[DB/OL]. <https://arxiv.org/abs/2011.08036>.
- [17] DING X H, ZHANG X Y, MA N N, et al. RepVGG: making VGG-style ConvNets great again[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13728-13737.
- [18] DING X H, ZHANG Y Y, GE Y X, et al. UniRepLKNet: a universal perception large-kernel convnet for audio, video, point cloud, time-series and image recognition[DB/OL]. <https://arxiv.org/abs/2311.15599>.
- [19] SHAO H, ZENG Q S, HOU Q B. MCANet: medical image segmentation with multi-scale cross-axis attention [DB/OL]. <https://arxiv.org/html/2312.08866v2>.
- [20] WANG J W, XU C, YANG W, et al. A normalized gaussian Wasserstein distance for tiny object detection [DB/OL]. <https://arxiv.org/abs/2110.13389>.

(责任编辑:刘嘉文)