

基于 EDR-YOLOv7 的架空输电线路无人机巡检 边缘端目标检测方法

赵文俊^{1,2}, 刘凯³, 许国伟⁴, 吴田^{1,2}, 方春华^{1,2}, 普子恒^{1,2}

(1. 湖北省输电线路工程技术研究中心(三峡大学), 湖北 宜昌 443002; 2. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 3. 中国电力科学研究院有限公司电网环境保护国家重点实验室, 武汉 430072; 4. 广东电网有限责任公司汕头供电局, 广东 汕头 515000)

摘要: 在无人机电力巡检的航拍视角下, 考虑到电力设备图像特征的特殊性, 针对普遍存在的小目标检测、目标点遮挡和航拍图像尺度多变引起模型漏检率上升, 以及稠密检测带来计算量增加的问题, 提出了一种适用于无人机边缘端的视觉检测模型 EDR-YOLOv7(EVC-DySample-Reploss-YOLOv7)。首先, 在颈部网络中引入显示视觉中心模块捕捉像素的隐性关系, 解决小目标特征遗漏的问题。其次, 用动态采样模块替换转置卷积实现特征点的灵活采样, 降低模型计算的复杂度。最后, 针对无人机视角尺度多变的问题及因局部遮挡而导致的预测框误删和偏离的问题, 在损失函数中先后添加 Inner-SIoU(inner-scylla intersection over union)损失项和斥力因子损失项, 不断缩小训练迭代时的预测误差。经试验验证, EDR-YOLOv7 相较于原模型 mAP@0.5 提升 3.89% 的同时检测帧率提升了 5.2 frames/s, 最终将模型部署于 Jetson XAVIER NX 边缘计算机上并采用 TensorRT 推理加速, 在视频流检测任务中表现出色。

关键词: 无人机; 电力巡检; 架空输电线路; YOLOv7; 边缘端; 小目标检测; 多尺度识别; 局部遮挡

Edge-End Target Detection Method for UAVs Inspection of Overhead Transmission Lines Based on EDR-YOLOv7

ZHAO Wenjun^{1,2}, LIU Kai³, XU Guowei⁴, WU Tian^{1,2}, FANG Chunhua^{1,2}, PU Ziheng^{1,2}

(1. Hubei Provincial Engineering Technology Research Center for Power Transmission Line, China Three Gorges University, Yichang, Hubei 443002, China; 2. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang, Hubei 443002, China; 3. State Key Laboratory of Power Grid Environmental Protection, China Electric Power Research Institute, Wuhan 430072, China; 4. Shantou Power Supply Bureau of Guangdong Power Grid Co., Ltd., Shantou, Guangdong 515000, China)

Abstract: From the perspective of aerial photography of UAVs(unmanned aerial vehicles) during power inspections, taking into account the particularity of the image characteristics of power equipment, a visual detection model EDR-YOLOv7 is proposed suitable for the edge of UAVs to address the common problems of the ubiquitous small target detection, target point occlusion, and the increase in model missed detection rate caused by the variable scale of aerial images, as well as increased calculation amount caused by dense detection. Firstly, a display visual center module is introduced into the neck network to capture the implicit relationship of pixels and solve the problem of missing small target features. Secondly, the dynamic sampling module is used to replace the transposed convolution to achieve flexible sampling of feature points and reduce the complexity of model calculation. Finally, in order to solve the problem of variable viewing angle scale of UAVs and the problem of accidental deletion and deviation of prediction frames caused by partial occlusion, the Inner-SIoU(inner-scylla intersection over union) loss term and the repulsion factor are added to the loss function, continuously reducing the prediction error during training iterations. After experimental verification, EDR-YOLOv7 compared to the original model increases mAP@0.5 and the detection frame rate by 3.89% and 5.2 frames/s respectively. The model is finally deployed on the Jetson XAVIER NX edge computer and accelerated by TensorRT reasoning, which performs well in video stream detection tasks.

Key words: UAV; electric power inspection; overhead transmission lines; YOLOv7; edge deployment; small object detection; multiscale identification; partial occlusion

0 引言

随着电力行业数字化转型战略的不断推进,发展人工智能技术为核心的新型电力系统是实现“双碳”目标的重要途径,已逐步形成了“机巡为主,人巡为辅”的输电线路巡检体系^[1-3]。高压输电线路长期挂网运行受自然侵蚀、高电压强电磁干扰等因素的影响,各类输电线路设备存在如绝缘子串的缺陷、金具螺栓松动等潜在风险,需定期巡检维护。

随着无人机在电力网络中的大规模推广应用,电力巡检的效率和覆盖率得到了显著提升。然而传统无人机巡检模式仍需大量人工干预,存在人力成本高、效率低、耗时长等弊端,开展无人机自主导航技术研究是电网智能化发展的必然趋势。而无人机自主巡检的关键在于如何快速准确地识别架空线路上的关键设备,实现自主定位。通过无人机搭载目标深度学习技术,可高效完成对于巡检目标的自主导航定位与跟踪,增强无人机的实时环境感知能力,并及时发现潜在问题。同时,目标识别算法还在无人机输电线路电力设备维护系统(如绝缘子防污闪涂料喷涂无人机系统等)有所应用,对于关键设备的精准定位极其重要。因此,研究图像识别算法对于实现电力网络中无人机系统自主化、无人化具有重要意义^[4-6]。

目前,目标检测领域中基于卷积神经网络(convolution neural network, CNN)主流的算法主要分为两阶段检测算法和单阶段检测算法。其中两阶段检测算法主要有区域神经网络系列(region-convolution neural network, R-CNN)^[7-9]。在此基础上,研究者们将Transformer的自注意力机制引入,提出了DETR(detection transformer)^[10];另外一类是单阶段检测算法,主要包括YOLO(you only look once)系列^[11]以及SSD(sintel shot multibox detection)系列^[12]等。YOLOv7以速度和精度上优异表现和轻量化的部署框架脱颖而出,在相同体量下,相较于YOLOv8还具有较快的推理速度^[13-14]。

在架空输电线路多旋翼无人机巡检任务中,无人机多位于线路外侧,而输电线路又是多分裂三

相输电,多股线路及其装配的电力设备会位于无人机巡检的同一视角下,这样就导致了以下3个问题。其一,航拍图像中普遍存在的大量小而密集的目标,YOLOv7原模型对于其局部角落特征捕捉并不理想,稠密检测增加了边缘计算设备的压力。其二,由于无人机需保证机与线路的安全距离,聚焦线路内侧设备时,存在许多目标局部遮挡的问题,引起模型漏检率上升。其三,因无人机的实际飞行高差的变化而引起电力设备特征尺度多变的问题。

为了解决上述问题,郭志超^[15]等人采用Pooling+Deconvolution的方式融合各层的语义特征的融合应用于SSD网络,从而解决重复检测问题,但Pooling操作会导致目标边界细节特征丢失,而小目标需要更细致的特征提取和更精准的定位。李利荣^[16]等人使用MobileNetV2进行特征提取,然后加入同尺度残差注意力融合特征,但引入椭圆高斯散射核增加了标签编码的复杂性,需要更多的预处理和处理步骤,难以满足实时性要求。朱敏玲^[17]等人将Swin-Transformer单元和金字塔池化模块融入YOLOv7,最后将Soft-NMS与Mish激活函数相结合,以应对检测对象被遮挡的问题,但是训练的效果依赖于参数的选择,特别是阈值和衰减系数的选择对结果的影响较大,并且存在将高度重叠的候选框视为假阳性的可能。以上方法均未考虑到边缘计算算法轻量化需求,同时上述方法未考虑到系统兼容的问题。胡晨龙^[18]考虑到边缘计算设备的轻量化需求,用LCnet网络优化主干网络,极大提升了网络的计算效率,但未考虑到无人机特殊的运用场景下局部遮挡、小目标等一系列影响检测精度的问题。

为同时满足航拍视频流的检测速度和识别精度的双重要求,以及在Jetson XAVIER NX边缘计算机上的适用性,因此引入YOLOv7作为基础模型。但原模型在局部遮挡条件下和小目标识别中的检测能力不满足要求,同时输电线路设备在同一视角下分布密集,导致边缘端的计算开销过大。针对上述问题,本文提出了EDR-YOLOv7,并进行试验验证得出以下结论。

1) 本试验在颈部网络结构中引入显示视觉中心模块(explicit visual center, EVC),保留了像素之间的隐性图像特征,以应对数据集中微小目标特

基金项目:国家自然科学基金资助项目(51807110)。

Foundation item: Supported by the National Natural Science Foundation of China (51807110).

征信息丢失的问题。

2) 在颈部网络中使用动态采样模块(DySample)替换转置卷积(transposed convolution, T-Conv)模块,通过采样点生成器实现特征信息的灵活捕捉。该模块无需多次进行采样卷积计算,利于边缘端的轻量化部署。

3) 用 Inner-SIoU 损失通过辅助边框计算定位回归损失。该函数根据尺度因子的选取调整辅助边框的大小,应对图像尺度多变的问题;引入斥力因子损失(repulsion loss, Rep Loss)应对多个目标预测点局部遮挡带来漏检率上升的问题。

1 改进 YOLOv7 的网络结构

1.1 YOLOv7 目标检测算法

对于现有的目标检测算法,YOLO 以优异的实时性能脱颖而出。而在 YOLO 系列算法中,YOLOv7 又更易于集成部署于移动 GPU 设备,具有优良的性能表现。YOLOv7 网络结构除输出端外,主要包括以下 3 个部分:骨干网络(Backbone)、颈部网络(Neck)和头部网络(Head)。

Backbone 的主要作用是提取电力设备的特征,主要由卷积模块、可扩展高效层聚合网络(extended-efficient layer aggregation network, E-ELAN)模块和最大值池化(max pooling, MP)模块组成。其中,ELAN-H 模块和 MP 层相互配合,使模型在提取特征时更加有效和全面。Backbone 采用组卷积的方式增加了并行运行的计算单元的数量,从而达到稳定网络结构的效果。

Neck 及 Head 作为一个整体,主要作用是对骨干网络所提取的特征进行捕捉,由特征金字塔网络(feature pyramid network, FPN)和路径聚合网络(path aggregation network, PAN)共同组成,二者互融互通,加强了不同层次的特征信息融合的联系。相较于 YOLOv5 网络提升了特征信息的融合效率^[19],减少了计算消耗,使得其最高模型 AP 值达到了 56.70 %。

1.2 EDR-YOLOv7 目标检测算法

针对存在电力设备可采样的特征像素面积小、目标点局部遮挡、多尺度变化导致漏检率上升以及稠密检测中边缘设备的计算压力过大的问题,进一步提出 EDR-YOLOv7 算法,整体网络结构图如图 1 所示。

在 Neck 和 Head 中,首先在 UP 模块之后添加显示视觉中心子网络,增加模型内部特征调节和角区域捕获能力,应对小目标特征点遗漏的问题。其次,在 UP 模块之中将原有的转置卷积层(transpose convolution, T-Conv)替换为动态采样模块(DySample),该模块通过点采样的方式对于图像特征进行灵活采样,以减小稠密预测时的计算开销。最后在损失函数中先后添加 Inner-SIoU Loss 和斥力因子损失项,应对航拍视角多尺度变化和局部遮挡引起的预测偏离和重叠和的问题。

1.2.1 全局显示视觉中心模块

对于航拍图像中存在大量密集的微小目标,致使模型可提取特征像素点面积并不理想。因此,引入全局集中式调节模块——显示视觉中心模块(explicit visual center, EVC)^[20],利用层内特征交互的调节方式来学习像素之间的隐性关系。

EVC 网络结构如图 2 所示,其中 X_i 表示每层特征信息。首先,由骨干网络提取电力设备五级一特征的金子塔图像信息经 Stem 模块进行预处理。然后,分别由轻量级 MLP 和可学习视觉中心机制(learnable visual center, LVC)处理和提取图像信息。其中,使用轻量级 MLP 捕获顶层 X_4 的全局特征的依赖关系(如:颜色、纹理)。采用 LVC 来融合线路金具的层内局部角落特征。最后,这两部分的处理结果沿着各自通道层级联。

Grad-CAM^[21]通过类激活图技术来反映改进模块对预测输出的贡献分布,其可视化结果对比如图 3 所示,在原算法中出现均压环、防振锤、调整板及引流板的特征遗漏,将 EVC 网络结构引入,网络的关注重点集中在输电线路电力设备上,解决了小目标特征点遗漏的问题。

1.2.2 动态采样模块

为更好地适应无人视角下电力设备在不同尺度和位置的分布,减少密集目标检测任务中的计算开销、内存占用率,故引入动态采样模块(DySample)。该模块通过点采样的方式逐步扩大特征分辨率。其中,采样算子通过引入高分辨率的引导特征,以更好地适应目标的尺度和位置变化^[22]。

如图 4 所示,首先,该模块经采样点生成器将输入特征 X 通过线形层得出位置偏置 O ,同时生成采样集 S ,最后对输入的特征图进行采样和双线性




图1 EDR-YOLOv7网络结构图

Fig. 1 EDR-YOLOv7 network structure diagram

插值操作。采样表达式如式(1)—(3)所示。

$$O = 0.5 \cdot \text{sig}[\text{linear}_1(X)] \cdot \text{linear}_2(X) \quad (1)$$

$$S = G + O \quad (2)$$

$$X' = \text{gird_sample}(X, S) \quad (3)$$

式中: X 为采样点的特征信息; O 为逐采样点的位置偏移量; G 为原始网格的初始位置信息; S 为采样集; X' 为输出的采样特征图; $\text{linear}_i(\cdot)$ 为线形层映射; $\text{gird_sample}(\cdot)$ 为采样函数; $\text{sig}(\cdot)$ 为激活函数, 其定义如下。

$$\text{sig}(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

为提升上采样操作的效率, 将采样按通道维度分为4($g=4$)组, 每一通道共用同一偏移量, 再分别进行上采样操作, 最终输出分组采样的结果, 实现特征图上不同位置特征信息动态调整的效果。

1.2.3 损失函数改进

在局部遮挡环境的稠密预测任务中, 由于原模型的CIoU Loss未考虑到期望回归之间向量的夹角对于结果的影响, 同时预测框出现生成边界框振荡

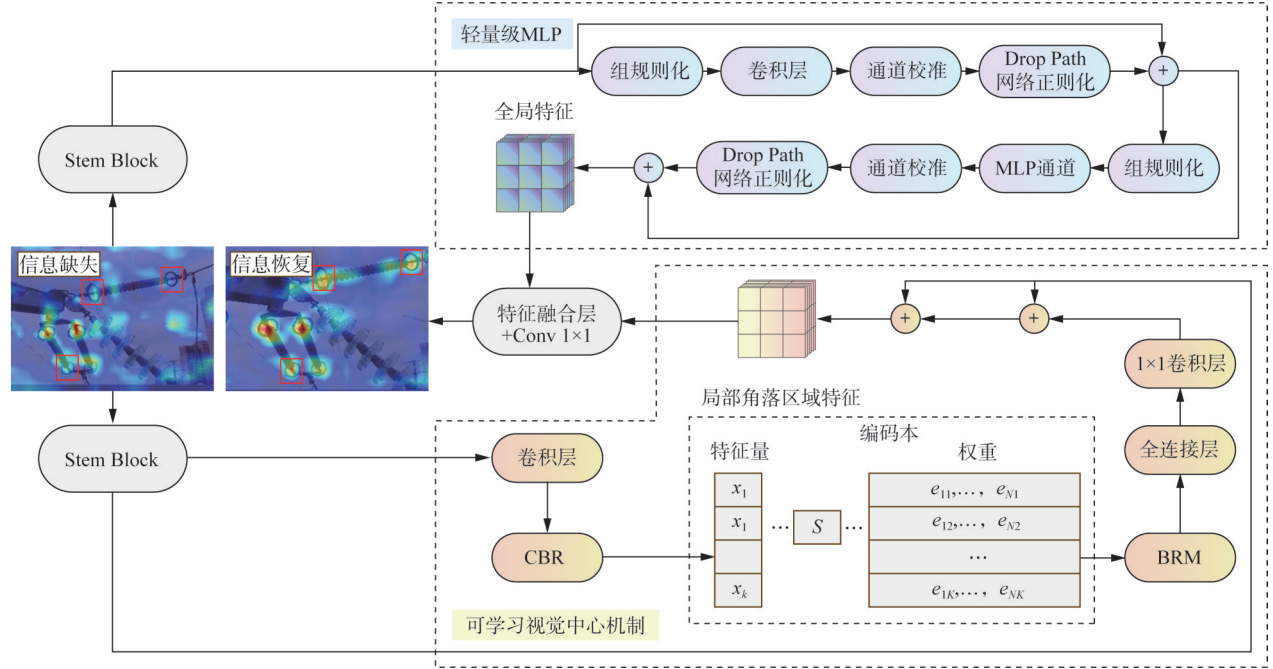



图2 EVC网络结构图

Fig. 2 EVC structure diagram



(a) 未引入EVC模块

(b) 引入EVC模块

图3 Grad-CAM可视化结果对比

Fig. 3 Grad-CAM visualization results comparison

的问题。采用 Inner-SIoU Loss 进一步弥补 CIoU 损失回归收敛较慢和定位偏差的问题^[23]。

Inner-SIoU Loss 通过采用尺度因子(ratio)调节辅助边框大小并计算回归损失 $L_{\text{Inner-SIoU}}$ ，其定义如下。

$$L_{\text{Inner-SIoU}} = 1 + \frac{(\Delta + \Omega)}{2} - I_{\text{oU}}^{\text{inter}} \quad (5)$$

其中：

$$I_{\text{oU}}^{\text{inter}} = \frac{I}{U} \quad (6)$$

$$b_l^{\text{gt}} = x_c^{\text{gt}} - \frac{w^{\text{gt}} \times r}{2}, b_r^{\text{gt}} = x_c^{\text{gt}} + \frac{w^{\text{gt}} \times r}{2} \quad (7)$$




图4 DySample 模块结构图

Fig. 4 DySample module structure diagram

$$b_t^{\text{gt}} = y_c^{\text{gt}} - \frac{h^{\text{gt}} \times r}{2}, b_b^{\text{gt}} = y_c^{\text{gt}} + \frac{h^{\text{gt}} \times r}{2} \quad (8)$$

$$b_t = y_c - \frac{h \times r}{2}, b_b = y_c + \frac{h \times r}{2} \quad (9)$$

$$I = [\min(b_r^{\text{gt}}, b_r) - \max(b_l^{\text{gt}}, b_l)] \times [\min(b_b^{\text{gt}}, b_b) - \max(b_t^{\text{gt}}, b_t)] \quad (10)$$

$$U = (w^{\text{gt}} \cdot h^{\text{gt}})r^2 + (w \cdot h)r^2 - I \quad (11)$$

式中: I 为交集面积; U 为并集面积; Δ 为引入的夹角损失; Ω 为形状损失; r 为尺度因子。上述参数的计算同文献[24]中 SIOU 的计算方式, 本文不再列出; x_c^{gt} 、 y_c^{gt} 为检测框中心点坐标; w^{gt} 、 h^{gt} 分别为对应真实框的宽度和高度; y_c 为检测框坐标; w 、 h 分别为检测框的长度和宽度。

得出边界框回归损失函数 L_{box} 定义为:

$$L_{box} = L_{Inner-SIoU} \quad (12)$$

对于局部遮挡的复杂场景, 引入 SIOU 和 Rep Loss 损失项应对预测偏离和重叠的问题^[25-28], 其定义如下。

$$L_{Rep} = \alpha L_{RepGT} + \beta L_{RepBox} \quad (13)$$

式中: α 、 β 为权重参数; L_{Rep} 为排斥损失总项, 由非目标斥力因子 L_{RepGT} 和预测框排斥因子 L_{RepBox} 组成, 用于减少预测框与非对应目标之间的重叠干扰。

其中, 非目标斥力因子 L_{RepGT} 定义如下。

$$G_{Rep}^p = \arg \max_{G \in \mathcal{G} \setminus \{G_{attr}^p\}} SIOU(G, P_p) \quad (14)$$

$$IoG(B^p, G_{Rep}^p) \triangleq \frac{area(B^p \cap G_{Rep}^p)}{area(G_{Rep}^p)} \quad (15)$$

$$Smooth_{Ln} = \begin{cases} -\ln(1-x), & x \leq \sigma \\ \frac{x-\sigma}{1-\sigma} - \ln(1-\sigma), & x > \sigma \end{cases} \quad (16)$$

$$L_{RepGT} = \frac{\sum Smooth_{Ln}[IoG(B^p, G_{Rep}^p)]}{|P_+|} \quad (17)$$

式中: G 和 P_p 分别为真值框和预测框; G_{attr}^p 为预测框 P_p 在回归时对应的真值框; B^p 为经回归偏移后的预测框; G_{Rep}^p 为预测框 P_p 的 SIOU 值最大的真值框; σ 为平滑因子; $|P_+|$ 为所有预测候选框正样本集合; x 为输入变量; $Smooth_{Ln}$ 为平滑自然对数函数; $SIOU(\cdot)$ 为基于形状和角度的边界框回归损失; $IoG(\cdot)$ 为交并比与参考框面积之比; $area(\cdot)$ 为区域面积函数。

为进一步解决传统的 NMS 阈值选择由于类别指向不明而误删候选框, 在 NMS 处理算法中引入候选框斥力因子 L_{RepBox} , 其定义为:

$$L_{RepBox} = \frac{\sum_{i \neq j} Smooth_{Ln}[IoU(B^{P_i}, G_{Rep}^{P_j})]}{\sum_{i \neq j} \Phi[Iou(B^{P_i}, G_{Rep}^{P_j}) > 0] + \varepsilon} \quad (19)$$

式中: Φ 为恒等函数; ε 为防除零常数; i 为第 i 个真实目标; j 为第 j 个预测框; B^{P_i} 为第 i 个预测框; $G_{Rep}^{P_j}$ 为第 j 个预测框 P_j 对应的 SIOU 值最大的真值框 (其中 $i \neq j$); $IoU(\cdot)$ 为交并比函数。

综上所述, 在引入 Repulsion 损失和 Inner-SIoU 边界框损失函数后最终得出总损失函数定义 L_{total} 如下。

$$L_{total} = L_{box} + L_{obj} + L_{cls} + L_{rep} \quad (20)$$

式中: L_{box} 为边界框回归损失; L_{obj} 为目标置信度损失; L_{cls} 为分类损失; L_{rep} 为排斥损失。

2 试验结果与分析

2.1 试验数据集构建

本文的数据集为某供电公司无人机输电线路巡检所采集的现场图像, 共计 8 758 张, 其分辨率均为 5 472×3 648。

采用图像标定工具 LabelImg 对于 11 类常见巡检的输电线路电力设备进行标注, 各个电力设备数量分布如图 5 所示。为了达到最优训练模型效果按照 7:2:1 的比例划分训练集、测试集和验证集。




图5 各输电设备标签样本数量统计图

Fig. 5 Statistical chart of sample number of labels for each power transmission equipment

2.2 性能评价指标

为评估所改进得输电线路无人机巡检网络分类及定位的准确性, 现通过查准率 (precision, P)、召回率 (recall, R)、平均精度 (average Precision, AP) 及平均精度均值 (mean average precision, mAP) 作为模型锚框检出能力的评价指标。

其中,查准率 P 和召回率 R , 计算方式如下。

$$P = \frac{T_p}{T_p + F_p} \quad (21)$$

$$R = \frac{T_p}{T_p + F_N} \quad (22)$$

式中: T_p 为预测正确的正例数量; F_p 为负样本被错误预测为正例数量; F_N 为预测正确的负例数量。

为进一步计算指标 mAP 值 F_{mAP} , 首先根据类别训练结果, 绘制 P - R 曲线, 然后再取其积分得出类别 R 的 AP 值 F_{APR} , 将所有类别取平均, 计算方式如下。

$$F_{APR} = \int_0^1 P(R) dR \quad (23)$$

$$F_{mAP} = \frac{\sum_{k=1}^n F_{APR}}{n} \quad (24)$$

式中: $P(R)$ 为以召回率 R 为自变量的精确率函数; n 为数据集标注类别数量; F_{APR} 为第 R 个类别的平均精度值。

衡量实时性能的评价指标是模型每秒可检测帧数(frames per second, FPS); 衡量轻量化程度的指标是模型参数量(parameters, Params), 即网络结构中所有参数的总和。

2.3 试验硬件设置与参数设置

试验训练平台和前端部署平台软硬配置如表 1 所示, 经多次试验调整训练超参数如表 2 所示。

表 1 试验硬件配置表

Tab. 1 Experimental hardware configuration table

配置	训练平台(PC端)	边缘端部署平台 (Jetson XAVIER NX)
CPU	Intel Core i5-13700	6核 NVIDIA Carmel Arm v8. 2 6 MB L2 + 4 MB L3
GPU	NVIDIA GeForce RTX 4 090	384核 NVIDIA Volta + 48 Tensor Core
操作系统	Windows 10	Ubuntu 18. 04
运行环境	Cuda Toolkit 11. 7	Cuda Toolkit 11. 4
	Cudnn 8. 9. 7	Cudnn 8. 6. 0
	Pytorch 1. 13. 1	TenssorRT 8. 5. 1

在 Inner-SIoU 损失项中, 为选取合适的尺度因子 $ratio$, 现引入 8 组试验, 评估其值的选取对于检测性能的影响, 结果如表 3 所示。当尺度因子 $ratio$ 为 1. 2 时, 模型的 mAP 值最高, 对于检测查准的收益最大, 故设定其值为 1. 2。

表 2 网络训练超参数

Tab. 2 Network training hyperparameters

参数名称	参数设置
训练图像尺寸/px	640×640
训练轮次	200
批量大小	8
初始学习率	0. 01
最小学习率	0. 000 01
学习率动量	0. 95
优化器	SGD
余弦退火超参数	0. 2
权重衰减系数	0. 000 5

表 3 不同尺度因子效果对比

Tab. 3 Comparison of effects of factors at different scales

尺度因子	$mAP@0. 5/\%$	$mAP@0. 5-0. 95/\%$
0. 7	84. 21	55. 87
0. 8	86. 13	57. 39
0. 9	86. 44	57. 55
1. 0	86. 87	57. 62
1. 1	87. 0	57. 84
1. 2	88. 06	59. 45
1. 3	87. 54	58. 98
1. 4	87. 16	58. 35

注: 加粗字体为每列最优值。

2.4 消融试验结果及分析

EDR-YOLOv7 网络需通过消融试验验证各模块对网络结构中各项指标的影响。在保证各项参数不变的前提下, 进行试验, 得出表 4 数据。此表中“ $\hat{u}$ ”表示将改进模块引入原模型中, 通过各试验数据对比分析可知:

1) 本试验在模型颈部网络结构中引入 EVC, 提升了小目标的检测能力, $mAP@0. 5$ 提升了 1. 09 %, $mAP@0. 5-0. 95$ 提升 2. 13 %, 这主要归因于 EVC 能够保留像素之间的隐性图像特征, 但随之带来的是推理速度下降 1. 31 帧的结果。

2) 为解决 EVC 的引入而带来计算量增加的问题, 通过 DySample 模块进行上采样, 相较于原模型 $mAP@0. 5-0. 95$ 提升 0. 86 %, FPS 提升至 61. 7 frames/s。

3) 进一步减少漏检率和定位偏差, 将 Inner-SIoU Loss 和 Rep Loss 引入损失函数, 在原模型的基础上为 $mAP@0. 5$ 值贡献了 2. 56 %, 为 $mAP@0. 5-0. 95$ 值贡献了 1. 24 %, 同时使得 FPS 提升了

表4 EDR-YOLOv7消融试验结果

Tab. 4 EDR-YOLOv7 ablation experimental results

Group	EVC	DySample	Inner-SIoU Loss	Rep Loss	评价指标			
					mAP@0.5/%	mAP@0.5-0.95/%	Params/ 10^6	FPS/(frames·s ⁻¹)
第1组					87.01	58.41	36.5	55.4
第2组	√				88.10	60.54	37.3	54.1
第3组		√			87.19	59.27	33.1	61.7
第4组			√		88.86	59.44	34.1	56.8
第5组				√	88.43	59.45	36.5	55.4
第6组	√	√			90.21	61.87	33.9	61.1
第7组			√	√	89.57	59.65	34.1	56.8
第8组	√	√	√	√	90.9	62.31	34.5	60.6

注:加粗字体为每列最优值。

1.4 frames/s。


经以上3个改进点的替换融合,得到了EDR-YOLOv7,相比于原YOLOv7算法,在输电线路巡检数据集上mAP@0.5增加3.89%,mAP@0.5-0.95增加了3.9%,推理速度从55.4 frames/s提升至60.6 frames/s,最大限度地保证了精度和检测时的帧率、减少模型参数数量和复杂度。

模型锚框检出能力与训练轮次的关系图6所示,其中,各改进模块按其对应的平均精度均值由高到低依次排序,各类别预测情况用混淆矩阵表示,如图7所示。经分析,得出EVC和DySample的组合对于原模型贡献最大,归因于二者相互配合,在捕捉微小特征带来的收益;RI-SIoU Loss在mAP值上的提升主要在IoU阈值为0.5时有所体现。EDR-YOLOv7在迭代收敛速度上和检测精度上都有一定提升,且其训练迭代效果也稳中向好。


最终得出EDR-YOLOv7算法的混淆矩阵图如图7所示,该图表示各类别电力设备的预测情况。

2.5 对比试验结果及分析

为了验证EDR-YOLOv7的优越性,将该模型与时下流行的网络进行对比,结果如表5所示,分析可知:在电力设备检测任务中,表中模型均取得mAP@0.5高于70%的优异分值,但在检测速度上有显著差异。其中在Faster-RCNN、Cascade-RCNN、DETR、EfficientDet此类两阶段检测算法上检测速率并不理想。尽管YOLOv8在mAP值上达到了88.06%,但由于输电设备数据集稠密点过多的影响,而导致检测速度稍逊于本文方法。其中,YOLOv7-tiny的检测速度表现最佳,但是以牺



(a) mAP@0.5训练变化曲线



(b) mAP@0.5:0.95训练变化曲线

图6 训练过程中EDR-YOLOv7的mAP变化对比曲线

Fig. 6 mAP change comparison curves of EDR-YOLOv7 during the training process

牲模型精度为前提,其mAP是不满足检测要求的。经以上分析得知本文算法相较于其他算法在输电线路电力设备检测在各指标上呈现出更好的效果,满




图7 各类别预测混淆矩阵图

Fig. 7 Prediction confusion matrix diagram for each category

表5 不同目标检测算法对比试验

Tab. 5 Comparison experiment of different target detection algorithms

网络名称	mAP@0.5/%	FPS/(frames·s ⁻¹)
Faster-RCNN	86.64	28.8
Cascade-RCNN	86.85	18.3
DETR	83.37	19.9
EfficientDet	87.8	35.5
SSD	73.51	59.7
YOLOv5	85.74	51.6
YOLOv7-tiny	80.31	61.9
YOLOv7	87.01	55.4
YOLOv8	88.06	54.2
Ours	90.9	60.6

注：加粗字体为每列最优值。

足了实时性和准确性的双重要求。

2.6 检测结果对比

为了直观对比原模型与EDR-YOLOv7改进后在输电巡线视频流数据中的检测差异，将二者分别部署于边缘端计算机上，并使用TensorRT进行推理加速，试验部署如图8所示。

最后，选取典型的图像样本进行对比展示，改进前后的推理结果如图9—10所示，其中椭圆框代表漏检区域，正方形框代表放大区域。显然改进后的网络模型在复杂背景干扰和局部遮挡条件下电力设备检测性能有所提升，在小目标和稠密检测任务中表现出色。






图8 试验部署图

Fig. 8 Experimental deployment diagram




(a) 局部遮挡及复杂背景下YOLOv7检测结果




(b) 局部遮挡及复杂背景下EDR-YOLOv7检测结果

图9 局部遮挡及复杂背景下输电线路设备检测改进前、后对比

Fig. 9 Comparison before and after improvement of transmission line equipment detection under partial occlusion and complex background



(a) 小目标稠密条件下YOLOv7检测结果



(b) 小目标稠密条件下EDR-YOLOv7检测结果

图10 小目标稠密条件下输电线路设备检测改进前、后对比
Fig. 10 Comparison before and after improvement of transmission line equipment detection under small target and dense conditions

3 结论

本文使用多旋翼无人机搭载 Jetson XAVIER NX 边缘计算机, 对于架空线路电力设备进行实时跟踪, 实现对于各类输电设备精准定位。针对巡检目标密集、可提取像素面积小、目标点局部遮挡以及尺度多变问题, 提出 EDR-YOLOv7 模型, 并通过消融试验和对比试验验证了改进模型的有效性。

1) 本试验引入 EVC 极大地保留了各类金具及输电设备的重要角落区域, 从而解决小目标点特征遗漏的问题。

2) 为减少模型的计算消耗和应对目标位置分布多样而导致采样困难的问题, 采用 DySample 通过偏置因子逐步扩大特征分辨率的方式进行特征点采样, 通过试验发现, 模型的检测能力有所提升。

3) 完成对于损失函数的改进优化, 引入 Rep Loss 改进局部遮挡条件下的漏检问题; 采用 Inner-

SIoU Loss 中的 *ratio* 来提升模型多尺度的鲁棒性, 同时还带来了训练收敛速度加快的收益。

最终可得出, EDR-YOLOv7 相较于原模型 mAP@0.5 提升了 3.89%, 相较于 mAP@0.5-0.95 提升了 3.9%, 帧率提升至 60.6 frames/s, 最终将模型部署于边缘端计算平台, 在视频流巡线检测任务中表现优异。

参考文献

- [1] 梁华尘, 周稳, 倪旭东, 等. 面向多目标联合电力巡检的车载无人机协同巡检路径规划方法[J]. 南方电网技术, 2023, 17(11): 138-147.
LIANG Huachen, ZHOU Wen, NI Xudong, et al. Cooperative inspection path planning method for multi-objective joint power inspection by vehicle-mounted UAV [J]. Southern Power System Technology, 2023, 17(11): 138-147.
- [2] 隋宇, 宁平凡, 牛萍娟, 等. 面向架空输电线路的挂载无人机电力巡检技术研究综述[J]. 电网技术, 2021, 45(9): 3636-3648.
SUI Yu, NING Pingfan, NIU Pingjuan, et al. Review on mounted UAV for transmission line inspection [J]. Power System Technology, 2021, 45(9): 3636-3648.
- [3] 彭向阳, 吴功平, 金亮, 等. 架空输电线路智能机器人全自主巡检技术及应用[J]. 南方电网技术, 2017, 11(4): 14-22.
PENG Xiangyang, WU Gongping, JIN Liang, et al. Full-automatic inspection technology of intelligent robot for overhead transmission lines and its application [J]. Southern Power System Technology, 2017, 11(4): 14-22.
- [4] 华志刚. 发电行业人工智能应用[M]. 北京: 中国电力出版社, 2020.
- [5] 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 Chuanyang, WU Yiquan. Research progress of vision detection methods based on deep learning for transmission lines [J]. Proceedings of the CSEE, 2023, 43(19): 7423-7446.
- [6] 邵瑰玮, 刘壮, 付晶, 等. 架空输电线路无人机巡检技术研究进展[J]. 高电压技术, 2020, 46(1): 14-22.
SHAO Guiwei, LIU Zhuang, FU Jing, et al. Research progress in unmanned aerial vehicle inspection technology on overhead transmission lines [J]. High Voltage Engineering, 2020, 46(1): 14-22.
- [7] GIRSHICK R. Fast R-CNN[DB/OL]. (2015-4-30) [2015-9-27]. <https://arxiv.org/abs/1504.08083>.
- [8] 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.
- [9] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[DB/OL]. (2017-3-20) [2018-1-24]. <https://arxiv.org/abs/1703.06870>.
- [10] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]//Proceedings of the European Conference on Computer Vision, August 23, 2020, Glasgow, UK. New York: IEEE, 2020: 23-28.
- [11] REDMON J, DIVVALA S, GIRSHICK R, et al. You only

- look once: unified, real-time object detection [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27 – 30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 779 – 788.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C]//European Conference on Computer Vision, September 17, 2016, Amsterdam, Netherlands. Cham: Springer, 2016: 21 – 37.
- [13] 王琳毅, 白静, 李文静, 等. YOLO 系列目标检测算法研究进展 [J]. 计算机工程与应用, 2023, 59(14): 15 – 29.
WANG Linyi, BAI Jing, LI Wenjing, et al. Research progress of YOLO series target detection algorithms [J]. Computer Engineering and Applications, 2023, 59(14): 15 – 29.
- [14] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 17 – 24, 2023, Vancouver, BC, Canada. New York: IEEE, 2023: 7464 – 7475.
- [15] 郭智超, 邓建球, 刘爱东, 等. 基于改进 SSD 的无人机航拍目标检测方法 [J]. 兵器装备工程学报, 2021, 42(5): 184 – 190.
GUO Zhichao, DENG Jianqiu, LIU Aidong, et al. UAV aerial target detection method based on improved SSD [J]. Journal of Ordnance Equipment Engineering, 2021, 42(5): 184 – 190.
- [16] 李利荣, 陈鹏, 张云良, 等. 基于改进 CenterNet 的输电线路电力器件及异常目标检测 [J]. 高电压技术, 2023, 49(11): 4757 – 4765.
LI Lirong, CHEN Peng, ZHANG Yunliang, et al. Detection of power devices and abnormal objects in transmission lines based on improved CenterNet [J]. High Voltage Engineering, 2023, 49(11): 4757 – 4765.
- [17] ZHAO L, ZHU L M. MS-YOLOv7: YOLOv7 based on multi-scale for object detection on UAV aerial photography [J]. UAVs, 2023, 7(3): 188.
- [18] 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 Chenlong, PEI Shaotong, LIU Yunpeng, et al. Real-time defect detection method for transmission line edge end based on LEE-YOLOv7 [J]. High Voltage Engineering, 2024, 50(11): 5047 – 5057.
- [19] 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.
- [20] QUAN Y, ZHANG D, ZHANG L, et al. Centralized feature pyramid for object detection [J]. IEEE Transactions on Image Processing, 2023(32): 4341 – 4354.
- [21] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient based localization [C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22 – 29, 2017, Venice, Italy. New York: IEEE, 2017: 618 – 626.
- [22] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV), October 1 – 6, 2023, Paris, France. New York: IEEE, 2023: 6004 – 6014.
- [23] ZHANG H, XU C, ZHANG S J, et al. Inner-IoU: more effective intersection over union loss with auxiliary bounding box [DB/OL]. (2023 – 11 – 6)[2023 – 11 – 14]. <https://arxiv.org/abs/2311.02877>.
- [24] ZHORA G. Siou loss: more powerful learning for bounding box regression [EB/OL]. (2022 – 5 – 25)[2022 – 5 – 20]. <https://arxiv.org/abs/2205.12740>.
- [25] 刘甜甜, 彭放, 卢伟龙, 等. 基于 YOLOv7 的智能电网外部安全帽佩戴风险因素识别与检测 [J]. 电测与仪表, 2024, 61(12): 42 – 48.
LIU Tiantian, PENG Fang, LU Weilong, et al. Identification and detection of external risk factors for safety helmet wearing in smart grid based on YOLOv7 [J]. Electrical Measurement & Instrumentation, 2024, 61(12): 42 – 48.
- [26] 潘国清, 洪永学, 邵天赐, 等. 基于改进 YOLOv10n 的变电设备红外图像检测 [J]. 广东电力, 2025, 38(8): 41 – 52.
PAN Guoqing, HONG Yongxue, SHAO Tianci, et al. Infrared image detection of substation equipment based on improved YOLOv10n [J]. Guangdong Electric Power, 2025, 38(8): 41 – 52.
- [27] 孙方伟, 李承阳, 谢永强, 等. 深度学习应用于遮挡目标检测算法综述 [J]. 计算机科学与探索, 2022, 16(6): 1243 – 1259.
SUN Fangwei, LI Chengyang, XIE Yongqiang, et al. Review of deep learning applied to occluded object detection [J]. Computer Science and Technology, 2022, 16(6): 1243 – 1259.
- [28] WANG X L, XIAO T T, JIANG Y N, et al. Repulsion loss: detecting pedestrians in a crowd [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Jun 18 – 23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 7774 – 7783.

收稿日期: 2024-05-07; 网络首发日期: 2025-01-28

作者简介:

赵文俊(2000), 男, 硕士研究生, 研究方向为高电压与绝缘技术、输电线路智能运维技术、无人机智能巡检技术, 1491331697@qq.com;

刘凯(1979), 男, 高级工程师(教授级), 博士, 从事输电线路运行维护、带电作业技术研究, liukai3@epri.sgcc.com.cn;

吴田(1983), 男, 通信作者, 副教授, 博士, 研究方向为带电作业、高电压与绝缘技术, wutian_08@163.com。