

DOI:10.19651/j.cnki.emt.2519177

# 改进 YOLOv10n 的绝缘子缺陷检测算法<sup>\*</sup>

刘庆强<sup>1</sup> 郑潇栋<sup>1</sup> 刘远红<sup>1</sup> 钱坤<sup>2</sup>

(1. 东北石油大学电气信息工程学院 大庆 163318; 2. 大庆油田采油工艺研究院 大庆 163453)

**摘要:** 针对无人机电力巡检场景下绝缘子故障检测存在的小目标漏检率高、复杂背景干扰显著及实时性不足等关键挑战,本研究提出一种基于多尺度特征协同优化的改进型 YOLOv10n 检测模型。通过构建轻量化自适应特征提取网络与多尺度语义增强架构的分层融合机制,在浅层网络采用动态可变形分组卷积与通道重校准策略提升微小缺陷特征敏感性,深层网络则通过多分支空洞卷积金字塔与跨维度注意力机制建立跨尺度关联,实现了检测精度与计算效率的协同优化。提出一种形状敏感的 InSh-IoU 损失函数,通过动态调整边界框形状权重系数,使长宽比异常目标的定位误差降低,能更好定位绝缘子位置。经自建的绝缘子故障数据集验证,本模型在保持实时检测速度的前提下,平均检测精度(mAP@0.5)达到 97.12%,较基准模型提升 2.82%。

**关键词:** 绝缘子故障检测;改进 YOLOv10n;小目标检测;多尺度特征融合;形状权重损失函数

**中图分类号:** TP391.4;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.6040

## Improved YOLOv10n insulator defect detection algorithm

Liu Qingqiang<sup>1</sup> Zheng Xiaodong<sup>1</sup> Liu Yuanhong<sup>1</sup> Qian Kun<sup>2</sup>

(1. College of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163318, China;

2. Daqing Oilfield Production Technology Institute, Daqing 163453, China)

**Abstract:** Addressing the key challenges of insulator fault detection in drone-based power inspection scenarios, such as high missed detection rate for small targets, significant interference from complex backgrounds, and insufficient real-time performance, this study proposes an improved YOLOv10n detection model based on multi-scale feature collaborative optimization. By constructing a lightweight adaptive feature extraction network and a hierarchical fusion mechanism of multi-scale semantic enhancement architecture, dynamic deformable grouped convolution and channel recalibration strategies are adopted in the shallow network to enhance the sensitivity to micro-defect features, while a multi-branch dilated convolution pyramid and cross-dimensional attention mechanism are established in the deep network to build cross-scale associations, achieving a collaborative optimization of detection accuracy and computational efficiency. A shape-sensitive InSh-IoU loss function is proposed, which dynamically adjusts the weight coefficient of the bounding box shape to reduce the positioning error of targets with abnormal aspect ratios, enabling more accurate localization of insulators. Verified by a self-built insulator fault dataset, this model maintains real-time detection speed while achieving an average detection accuracy (mAP@0.5) of 97.12%, an improvement of 2.82% over the baseline model.

**Keywords:** insulator fault detection; improved YOLOv10n; small object detection; multi-scale feature fusion; shape weight loss function

## 0 引言

随着智能电网建设进程的加速推进,电力设备状态智能检测技术已成为保障输电系统安全稳定运行的核心环节<sup>[1]</sup>。作为架空输电线路的重要绝缘组件,绝缘子的完整

性直接关系到电网系统的供电可靠性。近年来,无人机(unmanned aerial vehicle, UAV)电力巡检凭借其灵活性、覆盖范围广等特点,逐步取代传统人工巡检方式,成为电力设备缺陷检测的主流技术手段<sup>[2-6]</sup>。然而,受限于无人机巡检图像中绝缘子目标占比小、背景复杂度高(存在导

收稿日期:2025-06-23

<sup>\*</sup> 基金项目:海南省自然科学基金(623MS071)项目资助

线、植被等多重干扰)以及实时检测需求严格等技术瓶颈,现有检测模型在工程实践中仍面临显著挑战。

当前基于深度学习的目标检测算法主要分为两阶段(Two-stage)检测器(如 Faster R-CNN 系列<sup>[7]</sup>、Cascade R-CNN)和单阶段(One-stage)检测器(如 SSD(single shot multiBox detector)<sup>[8]</sup>、RetinaNet<sup>[9]</sup>、YOLO 系列<sup>[10-12]</sup>)。在无人机电力巡检场景中,绝缘子缺陷检测面临严格的实时性要求,同时需兼顾小目标检测精度。两阶段检测器虽精度较高,但其固有的区域建议机制导致推理速度较慢,难以满足实时性需求。相比之下,单阶段检测器因其端到端的预测流程而具有更高的计算效率。其中,YOLO 系列模型凭借其在速度-精度权衡上的持续优化,成为实时目标检测领域的代表性工作。

现有基于 YOLO 的绝缘子检测模型普遍面临浅层网络对小目标细节特征提取不充分,以及深层特征融合易受背景噪声干扰的双重困境<sup>[13]</sup>。例如,YOLOv5 的特征金字塔(feature pyramid network,FPN)在微小目标检测中存在语义信息丢失问题;YOLOv7 的 E-ELAN 虽增强特征复用,但对复杂背景干扰下的误检率控制不足;YOLOv10n 的无锚点设计简化了流程,但其标准卷积操作对微小缺陷的几何形变适应性不足。因此,基于无人机巡检对实时性的严格要求,本研究选择 YOLOv10n 作为基准模型进行改进,以应对绝缘子小目标漏检、背景干扰和实时性挑战。

针对目标尺度多样性问题,多尺度特征融合技术成为研究热点。特征金字塔网络(FPN)通过自上而下路径融合多尺度特征<sup>[14]</sup>,但在低分辨率特征图中难以保留微小缺陷的几何细节;双向特征金字塔(bidirectional feature pyramid network,BiFPN)虽加强了跨尺度信息交互,但其固定权重分配机制难以适应复杂多变的巡检场景;空间金字塔池化快速(spatial pyramid pooling fast,SPPF)模块通过多尺度池化核捕获全局上下文信息,但单一池化操作的纹理特征提取能力有限。这些方法在计算效率与多尺度表征能力的协同优化方面仍存在不足。

为提升模型对关键区域的关注度,轻量化注意力机制逐渐应用于缺陷检测。SENet 通过通道注意力实现特征重标定,但忽略空间维度的重要性;CBAM 联合通道与空间注意力<sup>[15]</sup>,但在高分辨率特征图中计算开销较大;MobileViT 通过线性自注意力重构特征映射关系<sup>[16]</sup>,但其固定窗口划分策略对不规则缺陷适应性较差。现有方法在平衡注意力机制的有效性与计算效率方面仍存在显著技术缺口,且在复杂背景干扰下普遍面临浅层细节特征丢失与深层语义混淆的双重困境<sup>[17-18]</sup>。

本研究提出 YOLOv10n-LAMSDA 模型,通过系统性整合多尺度特征融合、动态注意力引导与轻量化设计,主要贡献包括:

1)提出分层特征协同优化机制,设计多尺度深度聚合(MSDA)模块替代标准 FPN 结构,通过多分支空洞卷积建

立跨层级特征关联,实现浅层细节特征与深层语义特征的优势互补。

2)开发轻量化特征增强模块,构建 3 路并行特征流,通过轻量化自适应特征提取网络(LAE 模块)实现动态可变形卷积与通道重校准的协同优化,在计算资源受限条件下提升小目标特征表征能力。

3)提出基于边界关键点约束的新型损失函数,通过显式建模目标边缘关键点的空间分布与几何关联性,强化模型对小目标几何特征的感知能力。

## 1 改进的 YOLOv10n 模型

针对无人机电力巡检场景下绝缘子故障检测存在的小目标漏检率高、复杂背景干扰显著及实时性不足等关键问题,通过以下措施改进 YOLOv10n 模型:轻量自适应模块(lightweight adaptive extraction network, LAE)有机嵌入特征提取浅层与深层网络,该模块在保持轻量化的同时结合局部特征与全局上下文,提升对小目标检测能力;在深层网络中通过加入多尺度扩张注意力模块(multi-scale dilated attention,MSDA)建立跨尺度特征关联,增强复杂背景下故障区域的语义区分度。

图 1 描绘了改进后的 YOLOv10n-LAMSDA 模型网络结构。首先对绝缘子图像进行数据预处理操作,特征提取网络接收尺寸为 640 pixel×640 pixel 的绝缘子图片作为输入。通过特征提取模块后,将尺寸为 80×80,40×40 和 20×20 三种分别对应高、中、低分辨率的特征图,之后输入到预测网络采用非极大值抑制融合多尺度预测框,最终输出绝缘子正常/故障结果及定位信息。

### 1.1 多尺度空洞注意力模块

多尺度扩张注意力模块(MSDA)是为了利用自注意机制在不同尺度上的稀疏性。MSDA 通过线性投影得到特征图 X 的相应查询(Q)、键(K)和值(V)。然后,将特征图的通道分成  $n$  个不同的头部,并在不同的头部中以不同的扩张率执行多尺度 SWDA<sup>[19]</sup>。

MSDA 模块通过多级空洞卷积与通道注意力机制结合,增强模型对多尺度缺陷的感知能力。MSDA 的公式分为两部分:每个头的 SWDA 计算和最终的线性聚合。具体来说,每个头  $h_i$  的计算是 SWDA( $Q_i, K_i, V_i, r_i$ ),所有头的结果拼接后通过线性层得到最终输出 X。计算步骤如下:

对于单个查询位置  $(i, j)$  的自注意力计算:

$$x_{ij} = \text{Attention}(q_{ij}, \mathbf{K}_r, \mathbf{V}_r) = \text{Soft max}\left(\frac{q_{ij} \mathbf{K}_r^T}{\sqrt{d_k}}\right) \times \mathbf{V}_r \quad (1)$$

式中: $q_{ij}$  表示特征图中位置  $(i, j)$  的查询向量 Query; $\mathbf{K}_r$  表示在以  $(i, j)$  为中心的滑动窗口内根据膨胀率  $r$  稀疏选择的 Key 键矩阵; $\mathbf{V}_r$  表示在以  $(i, j)$  为中心的滑动窗口内根据膨胀率  $r$  稀疏选择的 Value 矩阵; $d_k$  表示键向量的

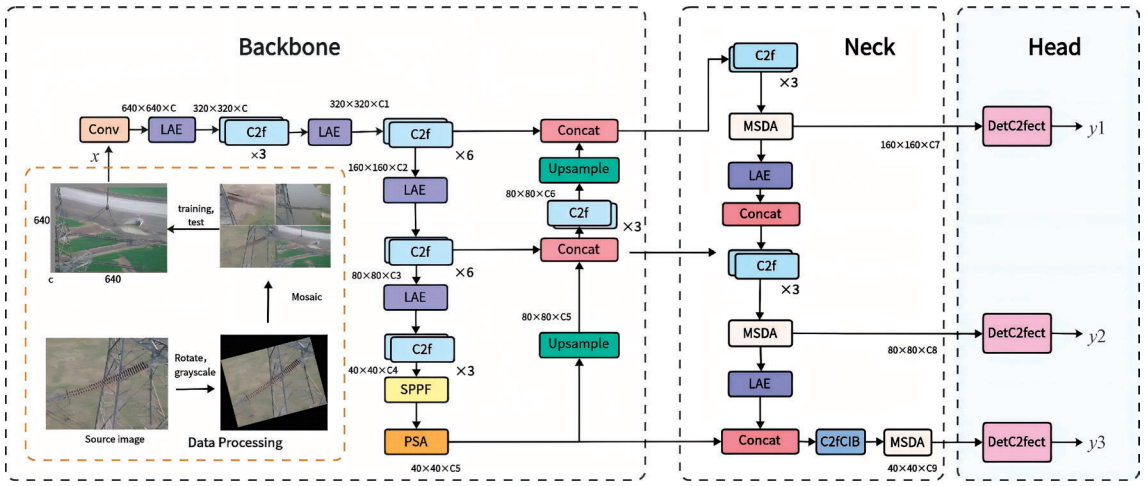


图1 新型YOLOv10n整体网络结构

Fig.1 Overall network architecture of the novel YOLOv10n

维度,用于缩放点积结果以防止梯度消失。

$$\{(i', j') | i' = i + p \times r, j' = j + q \times r\} \quad (2)$$

式中:  $\omega$  表示滑动窗口的尺寸,  $p, q$  表示窗口内位置的数偏移量,由图2可知  $r_i \in \{1, 2, 3, 4\}$ 。通过增大  $r$  逐步扩大注意力范围,捕捉长程依赖,同时保持计算稀疏性。

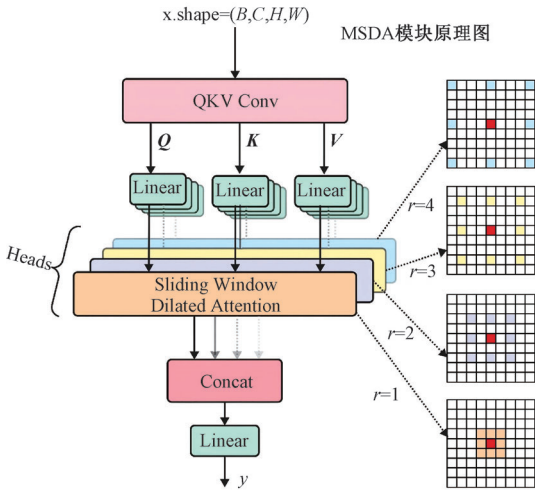


图2 MSDA模块原理图

Fig.2 Schematic diagram of the MSDA module

之后将特征通道划分为  $n$  个并行头,每头独立执行SWDA,公式为:

$$h_i = SWDA(Q_i, K_i, V_i, r_i), 1 \leq i \leq n \quad (3)$$

$$X = Linear(Concat(h_1, h_2, \dots, h_n)) \quad (4)$$

式中:  $Q_i$  表示第  $i$  个头的查询矩阵;  $K_i$  表示第  $i$  个头的键矩阵;  $V_i$  表示第  $i$  个头的值矩阵;  $r_i$  表示第  $i$  个头的膨胀率;  $h_i$  表示第  $i$  个头的输出特征。

### 1.2 轻量级自适应提取模块

与传统的卷积方法相比,在多尺度特征提取中,LAE显著减少了参数和计算的数量同时还提取具有更丰富的

语义信息的功能<sup>[20]</sup>。LAE模块分为 Adaptive Extraction(自适应提取)和 Lightweight Extraction(轻量级提取)两组分支。

对于LE部分,输入特征图尺寸是  $h \times w \times c$ ,经过  $1 \times 1$  卷积,groups= $c/16$  分组,然后是 Rearrange Operator(R)和 Softmax(S),最后通过 Sum 合并。这部分的作用是进行轻量级的特征提取,通过分组卷积减少参数量,同时利用重排和 Softmax 进行特征调整和归一化。

对于特征提取与维度变换路径,原始输入特征图经由LE部分,通过深度可分离卷积使其维度得到变换通过rearrange函数重新排列,将通道数分割成4个部分,并与空间维度结合。可以将不同子区域的特征分开,以便后续的加权求和。整体公式如式(5)所示。

$$X_{light} = Rearrange(Ds\_Conv(X_{input}), (b', s, ch, h, w) \rightarrow (b, ch, h, w, s')), s = 4 \quad (5)$$

式中:  $X_{input} \in \mathbf{R}^{h \times w \times c}$  表示原始特征图;  $b, s, ch$  分别代表批次大小,分割系数,通道数。

由图3可知  $X_{input}$  经过按通道分为16组进行组卷积,卷积后跨通道特征交互,生成  $X_{conv}$ ,之后将其通过可学习矩阵  $W_{map}$ ,对每组特征进行线性变换输出映射特征  $X_{map} \in \mathbf{R}^{h \times w \times 16 \times k}$ ,然后将16组特征沿空间维度拼接重组生成  $X_{rear}$ ,最后通过加权求和得到  $X_{light}$ 。

其次是自适应提取路径通过平均合并和卷积交换信息。从本质上讲,此路径上的减速采样会根据4个相邻像素(例如左上角的4个像素)重组特征图,其各自的权重通过SoftMax表达,也将尺寸转化为五维。公式如式(6)所示。

$$X_{adapt} = Softmax(Rearrange(Attention(X_{input}), (b', ch, s_1, h, s_2, w) \rightarrow (b, ch, h, w, s'_1, s'_2)), s'_1 = 1, s'_2 = 2) \quad (6)$$

由图4可知  $X_{input}$  经过平均池化层,压缩空间维度,捕获全局上下文得到  $X_{pool}$ ,再通过  $1 \times 1$  卷积实现特征升维




图 3 Lightweight extraction 部分结构图

Fig. 3 Schematic diagram of the lightweight extraction module




图 4 Adaptive Extraction 部分结构图

Fig. 4 Schematic diagram of the adaptive extraction module

得到  $X_{up}$ ，通过维度映射后，将不同组的特征沿空间或通道维度重新排列生成  $X_{rear1}$ ，通过计算全局注意力权重和特征校准得到该路径的输出  $X_{adapt}$ 。公式如式(7)~(8)所示。

$$A_{global} = \text{Soft max}(X_{rear1}) \quad (7)$$

$$X_{adapt} = A_{global} \times X_{input} \quad (8)$$

两分支融合最终得到输出尺寸为  $h/2 \times w/2 \times c$  的  $X_{output}$ ，即：

$$X_{output} = X_{adapt} \oplus X_{light} \quad (9)$$

### 1.3 全局局部注意力协同机制

针对无人机巡检图像中存在的浅层细节易丢失、深层语义受干扰的核心矛盾，本工作提出全局-局部注意力协同机制，将前文提到的 MSDA 模块和 LAE 模块在网络不同层次中有机融合，其设计遵循以下原则：

1) 在浅层网络高分辨率特征图(P2/P3)优先保留绝缘子边缘纹理等局部细节，在深层特征图(P5)强化背景干扰抑制能力；

2) 通过局部稀疏注意力与全局密集注意力的交替部署，构建自底向上的显著性特征增强路径；

如图 5 所示，MSDA 模块和 LAE 模块通过分层部署策略实现全局-局部特征的动态协同：浅层局部优化(P2/P3)，连续堆叠 2 个 LAE 模块，构建高密度细节增强路径。通过局部感受野约束(3×3 卷积核)和通道维度重标定，重点提取绝缘子边缘、裂纹等微小目标的梯度特征。中层交替融合(P4)采用 LAE 与 MSDA 的交替连接架构；在下采样阶段使用 LAE 模块进行局部特征增强，上采样阶段通过 MSDA 模块注入全局上下文信息。该策略在中分辨率特征图上实现细节保留与语义增强的平衡。深层网络中(P5)全局抑制：部署级联式 MSDA 模块(深度=3)，通过多尺度空洞卷积构建空间注意力金字塔，有效检测缺陷目标。

### 1.4 损失函数设计

目标检测的损失函数设计是平衡定位精度与分类置

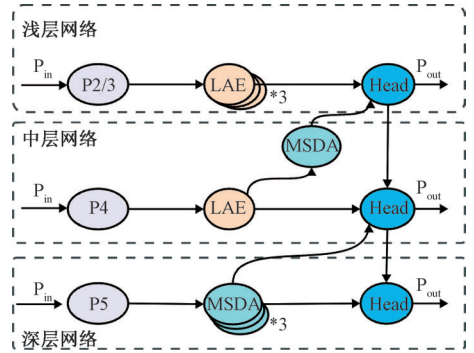


图 5 MSDA 与 LAE 模块融合图

Fig. 5 MSDA and LAE module fusion diagram

信度的核心问题。现有方法主要围绕交并比(IoU)的几何约束改进，但其在复杂场景下的局限性逐渐显现。

早期工作采用 IoU Loss 直接优化预测框与真实框的重叠区域，但其在非重叠情况下梯度消失的问题显著，GIoU 通过引入最小包围盒缓解了零重叠问题，但未考虑目标内部结构。CIoU<sup>[21]</sup>进一步融合中心点距离与宽高比约束，定义为：

$$L_{CIoU} = 1 - IOU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (10)$$

其中， $b$  和  $b^{gt}$  分别是预测框和真实框的中心点； $\rho(\cdot)$  表示欧几里得距离； $c$  是预测框与真实框之间的最小外接矩形的对角线距离； $\alpha$  是一个权衡参数； $v$  为衡量长宽比的一致性。

然而，CIoU 对目标形状的静态建模(如统一处理长宽方向)导致其对非规则目标(如长条形或小尺度物体)的敏感性不足<sup>[22]</sup>。

针对形状敏感性，SIoU<sup>[23]</sup>提出角度惩罚项，通过预测框与真实框中心连线与坐标轴的夹角动态调整损失权重，即：

$$L_{SIoU} = 1 - IOU + \Delta_\theta + \Delta_\gamma + \Omega_\rho \quad (11)$$

而 Shape-IoU<sup>[24]</sup>首次引入水平和垂直方向权重系数  $\omega\omega$  与  $hh$ , 根据目标长宽方向动态调整损失, 即:

$$L_{Shape-IoU} = 1 - IOU + d^{shape} + 0.5\Omega^{shape} \quad (12)$$

Shape-IoU 损失函数对小目标和长条形物体的检测精度提升显著, 但未解决高度重叠目标的定位模糊性问题。为提升密集目标的区分能力, Inner-IoU<sup>[25]</sup> 提出收缩原始边界框生成辅助框, 通过引入缩放因子  $ratio$  来缩放原始框生成, 用于聚焦核心区域 (高 IoU 样本) 或扩展回归范围 (低 IoU 样本), 聚焦目标核心区域。辅助框的边界坐标由原始框中心点、宽高及缩放因子动态生成, 公式如式 (13)~(15) 所示。

真实辅助框和预测辅助框宽高为:

$$\begin{cases} \omega_{inner}^{gt} = \omega \cdot (1 - ratio) \\ h_{inner}^{gt} = h \cdot (1 - ratio) \\ \omega_{inner} = \omega \cdot (1 - ratio) \\ h_{inner} = h \cdot (1 - ratio) \end{cases} \quad (13)$$

经缩放因子缩放后生成辅助框中心点保持不变, 即:

$$\begin{cases} x_{cinner}^{gt} = x_c^{gt} \\ y_{cinner}^{gt} = y_c^{gt} \\ x_{cinner} = x_c \\ y_{cinner} = y_c \end{cases} \quad (14)$$

$$IoU_{inner} = \frac{|B_{inner} \cap B_{inner}^{gt}|}{|B_{inner} \cup B_{inner}^{gt}|} \quad (15)$$

其中,  $B_{inner}$  为按比例压缩的预测辅助框,  $B_{inner}^{gt}$  为按比例压缩的真实辅助框; 但未考虑形状权重, 导致非对称目标的回归稳定性不足。综合上述现有方法存在一些局限: 传统 IoU-based 损失对高度重叠目标的边界区分能力弱, 易导致漏检或误检; 静态建模长宽比约束, 忽略目标自身形状对回归方向的动态影响; 小目标的 IoU 计算易受噪声干扰, 且短边方向偏差未被显式加权。

基于上述分析, 本文提出 InSh-IoU (Inner-Shape IoU), 其核心思想为: 通过 Inner-IoU 聚焦目标核心区域, 降低重叠干扰; 引入 Shape-IoU 的权重系数  $\omega\omega/hh$ , 根据目标自身形状调整损失敏感方向增强对非规则目标的回归鲁棒性; 将内部区域匹配与形状感知损失融合, 公式定义为:

$$L_{InSh-IoU} = 1 - IOU_{inner} + d_{inner}^{shape} + 0.5\Omega_{inner}^{shape} \quad (16)$$

$$\Omega_{inner}^{shape} = \sum_{l=\omega, h} (1 - e^{-\omega_l t})^4 \quad (17)$$

$$\omega_{\omega} = hh \cdot \frac{|\omega_{inner} - \omega_{inner}^{gt}|}{\max(\omega_{inner}, \omega_{inner}^{gt})^l} \quad (18)$$

该设计解决了传统方法在重叠目标、非规则形状及小尺度场景下的局限性, 为复杂检测任务提供更鲁棒的优化目标。

## 2 实验与结果分析

该实验在配备 i7-12700 和 RTX 4060 显卡 (GPU) 的

Windows 11 系统上进行。使用的深度学习框架为 PyTorch 1.8, 安装环境由 CUDA 12.6 和 OpenCV 组成。绝缘子数据集分为两部分: “真实”样本和“缺陷”样本。训练数据集和验证数据集以 6:1 的比例分割。网络优化采用随机梯度下降 (SGD) 算法, 配置初始学习率 0.001 并配合余弦退火策略动态调整, 设置动量参数 0.925 以加速收敛方向修正, 施加 L2 正则化 (权重衰减系数 0.0005) 抑制模型复杂度, 批量大小固定为 16 以平衡显存占用与梯度估计稳定性, 全程训练 100 个 epoch 确保参数充分收敛。检测正确性通过预测框与真实框的交并比 (IoU) 进行判定。上述参数配置对模型性能优化及实验可复现性至关重要。

### 2.1 数据预处理

无人机从 35 kV 输电线路拍摄的原始数据集。自用数据集数量为 2 000 张, 每张图片大小为  $6\,874 \times 3816$ 。图 6 显示了正常和有缺陷的绝缘子图片。为了获得更多样本, 使用灰度和旋转操作生成新样本, 生成的样本如图 7 所示。最终的训练数据集包含 1 500 个正常绝缘子和 1 500 个缺陷绝缘子。测试数据集由 500 张图片组成, 训练数据集中的所有图片均使用 labellmg 软件进行标注。




图 6 绝缘子现场图片

Fig. 6 On-site photographs of insulators




图 7 生成缺陷图像

Fig. 7 Generated defect images of insulators

### 2.2 消融实验

为了验证上述改进方法对整体模型性能的影响, 以 YOLOv10n 模型为基准模型, 输入图片大小均为  $640 \times 640$ , 在扩充的数据集上进行消融实验以验证改进方法的有效性, 方法 2~4 用来验证单个改进点对模型的有效性, 方法 5~7 用来验证改进点叠加后对模块的有效性。“√”表示在模型中使用了该方法, 消融实验结果如表 1 所示。

表 1 消融实验结果

Table 1 Ablation experimental results

模型	MSDA	LAE	InSh-IOU	mAP50/%	mAP50-95/%	检测速度/fps	Weight size/M
1				94.30	73.30	63.2	3.8
2	✓			95.80	75.61	58.9	4.6
3		✓		94.45	73.32	65.8	3.4
4			✓	95.56	75.93	63.2	3.8
5	✓	✓		96.90	77.36	61.3	4.2
6	✓		✓	96.77	76.79	58.9	4.6
7		✓	✓	95.45	74.46	65.8	3.4
8	✓	✓	✓	<b>97.12</b>	<b>78.70</b>	<b>61.3</b>	<b>4.2</b>

由表 1 可知:单独使用 MSDA、LAE 和 InSh-IoU 在基准模型上进行改进后,mAP50 分别提高了 1.50%、0.15% 和 1.26%,mAP50-95 分别提高了 2.21%、0.02% 和 2.63%。从精度来看,MSDA 是提升检测精度(尤其是 mAP50)最显著的单模块,但其代价是降低推理速度和增加模型大小。LAE 模块单独使用对精度提升很小,但其在参数量降低 0.4 MB 的同时,其检测速度提升 4.11%。InSh-IOU 提供接近 MSDA 的精度提升,且几乎不增加推理时间和模型大小,改进非常有效。

将改进模块两两叠加后,MSDA 与 LAE 叠加后表现

的效果最优,在检测速度仅损失 3.02%的前提下 mAP50 和 mAP50-95 分别提高了 2.47%和 3.49%。表明 LAE 与 MSDA 组合产生了协同作用,跨层级特征融合优化了小目标漏检问题,获得了比单独 MSDA 或单独 LAE 更好的性能总和。检测速度提高了 13.6%。将改进模块全部融合之后,相较于基准模型,在检测速度仅降低约 3.02%且参数量仅增加 0.4 mb 的情况下,mAP50 和 mAP50-95 分别提高了 2.82%和 5.40%。消融实验证明了最终改进模型 8 对绝缘子缺陷检测的有效性。所有实验的 mAP50、mAP50-95 如图 8 所示。

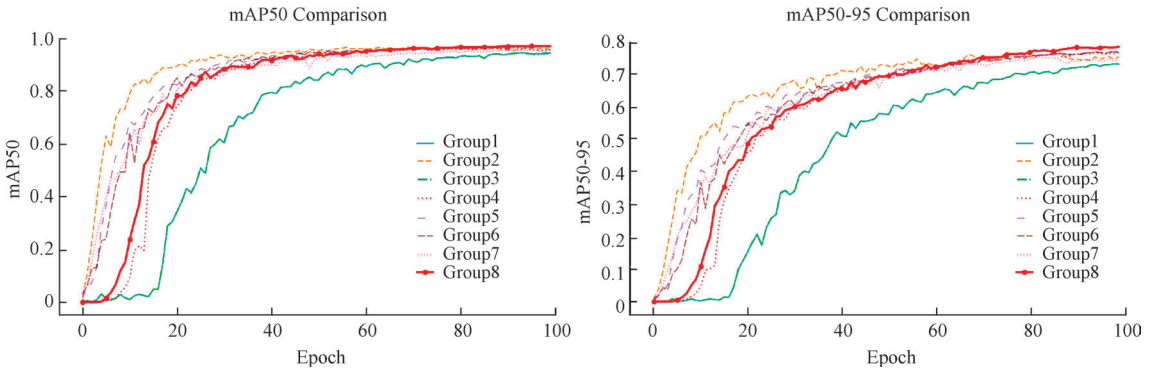


图 8 各项消融实验的 mAP50、mAP50-95 值

Fig. 8 mAP@0.5、mAP@0.5-0.95 values of component-wise ablation studies

改进后的模型在实际图片上的检测结果对比图如图 9 所示。基准模型对于输电线路中小目标绝缘子检测存在漏检现象,而改进后的 YOLOv10n-LSMSDA 模型能够准确识别绝缘子位置并且框置信度有较大幅度提升,对于输电线路绝缘子检测更加准确。

2.3 对比实验

1)不同注意力机制对比实验

为验证提出的多尺度空洞注意力(MSDA)模块的有效性,本实验在相同的 YOLOv10n 模型的基础上,对比了 3 种主流注意力机制的性能。所有注意力模块均部署在网络深层(P5)的相同位置。实验结果如表 2 所示。

SE 与 CBAM 两种注意力机制添加后,参数量基本不

变但检测精度和速度均有下降,因此不适合引入模型用于绝缘子缺陷检测,EMA 和 MSDA 注意力机制在参数量提升不大的情况下均能提升基线模型性能,证明二者在抑制复杂背景干扰上的有效性。相比近年高效的 EMA 注意力,MSDA 注意力机制 mAP 仍提升 0.38%。这验证了多尺度空洞机制在建模长程空间依赖上的优势。

MSDA 在降低 0.3 M 参数的情况下,检测速度仍高于 EMA,显示其良好的计算效率。说明引入 MSDA 能更好地区分缺陷特征和背景信息且不会增加额外计算开销,验证了本文引入 MSDA 的有效性。

2)不同损失函数对比实验

为验证提出的内部交并比形状约束损失函数(InSh-




图 9 改进前后模型检验效果

Fig. 9 Comparison of model validation results before and after improvement

表 2 不同注意力机制对比实验结果

Table 2 Comparative experimental results of different detection models

模型	mAP50/ %	Weight size/M	检测速度/ fps
YOLOv10n	94.30	3.8	54.5
YOLOv10n-SE	94.52	4.2	50.2
YOLOv10n-CBAM	94.95	3.9	52.4
YOLOv10n-EMA	95.42	4.9	55.8
YOLOv10n-MSDA	95.80	4.6	58.9

IoU) 的有效性,本实验在相同的 YOLOv10n 模型的基础上,对比了 4 种主流边界框损失函数。

由表 3 可知:引入损失函数 EIoU、Inner-IoU、Shape-IoU 和 InSh-IoU 后,相较于 CIoU, mAP50-95 精度均有提升,说明对小目标的定位能力均有提升。mAP50 除 SIoU 外均有小范围提升,其中 InSh-IoU 的 mAP50 和 mAP50-95 分别提高 1.26% 和 2.63%,在这几组损失函数中表现最优。由此可验证,改进的损失函数 InSh-IoU 相较于其它主流损失函数有助于模型性能提升。

表 3 不同损失函数对比实验

Table 3 Comparative experimental results of different detection models

损失函数	mAP50/%	mAP50-95/%
CIoU <sup>[21]</sup>	94.30	73.30
SIoU <sup>[23]</sup>	93.25	73.52
Inner-IoU <sup>[25]</sup>	94.83	74.12
Shape-IoU <sup>[24]</sup>	95.05	74.97
InSh-IoU	95.56	75.93

3) 不同 YOLO 系列模型对比实验

为了验证改进后 YOLOv10n-LSMSDA 模型的检测效

果,选择几种经典的 YOLO 系列网络,在相同的实验条件下进行实验,在进行过 Mosaic 数据增强的绝缘子数据集上进行 YOLO 系列网络对比实验,结果如表 4 所示, YOLO 系列网络模型的 mAP 值如图 10 所示。

表 4 YOLO 系列不同检测模型对比实验结果

Table 4 Comparison experimental results of different detection models in YOLO series

模型	mAP50/ %	mAP50-95/ %	检测速度/ fps
YOLOv5s <sup>[10]</sup>	87.50	62.40	52.8
YOLOv7 <sup>[11]</sup>	90.82	65.80	58.6
YOLOv8n	92.55	70.81	67.3
YOLOv10n <sup>[12]</sup>	94.30	73.30	63.2
本文算法	97.12	78.70	61.3




图 10 各项 YOLO 系列模型 mAP50 值

Fig. 10 MAP50 values for various YOLO series models

由表 4 可知,改进后的模型在与其它目标检测模型相比时,检测精度提升较大,相较于 YOLOv5s 模型, mAP50 提高约 10.9%,检测速度提高了 8.5 fps。由图 10 可知相

较于 YOLOv7-tiny, mAP50, mAP50-95 值分别提高 7.44% 和 7.50%, 在与常用的 YOLOv8n 模型相比较时, mAP50 分别提升了 6.86%、8.38%、5.71%。由此可以判断本文提出的基于 YOLOv10n 改进模型, 能够对输电线路绝缘子的位置和故障状态做出准确识别。

#### 4) 同类型模型对比实验

为了全面评估改进后 YOLOv10n-LAMSDA 模型的检测效果, 除了与 YOLO 系列经典网络进行纵向对比外, 本研究特别选取了近年来发表在绝缘子缺陷检测或通用小目标检测领域具有代表性的先进算法进行横向对比。在相同的实验条件下(相同的训练集、测试集、硬件环境、超参数设置), 将本文提出的 YOLOv10n-LAMSDA 模型与表 5 一些方法进行性能比较。

表 5 其它主流算法检测模型对比实验结果

Table 5 Comparison experimental results of other mainstream algorithm detection models

模型	mAP50/%	检测速度/fps
Faster R-CNN <sup>[7]</sup>	92.41	12.5
New-SSD <sup>[8]</sup>	93.25	28.7
RetinaNet <sup>[9]</sup>	92.55	50.6
本文算法	97.12	61.3

与近年代表性先进方法对比: 相较于 Faster R-CNN, 本文方法在 mAP50 上提升 5.85%, 精度优势显著, 且检测速度(61.3 fps) 远超 Faster R-CNN(12.5 fps)。与 New-SSD(引入先进小目标损失) 相比, mAP50 提升 5.01%, 检测速度也得到有效提高。与兼顾轻量化和精度的 RetinaNet 相比, 本文方法在 mAP50 上提升 4.57%, 速度也提高 10.7 fps。这充分证明本文提出的 LAE、MSDA 和 InSh-IoU 等改进模块有效解决了小目标检测的关键难题, 综合性能优于近年报道的代表性先进方法。

#### 5) 公开数据集对比实验

为了验证 YOLOv10n-LAMSDA 模型的泛化能力, 本文采用国家电网于 2022 年公开的中国电力线绝缘子数据集(CPLID)进行对比实验, 其中包含无人机捕获的正常绝缘体图像的数量为 600, 有缺陷的绝缘子图像数量为 248。对该数据集进行数据预处理操作, 训练数据集和验证数据集以 6:1 的比例分割, 所有图片均使用 labellmg 软件进行标注, 所有标注的格式与 VOC2007 数据集相同。该数据集更加贴近实际应用场景且应用较为广泛, 能够很好检验模型的泛化性能。其中实验设置与自建数据集保持一致, 实验结果如表 6 所示。

在 CPLID 公开数据集上的实验表明, 本文提出的 YOLOv10n-LAMSDA 模型与基准模型 YOLOv10n 相比, 在 mAP50 和 mAP50-95 上分别提升了 0.33% 和 0.90%, 相较于更早期的 YOLOv5s 模型, 在 mAP50 和 mAP50-95

表 6 CPLID 数据集实验结果对比

Table 6 Comparison of experimental results on CPLID dataset

模型	CPLID dataset		检测速度/ fps
	mAP50/ %	mAP50-95/ %	
New-SSD <sup>[8]</sup>	85.81	62.09	30.5
YOLOv5s <sup>[10]</sup>	93.69	73.03	53.4
YOLOv8n	97.67	82.13	65.5
YOLOv10n <sup>[12]</sup>	98.38	80.98	63.1
本文算法	98.71	81.88	62.2

上分别显著提升了 5.02% 和 8.85%。这说明本文提出的 YOLOv10n-LAMSDA 模型不仅在所有对比模型中取得了良好的检测精度, 同时保持了优异的推理速度。其在不同分布数据集上的卓越表现, 强有力地验证了该模型具有强大的泛化能力和实际应用价值, 能够很好地适应真实电力巡检场景中的复杂变化, 为无人机电力巡检的智能化应用提供了可靠的技术方案。

## 3 结 论

绝缘子作为输电线路的关键绝缘组件, 其完整性直接影响电网系统的供电可靠性。针对无人机电力巡检场景中存在的绝缘子小目标漏检率高、复杂背景干扰显著、实时性不足等核心挑战, 本研究提出了一种基于改进 YOLOv10n 架构的目标检测算法。通过创新性地引入轻量化自适应特征提取模块(LAE)、多尺度稀疏注意力机制(MSDA)及内部形状感知损失函数(InSh-IoU), 实现了精度与效率的协同优化, 有效满足无人机对输电线路绝缘子的日常巡检需求。尽管本算法在综合性能上表现突出, 但其权重大小(4.2 M)仍略高于 YOLOv10n(3.8 M), 且在高 IoU 阈值下的定位精度存在瓶颈。未来的研究将聚焦于采用知识蒸馏与通道剪枝技术压缩模型体积、引入动态 IoU 阈值分配策略, 针对目标尺度自适应调整定位损失权重, 缓解小目标检测瓶颈。

## 参考文献

- [1] 谢清玉, 张耀坤, 李经纬. 面向智能电网的电力大数据关键技术应用[J]. 电网与清洁能源, 2021, 37(12): 39-46.  
XIE Q Y, ZHANG Y K, LI J W. Key technologies and applications of power big data in smart grids[J]. Power System and Clean Energy, 2021, 37(12): 39-46.
- [2] 艾峰, 邓耀华. 用于缺陷检测的 YOLOv8 轻量化设计方法[J]. 电子测量技术, 2025, 48(4): 181-190.  
AI F, DENG Y H. YOLOv8 lightweight design approach for defect detection [J]. Electronic Measurement Technology, 2025, 48(4): 181-190.

- [3] 熊伟, 路鑫, 邱维进, 等. 基于YOLOv8的输电线路绝缘子表面缺陷识别算法[J]. 电子测量技术, 2025, 48(2):178-188.  
XIONG W, LU X, QIU W J, et al. Urface defect detection algorithm of transmission line insulators based on YOLOv8 [J]. Electronic Measurement Technology, 2025, 48(2): 178-188.
- [4] SHUANG F, HAN SH, LI Y, et al. RSIn-dataset: An UAV-based insulator detection aerial images dataset and benchmark[J]. Drones, 2023, 7(2): 125, DOI:10.3390/drones7020125.
- [5] 赵云鹏, 胡玉耀, 蒋兴良, 等. 绝缘子不均匀积污成因及其对交流闪络特性的影响[J]. 电子测量与仪器学报, 2023, 37(12): 186-195.  
ZHAO Y P, HU Y Y, JIANG X L, et al. Causes of uneven pollution accumulation on the insulator and its influence on AC flashover characteristics[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 186-195.
- [6] 李特, 陶瑞祥, 张锐, 等. 典型发热缺陷复合绝缘子红外特征及无人机红外测试参数选择[J]. 高电压技术, 2022, 48(3): 865-875.  
LI T, TAO R X, ZHANG R, et al. Infrared characteristic of typical composite insulator heating defects and selection of field unmanned aerial vehicle infrared test parameters [J]. High Voltage Technology, 2022, 48(3): 865-875.
- [7] XU X Y, ZHAO M, SHI P X, et al. Crack detection and comparison study based on faster R-CNN and mask R-CNN[J]. Sensors, 2022, 22(3): 1215.
- [8] ZHENG W, TANG W L, JIANG L, et al. SE-SSD: Self-ensembling single-stage object detector from point cloud[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 14494-14503.
- [9] MIAO T, ZENG H CH, YANG W, et al. An improved lightweight RetinaNet for ship detection in SAR images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 4667-4679.
- [10] 赵振兵, 王帆帆, 刘良帅. 基于注意力特征融合YOLOv5模型的无人机输电线路航拍图像金具检测方法[J]. 电测与仪表, 2023, 60(3): 145-152.  
ZHAO ZH B, WANG F F, LIU L SH. Hardware detection method for UAV transmission line aerial images based on attention feature fusion YOLOv5 model[J]. Electrical Measurement & Instrumentation, 2023, 60(3): 145-152.
- [11] 陈永麟, 王恒涛, 张上. 基于YOLOv7的轻量级红外目标检测算法[J]. 红外技术, 2024, 46(12): 1380-1389.  
CHEN Y L, WANG H T, ZHANG SH. Lightweight infrared target detection algorithm based on YOLOv7[J]. Infrared Technology, 2024, 46(12): 1380-1389.
- [12] LI Y, GUO ZH H, SUN Y, et al. Weed detection algorithms in rice fields based on improved YOLOv10n[J]. Agriculture, 2024, 14(11): 2066.
- [13] 郝帅, 杨磊, 马旭, 等. 基于注意力机制与跨尺度特征融合的YOLOv5输电线路故障检测[J]. 中国电机工程学报, 2022, 43(6): 2319-2331.  
HAO SH, YANG L, MA X, et al. YOLOv5 transmission line fault detection based on attention mechanism and cross-scale feature fusion [J]. Proceedings of the CSEE, 2022, 43(6): 2319-2331.
- [14] WANG C Y, LIAO H Y M, WU Y H, et al. A new backbone that can enhance learning capability of CNN[C]. 2020 IEEE CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 1571-1580.
- [15] 张栋, 姜媛媛. 融合注意力机制与逆残差结构的轻量级钻机目标检测方法[J]. 电子测量与仪器学报, 2022, 36(11): 201-210.  
ZHANG D, JIANG Y Y. Lightweight drilling target detection method integrating attention mechanism and inverted residual structure[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 201-210.
- [16] WO S, PARK J, LEE J Y, et al. CBAN: Convolutional block attention module [C]. The European Conference on Computer Vision, 2018: 3-19.
- [17] 臧国强, 刘晓莉, 徐颖菲. 深度学习在电力设备缺陷识别中的应用进展[J]. 电气技术, 2022, 23(6): 1-7.  
ZANG G Q, LIU X L, XU Y F. Research progress of deep learning in power equipment defect recognition[J]. Electrical Technology, 2022, 23(6): 1-7.
- [18] 赵振兵, 熊静, 李冰, 等. 基于改进 Cascade R-CNN的典型金具及其部分缺陷检测方法[J]. 高电压技术, 2022, 48(3): 1060-1067.  
ZHAO ZH B, XIONG J, LI B, et al. Detection method for typical hardware and partial defects based on improved Cascade R-CNN [J]. High Voltage Technology, 2022, 48(3): 1060-1067.
- [19] JIAO J Y, TANG Y M, LIN K Y, et al. Dilateformer: Multi-scale dilated transformer for visual recognition [J]. IEEE Transactions on Multimedia, 2023, 25: 8906-8919.
- [20] YU ZH W, GUAN Q, YANG J M, et al. LSM-

- YOLO: A compact and effective roi detector for medical detection [J]. ArXiv preprint arXiv: 2408.14087, 2024.
- [21] REZATOFIHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 658-666.
- [22] ZHENG ZH H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [23] GEVORGYAN Z. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv:2205.12740, 2022.
- [24] ZHANG H, ZHANG SH K. Shape-IoU: More accurate metric considering bounding box shape and scale[J]. ArXiv preprint arXiv:2312.17663, 2023.
- [25] ZHANG H, XU C, ZHANG SH J. Inner-IoU: More effective intersection over union loss with auxiliary bounding box[J]. ArXiv preprint arXiv:2311.02877, 2023.

### 作者简介

刘庆强(通信作者), 博士, 副教授, 主要研究方向为信号处理、机器学习等。

E-mail: petroboy@163.com

郑潇栋, 硕士研究生, 主要研究方向为深度学习、机器视觉与缺陷检测。

E-mail: 2053644176@qq.com