

文章编号:1007-2780(2026)05-0687-13

基于改进 YOLOv11n 的绝缘子缺陷检测

雷德伟¹, 林国军^{1,2*}, 马 润^{1,2}, 陈明举^{1,2}

(1. 四川轻化工大学 自动化与信息工程学院, 四川 宜宾 644000;

2. 智能感知与控制四川省重点实验室, 四川 宜宾 644000)

摘要:针对电力系统巡检中绝缘子缺陷尺寸微小、特征微弱且易受复杂背景干扰导致的检测精度不足问题,提出一种改进的 YOLOv11n 目标检测模型。该模型在骨干与颈部网络融入 3 项优化策略提升缺陷检测性能:引入 C3k2_DFF 模块,通过自适应通道注意力与跨尺度动态加权融合实现高效特征融合;设计 C3k2_LS 模块,利用大卷积核注意力路径增强全局上下文感知;采用 ConverseUp 上采样算子替代传统方式,基于可学习反卷积主动重建高分辨率细节,减少信息损失。在真实绝缘子缺陷数据集上,改进模型相较 YOLOv11n 基线模型,破损类平均精度(AP)提升 3.2%,闪污类 AP 提升 1.1%,mAP 提升 1.5%,精确率提升 5.7%,召回率稳定,同时保持对绝缘子目标的高检测精度,有效增强了缺陷识别能力,为电力巡检自动化提供了更可靠的技术支撑。

关键词:小目标检测;YOLOv11;绝缘子缺陷检测;动态特征融合;上采样算子

中图分类号:TM85;TP391.41 **文献标识码:**A **doi:**10.37188/CJLCD.2026-0053 **CSTR:**32172.14.CJLCD.2026-0053

Insulator defect detection based on improved YOLOv11n

LEI Dewei¹, LIN Guojun^{1,2*}, MA Run^{1,2}, CHEN Mingju^{1,2}

(1. School of Automation and Information Engineering, Sichuan University of Science and Engineering,
Yibin 644000, China;

2. Intelligent Perception and Control Key Laboratory of Sichuan Province, Yibin 644000, China)

Abstract: To address the problem of insufficient detection accuracy in power system inspection due to the small size, weak characteristics, and susceptibility to complex background interference of insulator defects, an improved YOLOv11n object detection model is proposed. The model integrates three key optimization strategies into its backbone and neck networks to comprehensively enhance defect detection performance. The C3k2_DFF module is introduced, which achieves efficient dynamic feature fusion through an adaptive channel attention mechanism and cross-scale feature dynamic weighted fusion strategy. The C3k2_LS module is designed to augment global context information perception via a large-kernel attention pathway. The ConverseUp upsampling operator is developed and incorporated to replace conventional upsampling

收稿日期:2026-03-27;修订日期:2026-04-12.

基金项目:国家自然科学基金(No. 42405145);四川省科技厅项目(No. 2024YFHZ0026);四川省自然科学基金(No. 2025ZNSFSC0477, No. 2024NSFSC2042)

Supported by National Natural Science Foundation of China (No.42405145); Project of Science and Technology Department of Sichuan Province (No. 2024YFHZ0026); Natural Science Foundation of Sichuan Province (No. 2025ZNSFSC0477, No. 2024NSFSC2042)

*通信联系人, E-mail: tiemujian123400@163.com

methods; based on a learnable deconvolution mechanism, it actively reconstructs high-resolution detail information during feature map scaling transformations, thereby mitigating information loss. Experimental results on a real-world insulator defect dataset demonstrate that the improved model significantly outperforms the original YOLOv11n baseline in critical defect categories, with the broken class Average Precision(AP) improving by 3.2%, the flashover contamination class AP by 1.1%, the overall mean Average Precision(mAP) by 1.5%, and Precision by 5.7%, while Recall remains stable. The model also maintains high detection accuracy for “insulator” targets, validating that the proposed improvements enhance defect recognition capability without compromising fundamental detection performance. This enhancement strategy effectively strengthens the model’s ability to identify insulator defects, providing more reliable technical support for automated power line inspection.

Key words: small object detection; YOLOv11; insulator defect detection; dynamic feature fusion; upsampling operator

1 引言

电力系统的安全运行高度依赖绝缘子的稳定工作,而绝缘子长期暴露于复杂多变的自然环境中,极易受到雷击、污秽、温差变化、机械应力以及化学腐蚀等多种因素的影响,从而产生破损、裂纹、闪络、污秽覆盖等各类缺陷。这些缺陷若未能及时发现和处理,可能引发严重的线路跳闸事故,甚至导致大面积停电,对社会生产生活造成重大经济损失和安全隐患,因此实现绝缘子状态的高效、准确监测具有至关重要的工程价值和现实意义。随着无人机巡检技术的快速普及和广泛应用,电力巡检模式正从传统的人工登塔检查向自动化、智能化方向转变,这对计算机视觉算法的检测精准性和实时性提出了更为严苛的要求。

绝缘子缺陷检测算法经历了从传统图像处理技术到现代深度学习技术的演进。近年来,国内外学者针对绝缘子缺陷检测开展了大量研究。在基于传统图像处理的方法中,Zhang等^[1]利用形态学滤波与边缘检测算子实现绝缘子自爆缺陷的初步识别,但此类方法对光照变化和复杂背景的鲁棒性较差,难以适应野外巡检的实际需求。随着深度学习技术的发展,基于卷积神经网络的目标检测方法逐渐成为主流。Zhang等^[2]采用Faster R-CNN对输电线路绝缘子进行定位与缺陷识别,在理想条件下取得了较高的检测精度,但该方法计算复杂度高、推理速度慢,难以满足无人机实时巡检的要求。Liu等^[3]将YOLO系列算

法应用于绝缘子缺陷检测,通过轻量级网络设计提升了检测效率,然而在面对微小缺陷、密集缺陷及强背景干扰时,漏检率和误检率仍然较高。早期的检测方法主要依赖人工设计的特征提取算子,如边缘检测、纹理分析和形态学处理等,这些方法在特定场景下虽有一定效果,但普遍存在鲁棒性差、泛化能力弱、难以适应复杂背景变化等固有缺陷。以卷积神经网络(CNN)为代表的深度学习技术^[4-7],其中YOLO(You Only Look Once)系列算法^[8-10]凭借速度与精度的平衡,成为无人机实时巡检的首选框架。具体而言,与通用目标检测任务相比,绝缘子缺陷检测具有以下3个方面的特殊挑战性难点:(1)绝缘子缺陷目标通常尺寸较小、特征微弱,易被复杂的背景噪声或绝缘子主体特征所稀释和淹没,导致漏检率较高;(2)标准卷积核的感受野相对有限,难以有效捕捉图像中的全局上下文信息和长距离依赖关系,限制了模型对缺陷语义的理解能力;(3)传统上采样方法在特征图恢复过程中容易丢失细粒度细节信息或引入虚假纹理伪影,影响定位精度。这3个难点相互交织、彼此加剧:微小缺陷本身特征微弱,若再遭遇复杂背景干扰,其有效特征极易被淹没;而感受野受限又导致模型难以建立缺陷区域与周围环境的上下文关联,进一步降低了区分缺陷与干扰的能力;上采样过程中的细节损失则使本已微弱的缺陷特征在深层网络中逐渐衰减,形成“特征退化”的级联效应。因此,如何协同解决上述难点,实现绝缘子微小缺陷的精准、高效、鲁棒检测,是当前该领域研究的核心

挑战与关键科学问题。

针对上述问题,本文以YOLOv11n为基线模型,提出3项针对性优化:引入动态特征融合^[11]模块抑制噪声、聚焦缺陷特征;通过大卷积核注意力模块^[12]捕捉全局上下文信息;采用ConverseUp算子重建高分辨率细节^[13]。旨在提升关键缺陷的检测性能。

2 相关理论

YOLOv11延续YOLO(You Only Look Once)系列的核心思想,即在推理速度和检测精度之间寻求最佳平衡。其结构遵循经典的3部分设计:骨干网络(Backbone)、颈部网络(Neck)和检测头(Head)。骨干网络作为特征提取器,负责从输入图像中逐层提取层次化的视觉特征。颈部网络将骨干网络输出的深层高语义特征图与浅层高

分辨率特征图进行融合。检测头(Decoupled Head)在颈部网络输出的多个融合特征图上并行执行分类和边界框回归任务,以实现针对不同尺度目标的精准定位。

3 改进的YOLOv11n模型

YOLOv11n模型性能先进,但应用于绝缘子缺陷检测有局限性:背景或主体特征稀释;闪污与铁塔锈迹等视觉相似的干扰物之间产生混淆;大量的精细纹理和边缘细节丢失。在骨干网络引入的C3k2_DFF模块能放大缺陷特征并抑制噪声,解决特征稀释问题;C3k2_LS模块可增强模型对全局上下文的理解力;ConverseUp能从低分辨率特征图中重建高分辨率细节,有效保留了“破损”的边缘和“闪污”的纹理,从而根本上解决了细节丢失问题。改进模型如图1所示。




图1 改进的YOLOv11n模型

Fig. 1 Improved YOLOv11n model

3.1 C3K2_DFF模块

在YOLOv11n的网络结构中,标准的C3与

C2f模块作为核心特征提取组件,其内部瓶颈结构(Bottleneck)在处理残差分支特征与主干分支特征

的融合时,普遍采用静态的逐元素相加(Element-wise Addition)或通道维度拼接(Channel-wise Concatenation)机制。此类固定权重的融合策略缺乏对特征通道间判别性差异的自适应能力,无法根据特征内容的重要性动态调整融合权重。具体而言,在工业缺陷检测等应用场景中,当表征微弱缺陷的弱语义特征(Low-saliency Semantic Features)与强响应的背景干扰特征(High-response Background Clutters)进行融合时,静态融合操作易导致关键缺陷信息的信噪比(Signal-to-Noise Ratio, SNR)下降,产生特征稀释(Feature Dilution)现象,进而削弱模型对细粒度缺陷模式的感知能力。

针对特征融合策略的优化,近年来研究者提出了多种改进方案。Liu 等^[14]提出的 ASFF 通过学习空间权重实现多尺度特征的自适应融合,有效缓解了不同尺度特征间的冲突。Wang 等^[15]在 YOLOv8 中引入迭代注意力特征融合(iAFF)模块,利用多尺度通道注意力(MS-CAM)提取局部与全局特征,改善了初始特征融合质量。Zhang

等^[16]提出的 DE-C2f 模块采用双卷积核设计,提升了网络的多尺度特征提取能力。周颖等^[17]提出了一种融合多尺度特征与注意力的太阳能电池表面缺陷检测方法,有效增强了模型对微小缺陷的感知能力,取得了优异的检测精度。尽管上述方法在通用目标检测任务中取得了良好效果,但其融合权重主要依赖于特征图的统计特性或空间位置信息,未能对特征内容的重要性差异进行显式建模,在工业缺陷检测^[18]等弱语义场景中,对背景冗余噪声的抑制能力仍然有限。

针对“特征稀释”这一问题,本文引入一种面向细粒度检测的 C3K2_DFF 模块,在 C3K2 的核心瓶颈结构中集成动态特征融合(Dynamic Feature Fusion, DFF)机制,以可学习的自适应加权策略替代传统的静态融合范式^[19]。如图 2 所示, DFF 机制通过构建轻量级双分支注意力子网络(Lightweight Dual-branch Attention Sub-network),对输入特征图的全局上下文信息(Global Context Information)进行通道维度与空间维度的联合建模,动态生成与特征内容相关的自适应融合权重




图 2 C3K2_DFF 模块结构

Fig. 2 Structure of C3K2_DFF module

重(Adaptive Fusion Weights)。该机制能够在特征融合阶段实现关键缺陷特征的自适应增强(Adaptive Enhancement)与背景冗余噪声的抑制性调控(Suppressive Regulation),从而提升特征表示的判别性与鲁棒性。定量实验结果表明,在PASCAL VOC或工业缺陷检测基准数据集上的评估中,C3K2_DFF模块作为独立插入组件虽对缺陷类别平均精度(Average Precision for Defect Classes, AP_defect)的提升幅度相对有限,但能够显著优化模型的精确率指标(Precision),验证了该动态融合机制在增强特征判别性、缓解背景干扰对微弱缺陷信号掩蔽效应方面的有效性。这一发现表明,DFF机制通过显式建模特征重要性权重,能够在保持检测召回能力的同时,有效降低误检率,为复杂工业场景下的高精度缺陷检测提供了可行的架构改进方案。

3.2 C3K2_LS模块

在电力系统绝缘子缺陷检测领域,基于深度学习的目标检测方法已取得显著进展。Zhou等^[20]针对高压输电线路关键目标与缺陷检测问题,提出了一种基于深度学习的方法,通过改进网络结构实现了对绝缘子及缺陷的有效识别,但

在复杂背景下对微小缺陷的区分能力仍显不足。Feng等^[21]基于YOLOv5框架设计了绝缘子缺陷检测方法,利用多尺度特征融合提升了检测精度,然而标准卷积固有的感受野受限问题导致其在微小缺陷与背景干扰的区分上存在局限。Hao等^[22]将注意力机制与跨尺度特征融合引入YOLOv5输电线路故障检测中,通过增强关键信息表示改善了小目标识别性能,但该方法多聚焦于单一尺度特征增强,缺乏对全局上下文信息与局部精细细节的自适应融合机制。上述研究表明,如何在复杂背景干扰下同时实现“大视野”全局感知与“小焦点”局部精细化处理,仍是绝缘子微小缺陷检测亟待解决的关键问题。

为解决标准卷积固有的感受野受限问题,以及由此导致的在复杂背景下难以有效区分绝缘子微弱缺陷与背景干扰的挑战,本文在骨干网络中间层设计C3K2_LS(C3K2 with Large-Small Convolution)模块,遵循“See Large, Focus Small”的设计策略^[23],核心采用LS_Conv(Large-Small Convolution)结构与LS_Bottleneck瓶颈单元。

该模块采用并行双路径特征提取架构:“Focus Small”分支通过标准小核卷积(3×3)对输入特




图3 C3K2_LS模块结构

Fig. 3 C3K2_LS module structure

征图进行精细化处理,专注于捕捉绝缘子表面缺陷的细微纹理、边缘轮廓及局部结构异常等精细局部特征;“See Large”分支则通过LS_Conv结构实现全局上下文感知,首先利用轻量级关键点预测模块(Lightweight Key Point Module, LKP)生成空间动态权重向量,随后采用Unfold算子将特征图展开为局部块序列,并通过批量矩阵乘法(Batch Matrix Multiplication, BMM)机制高效建模像素间的长距离依赖关系,从而捕获缺陷区域与周围环境的全局关联性。最终,大核全局特征与小核局部特征通过注意力门控机制进行自适应融合,生成富含上下文信息的注意力特征图,并与局部特征进行加权整合,实现全局语义与局部细节的互补增强。

将C3K2_LS模块部署于骨干网络中间层的决策基于以下深层考量:该层级的特征图在空间分辨率与语义抽象程度之间达到了最优权衡状态。具体而言,中间层既保留了充足的高频空间信息(如缺陷边缘、纹理细节),足以支持微小缺陷的精确定位,同时又通过前层网络的逐级抽象积累了丰富的高级语义表征(如绝缘子整体结构、背景场景理解),为缺陷的语义判别提供了坚实基础。在此层级应用大核卷积能够在计算效率与建模能力之间取得最佳平衡:一方面,相较于浅层的高分辨率特征图,中间层的下采样特征显著降低了大核卷积的计算开销;另一方面,相较于深层网络的过度抽象表征,中间层仍保留了足够的空间结构信息,使得大核卷积能够有效捕捉长距离空间依赖,显著提升模型对微弱缺陷的判别能力与鲁棒性。C3K2_LS模块的详细网络架构如图3所示。

3.3 ConverseUp上采样模块

原始YOLOv11n模型颈部网络采用传统的最近邻插值上采样算子。该方式为固定非学习型插值,仅通过邻近像素复制完成特征图放大,易产生锯齿状伪影与纹理失真,且无法恢复下采样过程中丢失的边缘、纹理等精细特征信息。对于绝缘子缺陷这类依赖清晰轮廓与细微纹理判别的小目标缺陷,传统上采样会造成不可逆的细节损失,直接制约模型检测精度。

在目标检测网络的上采样模块设计中,如何有效恢复下采样过程中丢失的精细特征信息是

提升小目标检测性能的关键问题。传统上采样方法如最近邻插值和双线性插值虽计算简单,但固定插值核难以适应复杂场景特征,易导致边缘模糊与纹理失真^[24]。近年来,学习型上采样方法受到广泛关注,Wang等^[25]提出了一种基于内容自适应的上采样算子,通过学习空间变化的插值核实现特征图的高效重建,在语义分割任务中取得了显著效果,但其插值核学习缺乏对下采样退化过程的显式建模。Shi等^[26]将亚像素卷积引入超分辨率重建,通过像素重排操作实现高效上采样,然而该方法的特征恢复能力依赖于前置卷积层的特征提取质量,对于下采样过程中已丢失的细微边缘信息难以有效补偿。上述研究表明,现有上采样方法多聚焦于插值方式或特征重排的改进,缺乏将下采样过程建模为特征退化并对其进行显式逆向重建的机制,难以满足绝缘子微小缺陷检测对边缘与纹理细节精确恢复的需求。

为解决上采样过程中精细特征丢失问题,本文在颈部网络中以ConverseUp可学习上采样模块替换原始Upsample算子。与转置卷积不同,ConverseUp将下采样过程视作一次特征退化,通过正则化最小二乘优化在频域实现退化过程的逆向重建,能够更精准地恢复高分辨率特征细节。实验结果表明,单独引入ConverseUp即可使破损类AP、闪污类AP及mAP均获得明显提升,同时有效提高精确率和召回率,证明该模块能够显著恢复下采样丢失的细微缺陷信息,改善边缘与纹理重建效果。

ConverseUp模块结构(图4)是一个双分支融合模型。它接收一个低分辨率的特征图 x ,通过两条独立的路径对其进行上采样,最后将两条路径的结果相加得到最终的输出。Converse2D算子进行高质量、可学习的上采样;Interpolate是标准的插值路径,提供平滑的基础特征。

Converse2D算子的推导过程如下^[27]:对于单个特征映射 $X \in \mathbb{R}^{H \times W}$,其中 H 和 W 分别表示特征




图4 ConverseUp上采样模块

Fig. 4 ConverseUp upsampling module

映射的高度和宽度,卷积核 $K \in \mathbb{R}^{k_h \times k_w}$,步长为 s ,特征映射为 $Y \in \mathbb{R}^{h' \times w'}$,该过程可以表示为:

$$Y = (X \otimes K) \downarrow_s. \quad (1)$$

目标是在给定观察到的 Y 、卷积核 K 和步幅 s 的情况下重建 X ,其可以表示为:

$$X = \mathcal{F}(Y, K, s). \quad (2)$$

将 X 的恢复表示为一个通过最小化实际输出 Y 和重构输出 $(X \otimes K) \downarrow_s$ 之间的误差来寻求近似解的优化问题。据此,将该优化问题定义为:

$$X^* = \arg \min_X \|Y - (X \otimes K) \downarrow_s\|_F^2. \quad (3)$$

由于问题的不适定性,可能导致不稳定的解。为了使解稳定,引入了一个二次正则化项:

$$X^* = \arg \min_X \|Y - (X \otimes K) \downarrow_s\|_F^2 + \lambda \|X - X_0\|_F^2. \quad (4)$$

目标函数中的第一项确保对估计的 X 执行卷积和下采样运算时,结果近似于观察到的 Y 。第二项充当正则化,以防止过拟合并将解提升到接近 x_0 。 x_0 的两个简单选择如下所示:

$$X_0 = \begin{cases} 0 \\ \text{Interp}(Y, s) \end{cases}, \quad (5)$$

其中 $\text{Interp}(Y, s)$ 表示应用于 Y 的比例因子为 s 的插值运算。

解决方程中的优化问题可以得到 X 的闭合解:

$$X^* = F^{-1} \left(\frac{1}{\lambda} \left(L - \overline{F_K} \odot_s \frac{(F_K L) \downarrow_s}{|F_K|^2 \downarrow_s + \lambda} \right) \right), \quad (6)$$

式中: $L = \overline{F_K} F_{Y \uparrow_s} + \lambda F_{X_0}$; $F(\cdot)$ 表示快速傅立叶变换(FFT); $F^{-1}(\cdot)$ 表示逆FFT; $\overline{F_K}$ 表示卷积核 K 的 F_K 的复共轭; $|F_K|^2 = \overline{F_K} \odot F_K$ 表示核 K 的傅里叶变换的元素平方幅度; $F_{Y \uparrow_s}$ 表示标准 s 倍上采样 Y 的FFT。运算符 $\odot_s$ 表示应用于 $s \times s$ 不同块的逐个元素乘法; $\downarrow_s$ 表示对 $s \times s$ 块求平均的不同块下采样算子;符号 $\uparrow_s$ 指的是标准的上采样算子。

为验证 ConverseUp 模块对高分辨率细节信息的重建精度,本文参考 Huang 等^[27]在图像超分辨率任务中的定量评估结果。如表1所示,在 Set5 和 Urban100 数据集上,采用 Converse2D(即 ConverseUp 核心算子)的 SRResNet 在 $\times 4$ 超分辨率任务中较 Pixelshuffle、最近邻插值(Nearest

Interpolation)、及转置卷积(ConvT)均有提升。上述结果表明,ConverseUp 通过正则化最小二乘逆向重建机制,能够有效恢复下采样过程中丢失的高频细节信息。Converse2D 在超分辨率任务中优于传统上采样方法,PSNR 提升 0.01~0.04 dB。

表1 不同上采样方法在超分辨率任务中的定量对比

Tab.1 Quantitative comparison of different upsampling methods in super-resolution tasks

上采样方法	PSNR/dB			
	Set5	Set14	BSD100	Urban100
Pixelshuffle	32.26	28.74	27.65	26.33
Nearest Interpolation	32.26	28.77	27.65	26.36
ConvT	32.24	28.74	27.64	26.33
Converse2D	32.26	28.78	27.66	26.36

4 实验

4.1 实验数据集建立

本实验所采用的数据集为电力线绝缘子缺陷数据集(PL Insulator Defect Dataset),数据集来源于 Roboflow Universe 平台。该数据集共包含 2 053 张图像,图像数据按照 7:2:1 划分训练集、验证集和测试集;数据增强后共有 4 927 张图片,用于目标检测任务,标注包含“损坏”(Broken)、“闪络污染”(Flashover-pollution)和“绝缘子”(Insulator)3 个类别。为了提升模型的泛化能力和鲁棒性,防止训练过拟合,该数据集在训练时配置了丰富的数据增强策略,设定每张训练样本随机生成 3 个增强后输出,从而有效扩充了训练规模。具体的增强操作组合了几何变换(包括水平翻转、顺时针与逆时针 90° 旋转,以及 0%~21% 的随机裁剪缩放)与像素级扰动(包括 $\pm 15^\circ$ 范围内的色调调整、最高 2.5 pixel 的模糊处理和高达 1.01% 的噪声注入)。

数据集中 3 类缺陷的具体形态特征如图 5 所示。损坏主要表现为绝缘子瓷件的自爆破损,包括局部碎裂、贯穿性裂纹及瓷件脱落等形态,缺陷区域呈不规则碎片状;闪络污染由电弧放电或长期污秽积累所致,表现为绝缘子表面的黑褐色烧灼痕迹、树状放电通道或大面积污秽覆盖,缺陷与瓷件本体颜色对比度低,且常沿伞裙呈条状或




图5 绝缘子缺陷图示例

Fig. 5 Example of insulator defect images

片状分布;绝缘子作为正常类别,用于区分背景与目标,但标注中亦包含部分疑似缺陷的模糊样本,增加了分类难度。

4.2 实验环境与实验参数

本实验使用的CPU为Intel i5 13400f,显卡为24G显存的4090D,操作系统为Windows11,CUDA版本为12.8。训练次数为200次,批量大小为64,优化器选用Adam,初始学习率为0.01,图片尺寸为640×640。

4.3 评估指标

本实验使用精确率、召回率、平均精度均值等指标系统地评价模型。表2混淆矩阵显示了模型预测时的类别分布结果。

表2 混淆矩阵
Tab. 2 Confusion matrix

	Predicted 0	Predicted 1
Actual 0	TN	FP
Actual 1	FN	TP

精确率是指模型预测为正样本的样本中,实际上为正样本的比例,可以表示为:

$$\text{Precision} = \frac{TP}{TP + FP}, \tag{7}$$

式中:TP(True Positive)表示正确预测的正样本数量,FP(False Positive)表示错误预测为正样本的负样本数量。

召回率衡量的是所有真实正类样本中被成功检测出的比例:

$$\text{Recall} = \frac{TP}{TP + FN}, \tag{8}$$

式中,FN(False Negative)表示错误预测为负样本的正样本数量。

平均精度(AP)用于评估单个类别的检测性能,而平均精度均值(mAP)则是所有类别的AP取平均,衡量模型整体的检测能力,如式(9)所示:

$$\text{mAP} = \frac{1}{N} \sum AP. \tag{9}$$

4.4 消融实验

为了进一步了解不同改进模块对YOLOv11n模型的影响,在绝缘子缺陷数据集上进行消融实验,结果如表3所示。其中“√”表示采用该改进方案,“×”表示不采用该改进方案。第1组实验为原始YOLOv11n模型;第2组实验用C3K2_DFF模块替换原始的C3K2模块;第3组在主干网络中间层引入C3K2_LS模块;第4组采用ConverseUp上采样算子;第5、6、7组为3种改进的两两组合;第8组同时采用3种改进。

实验结果表明,单独引入C3K2_DFF模块时,模型对破损、闪污类目标的AP及mAP均出现小幅下降,但精确率有所提升,说明该模块在增强特征判别性的同时,对小目标检测灵敏度略有削弱;单独引入C3K2_LS模块时,模型对绝缘子类目标AP略有提升,但破损、闪污类AP小幅下降,mAP微降,表明该模块对背景抑制与特征轻量化具有一定作用,但对缺陷目标检测性能影响有限;而单独采用ConverseUp上采样算子时,模型对破损、闪污类目标的AP分别提升0.3%

表 3 基于改进 YOLOv11n 的绝缘子缺陷检测消融实验结果

Tab. 3 Experimental results of insulator defect detection ablation based on improved YOLOv11n

组别	改进			AP/%			mAP/%	Precision/%	Recall/%
	C3K2_DFF	C3K2_LS	ConverseUp	破损	闪污	绝缘子			
1	×	×	×	0.605	0.634	0.863	0.700	0.802	0.653
2	✓	×	×	0.586	0.628	0.865	0.693	0.832	0.644
3	×	✓	×	0.597	0.629	0.866	0.697	0.814	0.651
4	×	×	✓	0.608	0.642	0.860	0.704	0.820	0.660
5	✓	✓	×	0.608	0.624	0.865	0.699	0.816	0.647
6	✓	×	✓	0.595	0.619	0.869	0.694	0.815	0.654
7	×	✓	✓	0.634	0.627	0.863	0.708	0.844	0.646
8	✓	✓	✓	0.637	0.645	0.863	0.715	0.859	0.656

注:粗体数字表示最优值

和 0.8%,mAP 提升 0.4%,召回率提升 1.8%,说明该模块可有效增强小目标特征的上采样还原能力,提升缺陷目标检测召回率。

在两组组合实验中,C3K2_DFF 与 C3K2_LS 模块组合后,模型对破损类目标的 AP 恢复至原始模型水平,mAP 较单模块使用时略有回升,体现出二者在特征增强方面的有限互补性;C3K2_DFF 与 ConverseUp 组合后,模型对闪污类目标的 AP 出现下降,mAP 略低于原始模型,表明二者在特征提取与上采样环节存在部分冲突;而 C3K2_LS 与 ConverseUp 组合后,模型对破损类目标的 AP 提升 2.9%,mAP 提升 0.8%,精确率提升 4.2%,说明二者在特征轻量化与上采样还原方面形成了有效协同,显著提升了模型

对破损缺陷的检测性能。

当同时采用 C3K2_DFF、C3K2_LS 与 ConverseUp 三种改进模块时,模型在各指标上均取得最优表现:破损类 AP 提升 3.2%、闪污类 AP 提升 1.1%,mAP 提升 1.5%,精确率提升 5.7%,召回率基本保持稳定,这表明 3 个模块在特征增强、轻量化与上采样环节形成了高效协同,全面提升了模型对绝缘子缺陷的检测精度与泛化能力。

为了更直观地观察原始 YOLOv11n 和改进模型在本文数据集上的表现,选取一组绝缘子缺陷图片在两个不同的模型上面进行检测,结果如图 6 所示。可以看到,原始模型存在一些漏检和误检的问题,改进后的模型在检测方面较为准确。




图 6 两种算法检测结果对比

Fig. 6 Comparison of detection results of the two algorithms

4.5 误差分析

为深入剖析模型改进前后的检测误差特性,

本文基于测试集的归一化混淆矩阵(图 7)进行定量对比分析。混淆矩阵的行代表预测类别,列代

表真实类别,对角线元素表示正确分类比例,非对角线元素反映各类误差分布。

对比改进前后的归一化混淆矩阵可见,改进模型在保持损坏(Broken)缺陷正确检出率(62%)不变的同时,将背景误判为损坏的比例从30%显著降至23%,说明 ConverseUp 模块对破损边缘细节的精确重建有效抑制了复杂背景干扰;闪络污染(Flashover-pollution)的正确率由60%微升至61%,且真实污染被误判为背景的比例从40%降至39%,反映出 C3K2_LS 模块的

全局-局部特征融合增强了对微弱污染特征的敏感度,更符合电力巡检“宁可误检、不可漏检”的安全需求;绝缘子(Insulator)正常类别的正确率从84%提升至85%,整体背景误检率由31.0%降至30.0%,验证了“See Large, Focus Small”策略与逆向重建机制的协同优化效果。总体而言,改进模型在降低背景误检和提升缺陷召回率之间取得了更好的平衡,尤其在破损缺陷的边缘判别和闪络污染的特征捕获方面改进明显。




图 7 混淆矩阵对比

Fig. 7 Confusion matrix comparison

4.6 对比实验

为了更全面地评估模型性能,将本文方法与YOLOv5、YOLOv8等其他模型进行对比。对比实验结果如表4所示。表中展示了YOLOv5、

YOLOv6、YOLOv8、YOLOv9t、YOLOv10、YOLOv11n及本文改进模型(Ours)在绝缘子缺陷检测任务上的性能对比。

选择的基准模型YOLOv11n对绝缘子缺陷

表 4 对比实验结果

Tab. 4 Results of the comparative experiment

模型	Precision/%	Recall/%	AP/%			mAP/%
			破损	闪污	绝缘子	
YOLOv5	0.784	0.629	0.590	0.564	0.860	0.671
YOLOv6	0.801	0.596	0.548	0.538	0.859	0.648
YOLOv8	0.818	0.635	0.598	0.598	0.859	0.685
YOLOv9t	0.828	0.639	0.635	0.625	0.865	0.708
YOLOv10	0.800	0.632	0.597	0.592	0.857	0.682
YOLOv11n	0.802	0.653	0.605	0.634	0.863	0.700
Ours	0.859	0.656	0.637	0.645	0.863	0.715

注:粗体数字表示最优值

检测的平均精度高于其他YOLO模型。本文提出方法(Ours)在所有评价指标上均取得了最优结果,精确率达到0.859、召回率为0.656、mAP为0.715,相比次优的YOLOv9t在mAP上提升了0.7个百分点。特别是在“闪络”缺陷检测上,本文方法的AP为0.645,显著优于YOLOv9t的0.625和YOLOv8的0.598,该方法对绝缘子表面细微缺陷具有更强的识别能力,此外,在“破损”和“绝缘子”类别上同样保持领先。

4.7 跨数据集验证

为进一步验证所提出的改进YOLOv11n模型在绝缘子缺陷检测数据集下的检测结果,选择了CPMID数据集和IDID数据集进行验证,实验结果如表5所示。数据集Complex Power-

grid Multi-scenario Insulator Dataset (CPMID)由Wang等^[28]构建并开源发布于GitHub平台,共包含7 712张高质量标注图像,涵盖72 596个实例,涉及绝缘子串、破损缺陷和闪络缺陷3类目标,并系统性地呈现了密集分布、目标重叠、遮挡、跨尺度变化、复杂背景干扰及小目标等实际检测挑战。IDID(Insulator Defect Image Dataset)是Kaggle平台公开用于绝缘子缺陷检测竞赛的图像数据集,共包含1 600张无人机航拍高分辨率图像,涵盖正常绝缘子、破损缺陷及闪络缺陷等类别,并提供了边界框与分割掩膜标注。该数据集具有类别不平衡、缺陷区域占比小、背景复杂多样等特点,被广泛应用于输电线路绝缘子缺陷智能检测算法的基准测试与性能评估。

表5 不同数据集检测结果对比

Tab. 5 Comparison of detection results from different datasets

Datasets	Models	Precision/%	Recall/%	mAP/%
Ours	YOLOv11n(Original)	0.802	0.653	0.700
	YOLOv11n(Improved)	0.859	0.656	0.715
CPMID	YOLOv11n(Original)	0.773	0.664	0.718
	YOLOv11n(Improved)	0.826	0.669	0.734
IDID	YOLOv11n(Original)	0.898	0.889	0.950
	YOLOv11n(Improved)	0.929	0.934	0.970

由表5数据可知,在与本文所使用数据集特征相似的CPMID数据集上,改进模型的平均精度实现了1.6%的小幅提升。在原本检测精度就比较高的IDID数据集上也有所提升,改进模型的召回率与平均精度均得到了大幅提升,其中召回率提升了4.5%,平均精度实现了2.0%的提升,表明本文改进策略对于在不同数据集上的绝缘子缺陷检测有良好的泛化能力。

5 结 论

针对复杂背景下绝缘子破损、闪污等微弱缺陷易漏检、特征易被背景稀释的问题,本文提出了一种基于改进YOLOv11n的绝缘子缺陷检测算法。改进算法通过引入C3K2_DFF动

态特征融合模块,有效缓解了特征融合过程中的关键信息稀释问题;在骨干网络嵌入C3K2_LS大核注意力模块,扩展了全局感受野并增强了缺陷与背景的区分能力;采用ConverseUp可学习上采样算子替换传统插值上采样,恢复了下采样中丢失的缺陷边缘与纹理细节。在绝缘子缺陷数据集上的实验结果表明,改进模型的mAP提升1.5%,破损类AP提升3.2%,闪污类AP提升1.1%,精确率提升5.7%,相比于原始YOLOv11n具有更优的检测性能,对比YOLO系列模型精度均保持领先。在3种不同的绝缘子缺陷数据集上的测试结果表明,改进YOLOv11n模型精度优于原始YOLOv11n模型。该模型能够在铁塔、天空等复杂背景下精准识别绝缘子微弱缺陷。

参 考 文 献:

- [1] ZHANG Z Y, HUANG S H, LI Y X, *et al.* Image detection of insulator defects based on morphological processing

- and deep learning [J]. *Energies*, 2022, 15(7): 2465.
- [2] ZHANG Y L, XUE X H, MU L X, *et al.* Detection of missing insulators in high-voltage transmission lines using UAV images [J]. *Drones*, 2026, 10(3): 213.
- [3] LIU Z Y, WU G P, HE W S, *et al.* Key target and defect detection of high-voltage power transmission lines with deep learning [J]. *International Journal of Electrical Power & Energy Systems*, 2022, 142: 108277.
- [4] WANG H, YANG Q, ZHANG B L, *et al.* Deep learning based insulator fault detection algorithm for power transmission lines [J]. *Journal of Real-Time Image Processing*, 2024, 21(4): 115.
- [5] SHI W X, HUANG Z, HUANG H H, *et al.* LOEN: Lensless opto-electronic neural network empowered machine vision [J]. *Light: Science & Applications*, 2022, 11(1): 121.
- [6] LUO M C, JIANG M R, SHASTRI B J, *et al.* Highly scalable machine vision enabled with meta-optics-based ultra-wide neural network [J]. *eLight*, 2026, 6(1): 10.
- [7] ZHAI Y P, FU X X, SU Q, *et al.* SparseFocus: Learning-based one-shot autofocus for microscopy with sparse content [J]. *Light: Advanced Manufacturing*, 2026, 7(1): 45-59.
- [8] 刘子洋,徐慧英,朱信忠,等. Bi-YOLO:一种基于YOLOv8n改进的轻量化目标检测算法[J]. *计算机工程与科学*, 2024, 46(8): 1444-1454.
- LIU Z Y, XU H Y, ZHU X Z, *et al.* Bi-YOLO: An improved lightweight object detection algorithm based on YOLOv8n [J]. *Computer Engineering & Science*, 2024, 46(8): 1444-1454. (in Chinese)
- [9] 彭雪玲,林珊玲,林志贤,等. 改进的YOLOv5s太阳能电池片缺陷检测算法[J]. *液晶与显示*, 2024, 39(2): 237-247.
- PENG X L, LIN S L, LIN Z X, *et al.* Defect detection algorithm of improved YOLOv5s solar cell [J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(2): 237-247. (in Chinese)
- [10] 杨彦萍,高军伟,刘兆龙,等. 基于改进YOLO11的印刷电路板表面缺陷检测算法[J]. *液晶与显示*, 2025, 40(10): 1545-1556.
- YANG Y P, GAO J W, LIU Z L, *et al.* Surface defect detection on printed circuit boards based on improved YOLO11 [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(10): 1545-1556. (in Chinese)
- [11] 谢星星,程臻,姚艳清,等. 动态特征融合的遥感图像目标检测[J]. *计算机学报*, 2022, 45(4): 735-747.
- XIE X X, CHENG G, YAO Y Q, *et al.* Dynamic feature fusion for object detection in remote sensing images [J]. *Chinese Journal of Computers*, 2022, 45(4): 735-747. (in Chinese)
- [12] GUO M H, LU C Z, LIU Z N, *et al.* Visual attention network [J]. *Computational Visual Media*, 2023, 9(4): 733-752.
- [13] LIU W Z, LU H, FU H T, *et al.* Learning to upsample by learning to sample [C]//*Proceedings of the IEEE/CVF International Conference on Computer Vision*. Paris, France: IEEE, 2023: 6004-6014.
- [14] LIU S T, HUANG D, WANG Y H, *et al.* Learning spatial fusion for single-shot object detection [J/OL]. *arXiv*, 2019: 1911.09516.
- [15] WANG Q L, WU B G, ZHU P F, *et al.* ECA-Net: Efficient channel attention for deep convolutional neural networks [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, WA, USA: IEEE, 2020: 11531-11539.
- [16] ZHANG H, WU C R, ZHANG Z Y, *et al.* ResNeSt: Split-attention networks [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, LA, USA: IEEE, 2022: 2735-2745.
- [17] 周颖,许士博,陈海永,等. 融合多尺度特征与注意力的太阳能电池表面缺陷检测[J]. *光学精密工程*, 2024, 32(14): 2286-2298.
- ZHOU Y, XU S B, CHEN H Y, *et al.* Solar cell defect detection network combining multiscale feature and attention [J]. *Optics and Precision Engineering*, 2024, 32(14): 2286-2298. (in Chinese)
- [18] 陈名渝,谢玥辰,吕雄涛,等. 冷轧钢表面与内部缺陷检测研究[J]. *中国光学(中英文)*, 2024, 17(4): 823-833.
- CHEN M Y, XIE Y C, LV X T, *et al.* Detection of surface and internal defects in cold rolled steel [J]. *Chinese Optics*, 2024, 17(4): 823-833. (in Chinese)
- [19] CAO L, XIAO W, HU Z, *et al.* Detection of citrus huanglongbing in natural field conditions using an enhanced

- YOLO11 framework [J]. *Mathematics*, 2025, 13(14): 2223.
- [20] ZHOU W Q, LIU G. Review of overhead line defect inspection based on deep learning and UAV images [J]. *Electric Power Engineering Technology*, 2024, 43(2): 73-82.
- [21] FENG Z Q, GUO L, HUANG D R, *et al.* Electrical insulator defects detection method based on YOLOv5 [C]// *Proceedings of the 2021 IEEE 10th Data Driven Control and Learning Systems Conference*. Suzhou, China: IEEE, 2021: 979-984.
- [22] 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*, 2023, 43(6): 2319-2330.
- HAO S, 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*, 2023, 43(6): 2319-2330. (in Chinese)
- [23] WANG A, CHEN H, LIN Z J, *et al.* LSNet: See large, focus small [C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, TN, USA: IEEE, 2025: 9718-9729.
- [24] 谢椿辉,吴金明,徐怀宇. 改进YOLOv5的无人机影像小目标检测算法[J]. *计算机工程与应用*, 2023, 59(9): 198-206.
- XIE C H, WU J M, XU H Y. Small object detection algorithm based on improved YOLOv5 in UAV image [J]. *Computer Engineering and Applications*, 2023, 59(9): 198-206. (in Chinese)
- [25] WANG Y H, ZHANG Y, YAO Z, *et al.* Learning content-adaptive upsampling for real-time image super-resolution [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2023, 33(5): 2456-2470.
- [26] SHI W Z, CABALLERO J, HUSZÁR F, *et al.* Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, NV, USA: IEEE, 2016: 1874-1883.
- [27] HUANG X H, LIU S Q, ZHANG K, *et al.* Reverse convolution and its applications to image restoration [C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. Honolulu, HI, USA: IEEE, 2025: 10507-10516.
- [28] WANG Q L, LI E T, CUI S H, *et al.* Cross-scale recognition of dense insulators and defects in complex power grid environments [J]. *Engineering Applications of Artificial Intelligence*, 2026, 164: 113283.

作者简介:



雷德伟,男,硕士研究生,2024年于四川轻化工大学获得学士学位,主要从事目标检测和图像处理方面的研究。
E-mail: 1837913313@qq.com



林国军,男,博士,副教授,2014年于电子科技大学获得博士学位,主要从事人脸识别、图像处理和计算机视觉方面的研究。E-mail: tiemujian123400@163.com