第 52 卷 第 5 期：2240-2252 高电压技术 Vol.52, No.5: 2240-2252
2026 年 5 月 31 日 High Voltage Engineering May 31, 2026
DOI: 10.13336/j.1003-6520.hve.20250441

多层级补偿与三维感知增强的绝缘子缺陷检测算法

孙 航[1,2]，刘晓亮[1]，胡得澳[3]，吴 田[3]，余 梅[2,4]，梁 超[4]
（1. 三峡大学计算机与信息学院，宜昌 443002；2. 三峡大学水电工程智能视觉监测湖北省重点实验室，宜昌 443002；3. 三峡大学电气与新能源学院，宜昌 443002；4. 武汉大学多媒体网络通信工程湖北省重点实验室，武汉 430072）

摘 要：针对现有目标检测模型中，特征在骨干网络至检测头传播过程逐步稀释，导致特征表征能力不足以及传统特征金字塔结构提取的特征判别能力有限，难以有效区分绝缘子缺陷与相似背景干扰的问题，该文提出了多层级补偿与三维感知增强的绝缘子缺陷检测算法。首先，多层级检测头特征差异化补偿框架通过门控激活机制动态融合频域分量信息，实现检测头各层级特征的高低频缺失信息校正，提高了绝缘子缺陷检测的精度。其次，三维感知复用的渐进增强模块通过设计特征空间-通道交互机制构建三维权重矩阵，采用权重复用策略渐进学习多尺度感受野特征，从而提升特征判别能力。实验结果表明，该文提出的算法在构建的绝缘子及其缺陷检测数据集上的均值平均精度为 89.0%，相较于目前 10 种先进的目标检测方法至少提高了 2.7%。该算法对提升基于无人机影像的输电线路绝缘子缺陷的识别性能具有指导意义。

关键词：绝缘子；缺陷检测；多层级补偿；三维感知增强；无人机影像

Multi-level Compensation 3D Perceptual Enhancement Algorithm for Insulator Defect Detection

SUN Hang[1,2], LIU Xiaoliang[1], HU Deao[3], WU Tian[3], YU Mei[2,4], LIANG Chao[4]
(1. College of Computer and Information Technology, China Three Gorges University, Yichang 443002, China; 2. Hubei Key Laboratory of Intelligent Vision Based Monitoring for Hydroelectric Engineering, China Three Gorges University, Yichang 443002, China; 3. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China; 4. Hubei Key Laboratory of Multimedia and Network Communication Engineering, Wuhan University, Wuhan 430072, China)

Abstract: This paper aims to address the issue in existing object detection models that face a gradual attenuation of features during forward propagation from Backbone to Head, leading to insufficient feature representation, and to overcome the limited ability of traditional feature pyramid network (FPN) to effectively learn discriminative features, which hinders the model's capacity to distinguish between insulator defects and the interference of similar background in complex environments. Moerover, a multi-level compensation 3D perceptual enhancement algorithm for insulator defect detection (MC3DPE) is put forward. Specifically, the multi-level detection head feature differentiated compensation (MDFDC) framework employs a gated activation mechanism to dynamically fuse frequency component information, enabling the correction of missing high- and low-frequency information at different levels of detection head, thus improving detection accuracy for insulator defects. The 3D perceptual reutilization progressive enhancement (3DPRPE) module constructs a 3D weight matrix through a space-channel feature interaction mechanism and adopts a weight reuse strategy to progressively learn multi-scale receptive field features, thereby improving feature discrimination capabilities. Experimental results show that, on our constructed insulator and defect detection dataset, the proposed algorithm achieves a mean average precision of 89.0%, surpassing the existing state-of-the-art 10 object detection algorithms by at least 2.7%. The algorithm provides valuable guidance for enhancing the recognition of insulator defects in transmission lines based on UAV imagery.

Key words: insulator; defect detection; multi-level compensation; 3D perceptual enhancement; UAV imagery

---

基金资助项目：国家自然科学基金青年科学基金(51807110)；中国创新创业大赛创新挑战赛(宁波)(2024T008)；多媒体网络通信湖北省重点实验室开放基金(HKLMNCE24KF08)。
Project supported by Young Scientists Fund of National Natural Science Foundation of China(51807110), Major Special Project of China Innovation Challenge (Ningbo)(2024T008), Open Project of Hubei Provincial Key Laboratory of Multimedia Network Communication Engineering(HKLMNCE24KF08).

0　引言

绝缘子作为电力传输系统中输电线路上的关键组件，由于其长期处于恶劣环境中，容易出现各种类型的缺陷与损伤[1-2]。若这些缺陷未能及时检测和修复，可能会导致电力中断，甚至引发严重的安全事故。因此，实现对绝缘子缺陷的高效、精准检测对于保障电力系统的安全稳定运行具有重要的现实意义。

近年来，基于卷积神经网络的目标检测方法[3-5]已广泛应用于绝缘子缺陷检测任务，主要可分为两类：基于两阶段和基于单阶段的目标检测方法。两阶段的目标检测算法如 Fast R-CNN[6]、Faster R-CNN[7]是通过先生成目标候选区域，然后对这些候选区域进行分类和回归实现目标的定位与识别。目前，基于两阶段的目标检测算法在电力设备缺陷检测领域取得了较好的检测效果。例如，Gu 等人[8]将深层残差网络作为前置特征提取网络，以增强模型对特征的提取能力，从而提高了对架空线路销钉的识别率。Zhao 等人基于 Faster R-CNN 集成了特征金字塔(feature pyramid network, FPN)反卷积模型[9]，以捕捉更多的语义信息，进而增强了模型对绝缘子的定位能力。尽管基于两阶段检测器的目标检测算法在检测精度方面表现良好，但这些算法具有较高的计算复杂度，导致推理速度下降，难以满足实时检测任务的需求。

随着深度学习技术的发展，研究人员提出了基于单阶段的目标检测方法，通过一次前向传播直接预测目标的类别和位置信息。Redmon J 等人首次提出了 YOLO(You Only Look Once)算法[10]，通过端到端的方式，在确保检测精度的同时取得了较快的检测速度。Jocher G 等人提出了 YOLOv5，通过设计高效的网络架构增强了算法对不同尺寸目标的检测性能[11]。目前，大多数研究人员普遍选用基于YOLO系列的目标检测方法作为基准模型[12-13]，以实现对绝缘子缺陷的实时检测。例如，Song 等人提出了 Deformable YOLOX[14]，通过在颈部网络中实现跨通道交互增强，提升了对绝缘子图像中密集小目标的检测精度。Luo 等人基于 YOLOX 在颈部网络中结合金字塔压缩注意力(pyramid squeeze attention, PSA)注意力机制以增强细节特征的表达能力[15]，提高了对小目标缺陷的检测能力。Li 等人提出了一种轻量级绝缘子缺陷检测模型 LiteYOLO-ID[16]，通过设计轻量级的骨干和颈部网络，有效平衡了模型的参数量与检测精度。

尽管上述方法在绝缘子缺陷检测领域取得了较好的成效，但仍存在以下局限性：

1）现有的目标检测算法忽略了信息传递过程中存在的特征稀释和丢失问题，导致输入检测头特征的表达能力不足，限制了模型的检测性能。Wang 等人在主干网络中嵌入了集成学习与聚合网络(ensemble learning and aggregation network, ELAN)[17]，通过多分支结构实现了多尺度特征的聚合，从而提高了目标检测的精度。Huang 等人设计了一种基于空间可变形卷积的骨干网络[18]，通过引入动态卷积核，提升了对表面缺陷的特征提取能力。Wang 等人将坐标注意力机制集成到 YOLOX 的主干网络中[19]，实现了对特征方向及位置信息的有效感知，改善了模型对于绝缘子缺陷特征的捕获能力。这些方法通过设计高效的骨干提取网络以捕获更丰富的特征信息。然而，随着卷积神经网络深度的增加，骨干网络深层更倾向于捕捉高层语义特征，这会导致输入图像的高频细节与低频结构特征在语义抽象过程中逐渐衰减。另外，颈部网络无法有效恢复特征编码过程中丢失的细节与结构信息，使得输入检测头特征的表达能力受限，进而导致了检测精度的下降。因此，如何有效缓解骨干网络向检测头信息传递过程中的特征衰减和信息丢失，仍是绝缘子缺陷检测研究中的重要挑战。

2）大多数颈部网络难以提取到更具判别性的特征表示，导致模型在复杂背景干扰下难以有效区分不同类别的绝缘子缺陷。Lin 等人提出了特征金字塔结构[20]，通过自顶向下的采样及横向连接实现了多尺度的特征提取，优化了网络对不同尺度目标的检测性能。Zhang 等人设计了一种特征金字塔的变体密集连接特征金字塔网络(densely connected-feature pyramid network, DC-FPN)[21]，通过密集连接增强了分层特征结构中的信息流动，提高了网络对于绝缘子缺陷的定位能力。He 等人构建了一种特征融合方法 ResPANet[22]，采用残差跳跃连接优化了低分辨率特征的信息表示，提升了模型对小目标缺陷的检测性能。这些方法通常作为目标检测网络的颈部网络，以提高不同分辨率特征的特征表达能力。然而，在复杂背景及缺陷多样化的情况下，颈部网络难以有效建立不同缺陷特征之间以及前景目标与背景噪声之间的决策边界，导致模型在复杂背

景下对绝缘子缺陷的检测过程中出现了不同程度的误检和漏检现象。因此，如何提升颈部网络对于判别性特征的学习能力，以精准识别不同种类的绝缘子缺陷，是绝缘子缺陷检测领域亟待解决的关键问题。

为解决上述问题，本文提出了多层级补偿与三维感知增强的绝缘子缺陷检测算法，通过频域分量信息的缺失校正与三维感知权重的递进复用增强，提升了绝缘子缺陷的检测精度。具体而言，本文设计了一种多层级检测头特征差异化补偿框架，利用多分支网络有效提取高低频特征分量，并通过各层级特征补偿单元对检测头门控实现高低频信息的有效弥补，以增强检测头特征的表达能力，进而提升了缺陷检测的精度。此外，本文构建了一个三维感知复用的渐进增强模块，通过跨空间-通道维度的协同权重分配学习三维感知权重矩阵，并结合权重复用策略，实现多尺度感受野特征的递进式学习，以增强网络的判别能力，在复杂环境下的绝缘子缺陷检测任务中表现出优异的性能。

本文后续章节的结构安排如下。第 1 章介绍了本文所提出的绝缘子缺陷检测算法；第 2、3 章分别通过对比实验和消融实验对算法的性能与有效性进行了评估；最后，第 4 章对全文进行了总结。

1 多层级补偿与三维感知增强的绝缘子缺陷检测算法

在本章中，首先在 1.1 节中介绍所提出的多层级补偿与三维感知增强的绝缘子缺陷检测算法架构，随后在 1.2 节和 1.3 节分别阐述多层级检测头特征差异化补偿框架与三维感知复用的渐进增强模块，最后在 1.4 节描述了训练过程中算法使用的损失函数。

1.1 算法整体架构

针对骨干网络向检测头特征传递过程中的特征稀释现象以及颈部网络在判别性特征学习方面的能力不足，本文提出了一种端到端的多层级补偿与三维感知增强的绝缘子缺陷检测算法。该算法以 RGB 三通道绝缘子图像作为输入，如图 1 所示。

本算法主要由多层级检测头特征差异化补偿框架和三维感知复用的渐进增强模块组成。多层级检测头特征差异化补偿框架通过对频域特征分量的特征编码和门控调制，生成特定化的频域信息表示，以弥补不同层级检测头在高低频信息上的缺失，从而提升缺陷特征的表达能力。三维感知复用的渐进增强模块集成于颈部网络的前向传输路径，通过构建三维感知矩阵，以及权重复用策略优化模型逐步

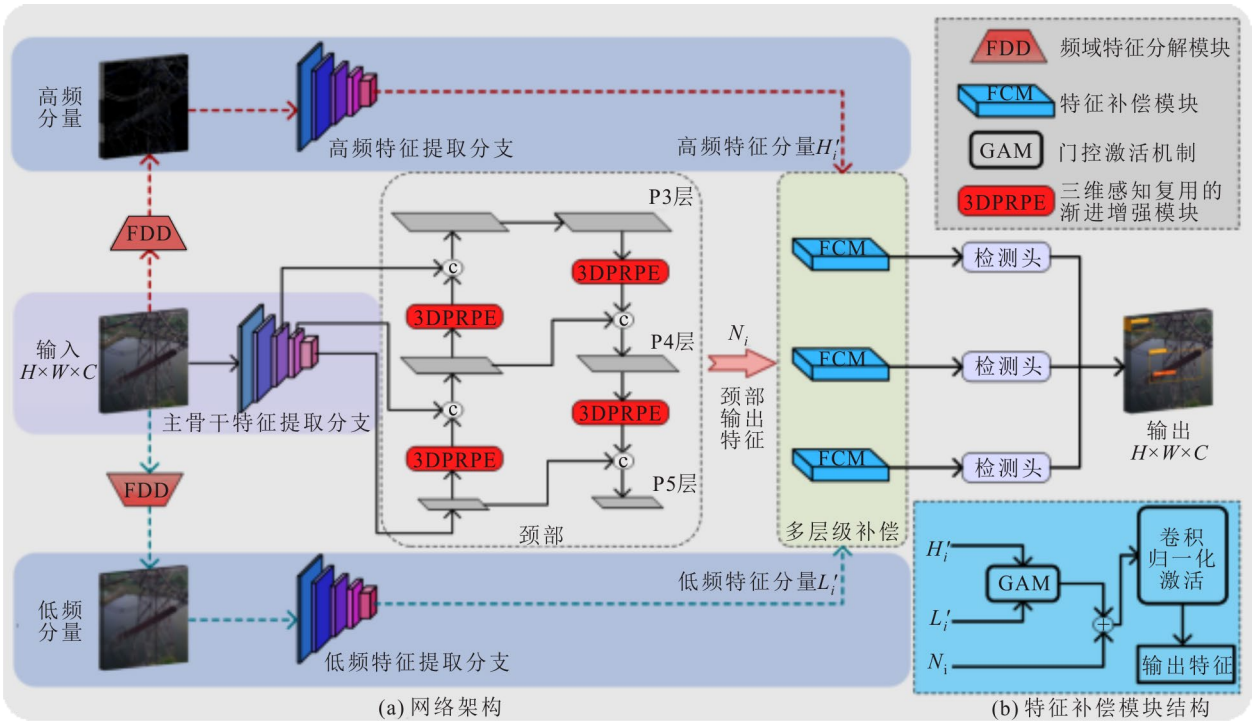


图 1 多层级补偿与三维感知增强的绝缘子缺陷检测算法结构

Fig.1 The overall architecture of our proposed multi-level compensation 3D perceptual enhancement algorithm for insulator defect detection

扩展感受野的多尺度特征学习过程，以克服背景复杂干扰所带来的检测挑战，从而实现绝缘子缺陷的精准识别。最终，检测头输出绝缘子图像中各类缺陷的边界框标注及其分类标签。所提出的训练多层级补偿与三维感知增强的绝缘子缺陷检测算法的训练过程如图 2 所示。其中：F_{D} 为频域分量分解操作；H_1、L_1 分别为高、低频分量；M_{F} 代表多分支特征编码操作；H'_{i+1}、F_i、L'_{i+1} 分别表示高频、主骨干、低频分支网络提取的中间特征；N_{E} 代表颈部特征提取操作；N_i 为颈部输出特征；M_{D} 是多层级特征差异化补偿操作；P_i 表示各层级特征补偿单元输出的特征；H_{E} 为检测头输出操作；L_{total} 为网络训练过程中的损失函数值。

输入： F：绝缘子 RGB 三通道图像；
N_{e}:训练轮数；
输出： F_{out}:绝缘子缺陷检测图像；
1：随机初始化 MC3DPE 参数 θ；
2：**for** i =1, 2, 3, …, N_{e} **do**
3：提取高低频特征分量: $H_1, L_1 = F_{\mathrm{D}}(F)$
4：对各层特征进行编码: $H'_{i+1}, F_i, L'_{i+1} = M_{\mathrm{F}}(H_1; F; L_1)$
5：将编码特征输入至特征金字塔，并依次经过三维感知复用的渐进增强模块和路径聚合网络
6：提取路径聚合网络各层级输出特征 $N_i = N_{\mathrm{E}}(F_i)$
7：执行多层级特征差异化补偿: $P_i = M_{\mathrm{D}}(H'_{i+1}; L'_{i+1}; L'_{i+1})$
8：输出绝缘子缺陷检测结果图像: $F_{\mathrm{out}} = H_{\mathrm{E}}(P_i)$
9：计算损失函数值 L_{total}
10：反向传播更新参数 θ
11：**end for**
12：**Return** θ

图 2　训练多层级补偿与三维感知增强的绝缘子缺陷检测算法

Fig.2　Training process of multi-level compensation and proposed MC3DPE algorithm for insulator defect detection

1.2　多层级检测头特征差异化补偿框架

在绝缘子缺陷识别任务中，缺陷的纹理形状特征及缺陷在绝缘子上的位置信息对于绝缘子缺陷的精确识别至关重要。然而，当前的绝缘子缺陷检测方法主要依赖于骨干网络通过连续堆叠的卷积层进行特征提取。随着网络深度的增加，网络深层倾向于捕捉高级别的语义信息，这会导致图像的高频细节与低频结构特征在深层的语义抽象中稀释。此外，这些特征难以通过颈部网络完全恢复，并且在信息传递过程中进一步衰减，这限制了检测头捕获特征的有效性，最终导致缺陷检测精度的下降。

为解决上述问题，本文提出了一种基于多分支特征提取网络和多层级特征分量补偿模块构成的多层级检测头特征差异化补偿框架。该框架能够有效分离和提取绝缘子 RGB 图像中的高低频特征分量，其中高频特征分量的有效提取有利于模型捕获缺陷目标的边缘和纹理特征，而低频特征分量的学习则增强了网络对图像结构信息的理解。随后，通过门控机制调控高低频特征分量的整合，并根据不同层级检测头对不同尺度目标的频域特征需求，实施针对性的高低频信息校正，从而增强检测头对多种绝缘子缺陷目标的纹理等外观特征的捕获能力，以提升对绝缘子缺陷的定位和识别能力。

(1)多分支特征提取网络(multi-branch feature extraction network, MFEN)：本文设计了一种多分支网络结构用于对绝缘子图像进行特征提取。该网络结构由高频特征提取分支(H-Backbone)、主骨干特征提取分支(M-Backbone)以及低频特征提取分支(L-Backbone)组成。首先，将绝缘子 RGB 三通道图像 $F \in \mathbf{R}^{3\times H\times W}$ 输入频域分量分解模块(frequency domain decomposition, FDD)实现对绝缘子可见光图像高、低频特征分量的解耦。FDD 模块基于拉普拉斯金字塔分解理论构建，频域分量分离具体过程可由下式描述：

$$\begin{cases} F_l(i,j) = \sum_{m=-2}^{2}\sum_{n=-2}^{2} w(m,n) F_{l-1}(2i+m, 2j+n) \\ L_l = P_{\mathrm{U}}(P_{\mathrm{D}}(F_l)) \\ H_l = F - L_l \end{cases} \tag{1}$$

式中：$w(m,n)$ 表示服从高斯分布的低通滤波器；$F_{l-1}(2i+m, 2j+n)$ 为第 $l-1$ 层金字塔特征在位置 $(2i+m, 2j+n)$ 处的值；F_l 是第 l 层的金字塔图像经过高斯内核卷积得到的特征图；P_{D} 与 P_{U} 分别为下采样与上采样操作；L_l 代表金字塔中第 l 层的低频特征分量；H_l 为金字塔中第 l 层的高频特征分量。

本文将 F、H_1、L_1 分别输入主骨干分支、高频特征提取分支、低频特征提取分支网络中进行独立的特征提取。其中，主骨干特征提取分支由 CSPDarknet53 构成。同时，本文设计了基于平均池化与最大池化并行的高、低频特征提取网络，以增强模型对于结构信息和细节特征的捕获能力，从而完成对不同频域分量的特征编码。由于低频特征提取网络的提取过程与高频特征提取网络的提取过程类似，本文以高频特征提取网络的特征提取过程为例，首先，对输入的高频特征分量 H_1 分别执行平均池化和最大池化操作，过程表示如下：

$$Z_{i+1} = \{A_{\mathrm{P}}(H'_i) \mid i = 1,2,3\} \tag{2}$$

$$E_{i+1} = \{M_{\mathrm{P}}(H'_i) \mid i = 1,2,3\} \tag{3}$$

式中：H_1' 表示绝缘子 RGB 图像经过频域分量分解模块解耦得到的高频特征分量，反映了图像中目标的边缘纹理等信息，具体可以表示为 $H_1'=H_1$；A_{P}、M_{P} 分别表示池化核大小为 2 的平均池化和最大池化操作。

然后，本文将来自不同池化操作得到的特征图 Z_{i+1}、E_{i+1} 通过特征整合，以增强频域特征的信息表示。

$$H'_{i+1}=\begin{cases}C_{\mathrm{A}}(Z_{i+1}+E_{i+1}), & 1\le i<\kappa\\ S_{\mathrm{A}}(C_{\mathrm{A}}(Z_{i+1}+E_{i+1})), & i\ge\kappa\end{cases} \tag{4}$$

式中：κ 是一个常数；C_{A} 表示通过一个核大小为 1，步长为 1，无填充的卷积操作，随后进行批量标准化和 SiLU 激活处理，以实现通道维度的转换；此外，S_{A} 代表空间注意力机制，以进一步增强高频特征图中重要像素的表达并抑制冗余特征的表示。

(2)多层级特征分量补偿模块：本文提出的多层级特征分量补偿模块由 3 个不同层级的特征分量补偿单元组成。首先，将多分支特征提取网络获取的对应层级的高频特征分量、低频特征分量以及路径聚合网络的中间特征输入到相应层级的特征补偿单元中。每个层级的特征补偿单元先经过门控学习机制动态融合高、低频特征分量后，生成针对相应层级检测头的频域信息表示，实现局部纹理和全局结构信息的有效整合。随后，利用频域信息表示对颈部网络的输出特征进行高低频信息补充，以弥补缺失信息并优化检测头的特征表达。

$$\begin{cases}Q_i=G_i(H_i',L_i')\\ T_i=C_{\mathrm{B}}(N_i+Q_i)\end{cases} \tag{5}$$

式中：$i=3,4,5$；G_i 为第 i 层级的门控激活机制，用于融合频域特征分量后得到频域特征表示 Q_i；将 Q_i 与 N_i 通过特征补偿后输出 T_i，实现高低频特征信息的缺失校正，增强了网络对于缺陷目标的有效感知能力；N_i 表示颈部网络中第 i 层级的特征；C_{B} 代表包含一个核大小为 3 的标准卷积、批量标准化和 SiLU 激活操作。门控激活机制的处理过程可用下式描述：

$$\begin{cases}Y_i=C_{\mathrm{B}}(C_{\mathrm{C}}(H_i',L_i'))\\ \omega_i=\sigma(C_{\mathrm{D}}(Y_i))\\ Q_i=H_i'\otimes\omega_i+L_i'\otimes(1-\omega_i)+H_i'+L_i'\end{cases} \tag{6}$$

式中：C_{C} 表示沿通道方向的级联操作；Y_i 是高、低频特征分量经过初步融合后的特征图；C_{D} 代表核大小为 1 的卷积操作，用于对特征图作通道维度的转换；σ 为 Sigmoid 激活函数；ω_i 为门控因子；$\otimes$ 代表元素方式的计算乘法。

由于破损(Breakage)缺陷可能表现为小范围的碎裂或大面积的破损，多样化的纹理外观对算法的特征表达能力提出了更高的要求。因此，本文通过对高低频特征分量的分离提取并结合网络门控机制动态整合，生成适配于各个检测头需求的频域信息表示，通过边缘纹理和结构信息的特征弥补与缺失校正，增强了检测头特征的表达能力。

1.3 三维感知复用的渐进增强模块

现有的绝缘子缺陷检测算法主要依赖于颈部网络实现对多尺度特征的信息捕捉，使得模型具备识别不同尺寸缺陷目标的能力。然而，由于绝缘子缺陷检测任务中待识别目标类别存在多样性，且目标与背景之间在颜色与纹理等视觉属性上具有相似性，往往使得模型在区分复杂背景与前景目标，或识别不同类别缺陷目标时，难以精确建立判别边界，导致漏检和误检现象的发生。此外，大多数注意力权重分配方法未能充分考虑特征在空间-通道联合空间上的独特性，降低了模型的鲁棒性。

针对上述问题，本文提出了三维感知复用的渐进增强模块。该模块通过跨空间与通道特征维度的三维感知权重分配，评估空间-通道联合空间中不同特征的重要性。在此基础上，复用三维感知权重逐步优化多尺度感受野特征的学习，使得模型在逐步扩大感受野的过程中，能够有效区分前景目标与复杂背景，以及不同类型缺陷目标之间的差异。三维感知复用的渐进增强模块的结构如图 3 所示。

给定一张特征图 $S\in\mathbf{R}^{C\times H\times W}$ 作为三维感知复用的渐进增强模块的输入。根据图 3 所示的结构，本文详细阐述了三维感知复用的渐进增强模块的处理流程，具体步骤如下：

步骤 1：特征图 S 首先被送入三维感知复用的渐进增强模块中的协同权重分配子模块中进行通道和空间信息的特征聚合，随后通过广播机制交互学习，以构建关于 S 的三维感知权重矩阵，过程如下式所示：

$$\begin{cases}S_{\mathrm{c}}=C_{\mathrm{D}}(R(C_{\mathrm{D}}(P_{\mathrm{G}}(S))))\\ S_{\mathrm{s}}=C_{\mathrm{D}}(R(C_{\mathrm{D}}(S)))\\ \omega=\sigma(S_{\mathrm{c}}\times S_{\mathrm{s}})\end{cases} \tag{7}$$

式中：P_{G} 代表全局平均池化操作；R 表示 ReLU 激活函数；S_{c} 与 S_{s} 分别是经过网络学习优化后的通道、空间特征表示；ω 为三维感知权重。目前，大多数通道权重或空间权重分配方法仅单一地考虑了

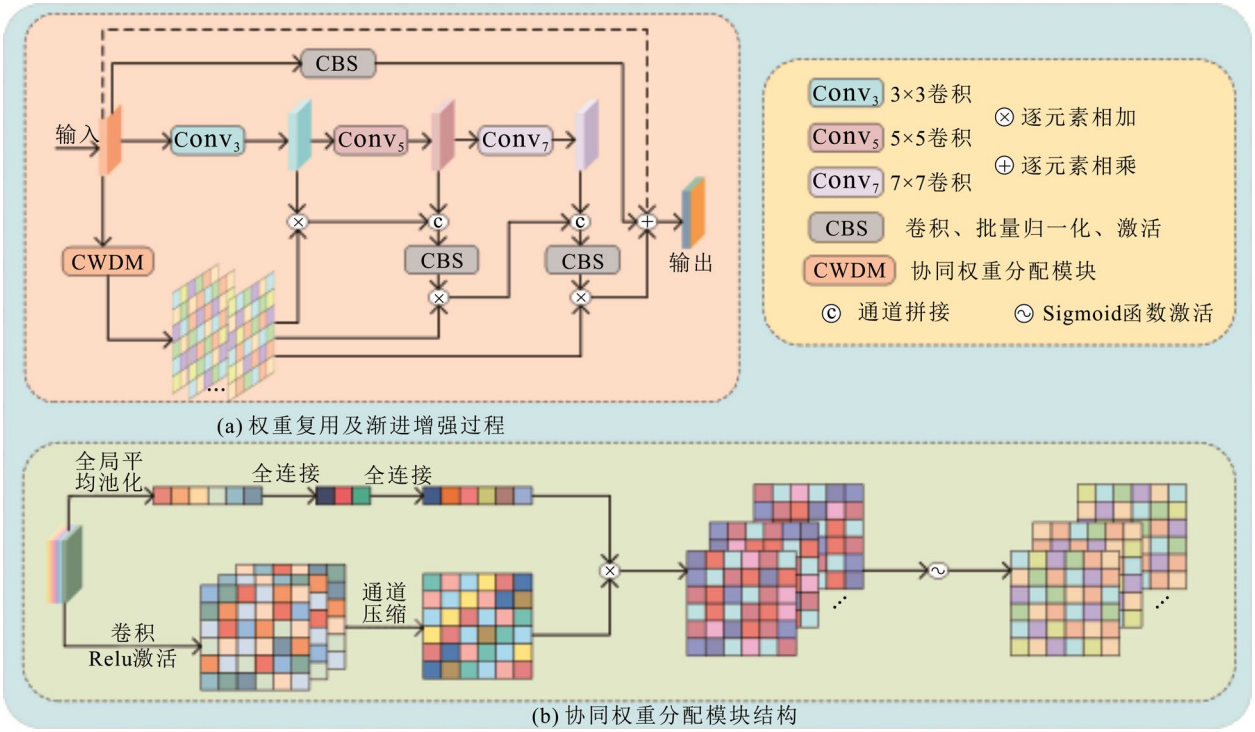


图 3　三维感知复用的渐进增强模块

Fig.3　The overall structure of the 3D Perceptual Reutilization Progressive Enhancement module

特征图在某一维度上的重要性，这不利于特征的精细化增强。相比于这些方法，本文所生成的三维感知权重充分考虑了特征在通道和空间位置各异情况下的独特性，有效提升了模型对细粒度特征信息的捕捉能力。

步骤 2：将特征图 S 输入核大小为 3、5、7 的级联空洞卷积中进行特征提取，在逐步扩展感受野的特征提取过程中通过三维感知权重的指导实现了更精确的特征捕捉。首先，在初步特征提取后，利用三维感知权重指导强化有利于缺陷检测任务的重要特征并抑制冗余特征的表达。随后，将经过第一次特征强化后的特征沿通道维度与第二阶段提取的特征进行拼接，并在通道维度转换后，再次复用三维感知权重进行特征强化引导。第三阶段的处理与第二阶段的处理过程类似。通过权重矩阵的复用操作，网络能够对不同感受野下的判别性特征进行渐进式学习，从而有效建立目标与目标之间，目标与背景之间的判别边界。最后，为了丰富特征表示并改善梯度流，构建了残差连接，以增强特征的丰富性。整个过程可由式(8)—式(10)表示：

$$\begin{cases} S_{11} = C_{\mathrm{E}}(S) \\ S_{21} = C_{\mathrm{F}}(S_{11}) \\ S_{31} = C_{\mathrm{G}}(S_{21}) \end{cases} \tag{8}$$

$$\begin{cases} S_{12} = S_{11} \otimes \omega \\ S_{22} = C_{\mathrm{B}}(C_{\mathrm{C}}(S_{12}, S_{21})) \otimes \omega \\ S_{32} = C_{\mathrm{B}}(C_{\mathrm{C}}(S_{22}, S_{31})) \otimes \omega \end{cases} \tag{9}$$

$$S_{\mathrm{out}} = S_{32} + C_{\mathrm{B}}(S) + S \tag{10}$$

式中：C_{E}、C_{F}、C_{G} 分别表示卷积核大小为 3、5、7，空洞率分别为 1、2、3，对应填充大小依次为 1、4、9 的空洞卷积；S_{i1} 为 S 依次经过不同空洞率卷积得到的特征图；S_{i2} 代表经过复用权重策略增强的特征；S_{out} 为三维感知复用的渐进增强模块的输出特征图。由于大核卷积及三维感知权重矩阵的权重分配过程涉及较大的参数量和计算量，本文在三维感知复用的渐进增强模块的输入和输出处分别应用全连接操作以进行通道的降维和升维，有效降低了模型的参数量和计算量。

由于闪络(Flashover)缺陷的电弧烧蚀痕迹与破损缺陷的小型裂纹在视觉上容易混淆。此外，存在相似背景的干扰使得绝缘子缺陷在复杂背景中难以被有效辨识。因此，为应对上述挑战，本文将三维感知复用的渐进增强模块集成到颈部网络中的特征金字塔及路径聚合网络的前向传播路径中，通过三维感知矩阵的构建与复用策略，使得网络在逐步扩大感受野的过程中有效捕获不同目标以及目标与背景之间的细微差异。此方法有助于提升网络对于判

别性特征的学习能力，从而进一步增强模型对缺陷目标的识别效果。

1.4 损失函数

在多层级补偿与三维感知增强的绝缘子缺陷检测算法训练过程中，本文使用的总损失函数如下：

$$L_{\text{total}} = \lambda_1 L_{\text{box}} + \lambda_2 L_{\text{cls}} + \lambda_3 L_{\text{obj}} \tag{11}$$

式中：L_{box} 为边界矩形框损失函数；L_{cls} 为目标分类损失函数；L_{obj} 为置信度损失函数；λ_1、λ_2、λ_3 是平衡 3 项损失函数的超参数。

$$L_{\text{box}} = 1 - I_{\text{IOU}} + \frac{\rho^2(p, p_{\text{gt}})}{c^2} + \alpha\nu \tag{12}$$

式中：I_{IOU} 为预测图像与标注图像中边框面积的交并比；ρ 用于计算两个点之间的欧氏距离；p 代表网络生成的预测结果图像；p_{gt} 表示标注图像；c 代表两个框之间最小闭包区域的对角线长度；ν 用于衡量预测框和标注框宽高比的偏差；α 为 ν 的权重因子。I_{IOU}、α、ν 的定义如式(13)—式(15)所示：

$$I_{\text{IOU}} = \frac{\left|p \cap p_{\text{gt}}\right|}{\left|p \cup p_{\text{gt}}\right|} \tag{13}$$

$$\alpha = \frac{\nu}{(1 - I_{\text{IOU}}) + \nu} \tag{14}$$

$$\nu = \frac{4(\arctan\frac{w_{\text{gt}}}{h_{\text{gt}}} - \arctan\frac{w_{\text{p}}}{h_{\text{p}}})^2}{\pi^2} \tag{15}$$

式中：$\left|p \cap p_{\text{gt}}\right|$ 为 p 与 p_{gt} 的交集面积；$\left|p \cup p_{\text{gt}}\right|$ 为 p 与 p_{gt} 的并集面积；w_{p} 与 h_{p} 分别是预测目标边框的宽度与高度；w_{gt} 与 h_{gt} 为标注目标锚框的宽度与高度。

$$L_{\text{cls}} = -\sum(O_{ij}\ln(C_{ij}) + (1 - O_{ij})\ln(1 - C_{ij})) \tag{16}$$

式中：O_{ij} 表示第 i 个预测框中是否存在第 j 种类别的目标实例；C_{ij} 用于量化第 j 种类别目标存在于第 i 个预测框中的概率。

$$L_{\text{obj}} = -\sum(o_i\ln(c_i) + (1 - o_i)\ln(1 - c_i)) \tag{17}$$

式中：o_i 代表预测框 i 中是否存在目标实例；c_i 表示预测框 i 中存在目标实例的概率。

2 对比实验结果与分析

在本章中，首先在第 2.1 节中介绍实验设置、数据集和评估指标。然后，在第 2.2 节和第 2.3 节中，本文提供了本研究所提出的多层级补偿与三维感知增强的绝缘子缺陷检测算法与最先进的 10 种目标检测算法在绝缘子及其缺陷检测数据集(insulator and defect detection dataset, IDDS)上的定量和定性评估结果。对比的目标检测算法包括 RetinaNet[23]、Faster R-CNN with FPN、DETR[24]、Mask R-CNN-Swin、Sparse R-CNN[25]、YOLOX[26]、RTM-Det[27]、YOLOv7、LiteYOLO-ID 和 YOLOv7+MCI-GLA[28]。

2.1 实验设置及数据集

实验设置：本文所有实验均在 NVIDIA RTX3090 GPU 上进行，并基于 Pytorch 框架实现代码。训练过程中使用随机梯度下降优化器对所提出的网络进行优化，初始学习率及批量大小分别设置为 0.01 和 8，采用余弦退火衰减策略以动态更新学习率。在训练期间，本文将输入到网络的图像分辨率统一调整为 640×640，同时采用随机旋转等数据增强策略，以提升模型的性能。损失函数的超参数具体设置如下：$\lambda_1 = 0.05$，$\lambda_2 = 0.5$，$\lambda_3 = 1.0$。

数据集：鉴于目前在绝缘子缺陷检测领域中缺乏公开且具有挑战性的绝缘子缺陷检测数据集，本团队与国内某电网公司合作，通过自主收集与网络收集相结合的方式，构建了一个针对于缺陷目标检测任务的绝缘子及其缺陷检测数据集，该数据集中的图像主要由无人机进行采集，涵盖了不同角度、距离以及多样化的场景。数据集中包括 2 881 张绝缘子图像，本文按照 7:2:1 的比例随机划分构成训练集(2016 张)、验证集(576 张)以及测试集(289 张)，并且标注了 4 种类别的目标实例：Breakage(破损)、Flashover(闪络)、Shed-Loss(伞裙脱落)、Insulator(绝缘子)，数据集详细情况如表 1 所示。

评估指标：为了有效评估绝缘子缺陷检测算法的性能，本文采用平均精度(average precision，P_{A})和均值平均精度(mean average precision，P_{mA})作为评价指标。对于每个类别，P_{A} 的计算基于准确率 P - 召回率 R 曲线下的面积，这种方式能够全面反映模型在准确率和召回率之间的平衡关系。P_{mA} 是通过对各类别的 P_{A} 值进行算术平均计算获得。P、R、P_{A}、P_{mA} 的计算表达式如下：

表 1 绝缘子及其缺陷检测数据集信息

Table 1 Insulator and defect detection dataset information

数据集	图片张数	破损个数	闪络个数	伞裙脱落个数	绝缘子个数	玻璃绝缘子个数	陶瓷绝缘子个数
训练集	2 016	950	1 825	489	2 376	141	2 235
验证集	576	283	520	142	682	46	636
测试集	289	161	269	65	353	19	334
共计	2 881	1 394	2 614	696	3 411	206	3 205

$$P=\frac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{P}}} \tag{18}$$

$$R=\frac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{N}}} \tag{19}$$

$$P_{\mathrm{A}}=\int_0^1 P(R)\mathrm{d}R \tag{20}$$

$$P_{\mathrm{mA}}=\frac{1}{N}\sum_{i=1}^{N}P_{\mathrm{A}i} \tag{21}$$

式中：N 代表待检测目标的类别总数。以 Breakage 类别实例为例，T_{P} 指模型正确识别为破损缺陷的样本数量；F_{P} 表示模型将其他物体错误识别为破损缺陷的数量；F_{N} 为那些实际存在但未被模型检测出的破损缺陷样本数量。

2.2　定量分析

为验证所提出的多层级补偿与三维感知增强的绝缘子缺陷检测算法的性能，本文将此算法与其他 10 种先进的目标检测方法进行了实验比较。实验结果如表 2 所示，其中展示了所评估的目标检测方法在 IDDS 数据集上的 P_{A} (0.5)和 P_{mA} (0.5)指标。P_{A} (0.5)与 P_{mA} (0.5)分别表示当交并比阈值设为 0.5 时的平均精度与均值平均精度。

本文在选择对比算法时，涵盖了当前主流的 3 类目标检测框架：(1)基于两阶段的目标检测方法(如 Faster R-CNN with FPN、Sparse R-CNN)；(2)基于单阶段的目标检测方法(如 RetinaNet、YOLOX、RTMDet、YOLOv7、LiteYOLO-ID、YOLOv7+MCI-GLA)；(3)基于 Transformer 的目标检测方法(如 DETR)。

与破损缺陷和闪络缺陷相比，绝缘子的外观呈串状，而伞裙脱落缺陷则通常表现为绝缘子串中个别绝缘子伞裙片的脱落，这两种目标类别的形态特征相对单一，因此易于识别。然而，破损缺陷可能以裂纹、碎裂等多种形式表现出不同程度的损伤，闪络缺陷的形态特征受到环境因素和雷击破坏力的影响，呈现出复杂且非固定的特征。这种形态的多样性为这两类缺陷目标的识别带来了更大的挑战。

实验结果表明，本文提出的方法在 IDDS 数据集上的 P_{mA} (0.5)显著优于所比较的先进的目标检测算法，并且破损、闪络、伞裙脱落 3 类缺陷的 P_{A} (0.5)指标均排名第 1。具体而言，与这些先进目标检测算法相比，本算法在破损、闪络、伞裙脱落 3 种缺陷类别的检测精度上分别提高了至少 3.8%、5.2%、0.3%，整个数据集上的 P_{mA} (0.5)也提升了至少 2.7%。这 3 种缺陷类别 P_{A} (0.5)指标上的大幅提升，得益于多层级检测头特征差异化补偿框架与三维感知复用的渐进增强模块的有效结合，网络在捕捉到局部细节与全局结构信息表示的基础上，逐步优化多尺度感受野特征，从而能够准确区分不同的缺陷目标以及前景与背景，实现对绝缘子缺陷目标的精准识别。

2.3　定性分析

本文在图 4—图 5 中展示了所提出的多层级补偿与三维感知增强的绝缘子缺陷检测算法以及 10 种先进目标检测算法在 IDDS 测试集上与 Ground-Truth 的对比可视化检测结果。基于这些结果，本文对不同目标检测算法对于绝缘子缺陷检测的性能表现进行了详细分析。

如图 4(a)所示，待检绝缘子破损缺陷由于表现为细小裂纹，且与绝缘子本体纹路存在相似，导致 RetinaNet、Faster R-CNN with fpn、DETR、Mask R-CNN-Swin、SparseR-CNN、RTMDet、YOLOv7、YOLOv7+MCI-GLA 8 种算法均出现了对于绝缘子破损缺陷的漏检现象。此外，Mask R-CNN-Swin 将绝缘子的正常表面纹理误检为破损缺陷，YOLOX、LiteYOLO-ID 虽然检测出了破损缺陷，但置信度较低，相比之下，本文提出的多层级补偿与三维感知增强的绝缘子缺陷检测算法成功检测出了缺陷目标，这归功于多层级检测头特征差异化补偿框架对于路径聚合网络不同层级的输出特征进行了频域信息缺失校正，使得特征图中包含丰富的边缘纹理及整体结构信息。此外，三维感知复用的渐进增强模块的有效集成，提高了模型对前景目标与背景之间以及不同类别缺陷之间的区分能力。

如图 4(b)所示，由于绝缘子与高压电塔之间出现重叠以及存在众多小目标的干扰，Retinanet、Faster R-CNN with FPN、RTMDet、YOLOv7、LiteYOLO-ID 5 种算法未能成功检测到绝缘子。其中，RTMDet 算法将背景区域错误地识别为绝缘子，而 Mask R-CNN-Swin 以及 Sparse R-CNN 算法由于待检测物体与高压电塔外观形状的相似性，出现了不同程度的重叠检测现象。此外，尽管 DETR、YOLOX、YOLOv7+MCI-GLA 3 种算法能够识别到绝缘子目标，但 DETR 依赖于自注意力机制的全局感受野，计算复杂度较高仍然是一个难以解决的问题，YOLOX 以及 YOLOv7+MCI-GLA 对于绝缘子的检测置信度低于本文提出的多层级补偿与三维感知增强的绝缘子缺陷检测算法，这进一步证明了本

表 2 在 IDDS 数据集上与最先进的方法定量实验比较结果

Table 2 Quantitative comparisons with the sota-of-art methods on the IDDS

算法	骨干网络	参数量/10^6	$P_A(0.5)$/%				$P_{mA}(0.5)$/%
			破损	闪络	伞裙脱落	绝缘子	
RetinaNet(2017)	R-50-FPN	36.39	72.9	67.2	88.5	94.8	80.9
Faster R-CNN with fpn	R-50-FPN	41.36	66.0	62.0	88.6	93.5	77.5
DETR(2020)	R-50	41.556	76.0	72.5	89.6	96.3	83.6
Mask R-CNN-Swin	SwinTransformer	47.39	77.3	76.9	93.0	96.3	85.4
SparseR-CNN(2021)	R-50-FPN	101.26	63.4	70.1	92.3	95.3	80.3
YOLOX(2021)	YOLOX-s	8.94	62.1	71.7	89.7	95.7	79.8
RTMDet(2022)	RTMDet-s	8.86	44.4	63.8	90.7	95.1	73.5
YOLOv7(2023)	CSPDarknet-53	35.49	74.7	78.3	91.8	97.0	85.5
LiteYOLO-ID(2024)	EGC-CSPGhostNet	3.58	66.9	72.9	90.8	94.3	81.2
YOLOv7+MCI-GLA(2024)	CSPDarknet-53	48.55	75.8	79.2	93.3	96.9	86.3
本文算法	CSPDarknet-53	27.73	81.1	84.4	93.6	96.9	89.0

注：在表中用下划线标注出 $P_A(0.5)$和 $P_{mA}(0.5)$的第 1 名、第 2 名和第 3 名。

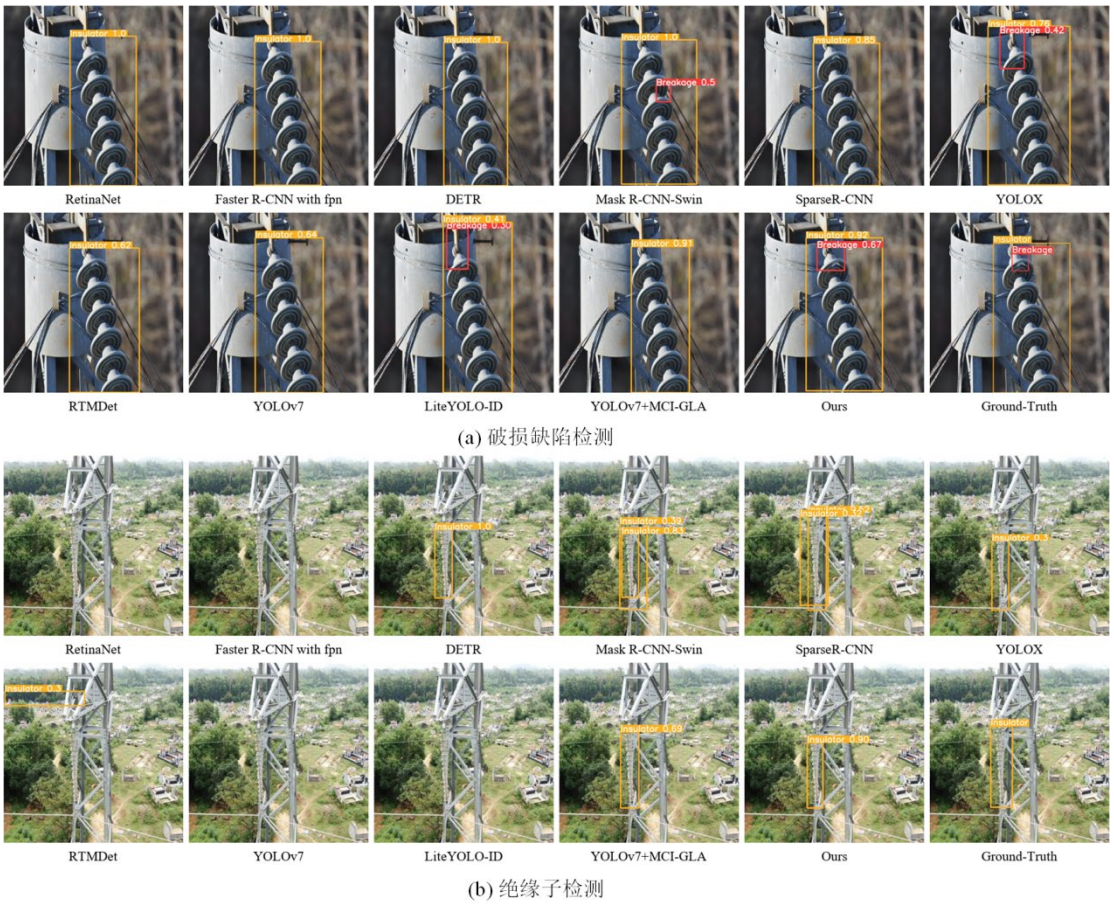


图 4 本文的绝缘子缺陷检测方法与其他 10 种先进的目标检测算法在 IDDS 数据集上的可视化对比(1)

Fig.4 Visual comparison of the insulator defect detection method proposed in this paper with 10 other advanced object detection algorithms on the IDDS dataset (1)

文所提出算法在复杂背景干扰下的绝缘子缺陷检测任务中的优势。

如图 5 (a)所示，由于待检测的小目标闪络缺陷的数量较多且缺陷形态多样，Retinanet、Faster R-CNN with FPN、DETR 、Mask R-CNN-Swin、Sparse R-CNN、YOLOX 、RTMDet 7 种目标检测

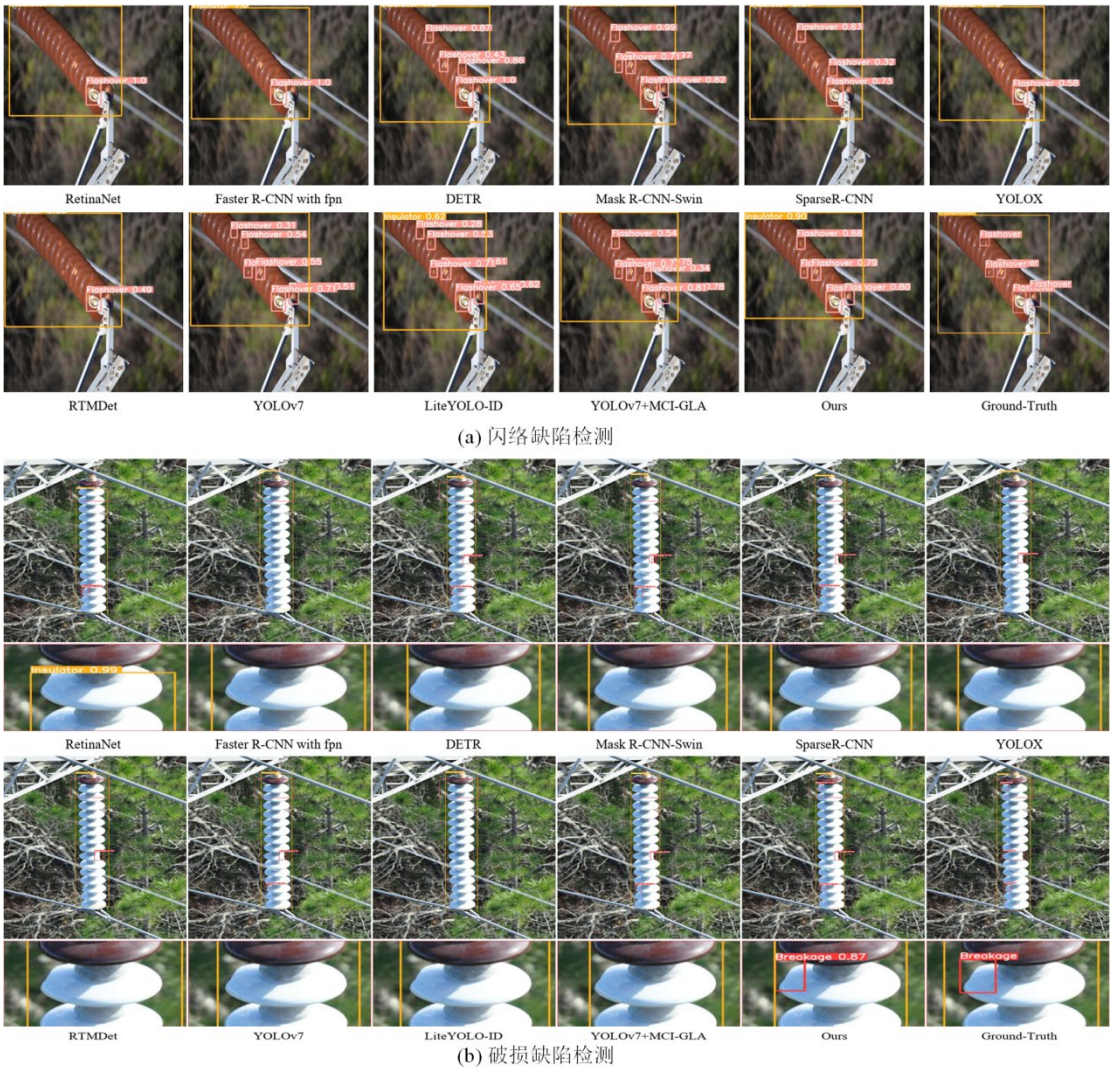


图 5　本文的绝缘子缺陷检测方法与其他 10 种先进的目标检测算法在 IDDS 数据集上的可视化对比(2)

Fig.5　Visual comparison of the insulator defect detection method proposed in this paper with 10 other advanced object detection algorithms on the IDDS dataset (2)

算法在缺陷类别的判别性特征学习能力方面存在不足，导致模型在闪络缺陷小目标的检测结果中出现了不同程度的漏检现象。此外，YOLOv7、LiteYOLO-ID、YOLOv7+MCI-GLA 在检测过程中将一些疑似发生闪络的绝缘子部位被错误识别为闪络缺陷，这可能是由于网络可捕获的待检小目标的特征信息较少，导致模型难以提取到与闪络缺陷相关的判别性特征。与上述这些方法相比，本文提出的多层级补偿与三维感知增强的绝缘子缺陷检测网络的检测结果与 Ground-Truth 最为接近，这是由于本文设计的多层级检测头特征差异化补偿框架和三维感知复用的渐进增强模块的无缝结合，有效捕捉到了关于闪络缺陷代表性的特征信息，从而提高了模型对闪络缺陷的检测效果。

如图 5(b)所示，除本文提出的算法外，对比的 10 种先进目标检测算法在识别绝缘子破损缺陷时均出现了漏检。这可能由于在树木茂盛的场景中，背景的干扰以及破损缺陷面积不同导致的外观差异，使得这些算法在识别和定位缺陷目标时面临困难。相比之下，本算法成功检测出了 3 个破损缺陷目标，并取得了较高的检测置信度。这一优异表现得益于多层级检测头特征差异化补偿框架为检测头提供了更加丰富的频域信息表示，以及三维感知复用的渐进增强模块在有效抑制背景干扰方面的作用，提升了算法对绝缘子缺陷的识别能力。

3　消融实验结果与分析

在本章中，为验证所提出的多层级补偿与三维

感知增强的绝缘子缺陷检测算法在绝缘子缺陷检测任务中的有效性，本文将算法分解为两个关键组件：多层级检测头特征差异化补偿框架与三维感知复用的渐进增强模块，并在 IDDS 数据集上进行了消融实验。本文设计了以下 4 种消融实验设置：(1)基线(Base)：采用集成特征金字塔和路径聚合网络的 CSPDarknet-53 架构，构建基线模型以评估网络的基础检测性能。(2)Base+MDFDC：将多层级检测头特征差异化补偿框架整合到基线模型中，以衡量多层级检测头特征差异化补偿框架对绝缘子缺陷检测效果的影响。(3)Base+3DPRPE：在基线模型中添加三维感知复用的渐进增强模块，以验证其对增强模型对缺陷检测的判别能力的有效性。(4)Base+MDFDC+3DPRPE：将多层级检测头特征差异化补偿框架与三维感知复用的渐进增强模块同时集成到基线模型中，以分析这两个组件组合对于绝缘子缺陷检测网络的性能影响。

如表 3 所示，与(1)基线模型(Base)相比，(2)Base+MDFDC 和(3)Base+3DPRPE 在多种缺陷类别的检测精度上均表现出显著的提升。对于(2)Base+MDFDC，破损、闪络、伞裙脱落、绝缘子的 $P_{\mathrm{A}}(0.5)$分别提高了 1.8%、4.2%、2.3%和 0.5%，整个数据集的 $P_{\mathrm{mA}}(0.5)$提升了 2.2%。3 种缺陷检测精度的显著提升，表明了多层级检测头特征差异化补偿框架通过门控动态融合经过频域信息分解的高低频特征分量信息，实现了各层级检测头特征中局部和全局信息的缺失弥补。尽管该框架在缺陷检测任务上取得了较好的检测结果，但在复杂相似背景干扰下，模型对于具有细微差异特征的缺陷识别仍存在不足，这使得 Base+MDFDC 相比于 Base 的性能提升有限。

在(3)Base+3DPRPE 中，相比于(1)基线模型，破损、闪络、伞裙脱落和绝缘子的 $P_{\mathrm{A}}(0.5)$分别对应提高了 1.3%、6.1%、2.9%和 0.1%，整体 $P_{\mathrm{mA}}(0.5)$有效提升了 2.6%。闪络和伞裙脱落缺陷类别检测精度的大幅提升，表明三维感知复用的渐进增强模块在复杂环境中模型对于绝缘子缺陷识别的有效性。这得益于网络通过跨空间-通道维度构建的三维感知权重以及权重复用的渐进增强操作，使得网络在由小到大的感受野范围内逐步强化判别性特征的学习，提升了网络在前景与背景之间、不同缺陷类别之间的区分能力。

在(2)Base+MDFDC 的基础上，添加 3DPRPE 模块构成(4)Base+MDFDC+3DPRPE，在已有良好表现的前提下，算法的检测能力得到了进一步提升。相较于(2)Base+MDFDC，模型在 IDDS 数据集上的 $P_{\mathrm{mA}}(0.5)$提高了 1.1%，在破损、闪络两类缺陷的检测精度分别提升了 1.0%、4.6%。尽管伞裙脱落类别的 $P_{\mathrm{A}}(0.5)$从 94.7%下降至 93.6%，绝缘子类别的 $P_{\mathrm{A}}(0.5)$减少了 0.1%，但在缺陷检测任务中的整体性能提升依然显著，特别是在应对复杂背景干扰和多样化缺陷的检测任务时表现优异。多层级检测头特征差异化补偿框架增强了网络对于纹理细节和整体结构的感知能力，在此基础上，三维感知复用的渐进增强模块首先学习精细化的三维感知权重，然后通过权重复用策略，使得模型在不同感受野下逐步提取具有判别性的特征表示。这两个组件的有效结合，改善了模型在复杂背景干扰下对绝缘子缺陷识别任务的性能。

表 3 消融实验各阶段在 IDDS 数据集上的实验结果

Table 3 The experiment result of each stage of the ablation when experiments were carried out on the IDDS

序号	模型	$P_{\mathrm{A}}(0.5)$/%				$P_{\mathrm{mA}}(0.5)$/%
		破损	闪络	伞裙脱落	绝缘子	
(1)	Base	78.3	75.6	92.4	96.5	85.7
(2)	Base+MDFDC	80.1	79.8	94.7	97.0	87.9
(3)	Base+3DPRPE	79.6	81.7	95.3	96.6	88.3
(4)	Base+MDFDC+3DPRPE	81.1	84.4	93.6	96.9	89.0

为了进一步验证三维感知复用的渐进增强模块的有效性，本文对算法集成该模块前后的检测结果进行了可视化及热力图分析，如图 6 所示。以图 6(c)为例，基线模型出现了对破损和闪络缺陷的误检风险，将三维感知复用的渐进增强模块集成至基线模型后，模型能够精准识别出闪络缺陷，并取得了与 Ground-Truth 更接近的检测结果。这表明在集成了三维感知复用的渐进增强模块后，网络在三维感知权重对于多感受野特征提取过程的复用指导下，能够有效抑制复杂背景的干扰，并且增强了模型对于不同缺陷目标的区分能力。此外，热力图可视化结果表明，基线模型由于判别能力的局限性，难以有效关注到绝缘子及缺陷区域，而在集成了三维感知复用的渐进增强模块后，算法能够聚焦于前景绝缘子缺陷区域。

4 结论

1）多层级检测头特征差异化补偿框架通过门

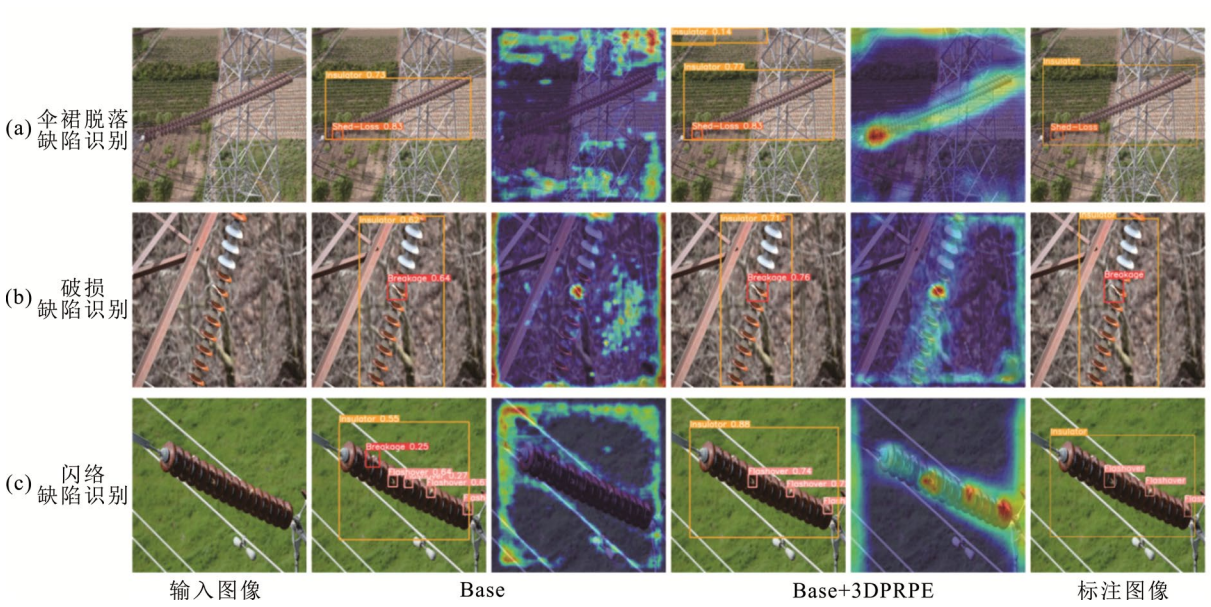


图 6　基线模型与三维感知复用的渐进增强模块的可视化及热力图对比

Fig.6　Visual and heatmap comparison between the Base and 3DPRPE module

控融合频域特征分量信息，有效弥补了各层级检测头在高频与低频信息上的缺失，提高了特征的表达能力。

2）三维感知复用的渐进增强模块通过跨空间与通道维度的交互构建三维特征权重矩阵，并结合权重复用策略，指导逐步扩大感受野的特征学习过程，实现了前景目标、复杂背景以及不同缺陷类型的有效区分。

3）多层级补偿与三维感知增强的绝缘子缺陷检测算法在构建的绝缘子及其缺陷检测数据集上，破损、闪络、伞裙脱落 3 类缺陷的平均精度分别达到了 81.1%、84.4%、93.6%，检测效果优于当前先进的 10 种目标检测方法。然而，在目前的算法架构上采用多分支特征提取网络的设计在一定程度上增加了模型的参数量。同时，权重复用策略中多次使用哈达玛积操作也导致了计算复杂度的上升。因此，实现网络结构的轻量化与计算复杂度的优化将成为后续研究的重要方向。我们将进一步探索更先进的技术以优化网络结构，从而提升模型在复杂环境下电力系统缺陷检测任务中的性能。

参考文献　References

[1] HAO K, CHEN G K, ZHAO L, et al. An insulator defect detection model in aerial images based on multiscale feature pyramid network[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3522412.

[2] 葛　召，李洪文，刘海峰，等. 基于 YOLO-GSS 的输电线路边缘端实时缺陷检测方法[J]. 高电压技术，2025，51(2)：669-677.
GE Zhao, LI Hongwen, LIU Haifeng, et al. Real-time defect detection method for edge-end of transmission line based on YOLO-GSS[J]. High Voltage Engineering, 2025, 51(2): 669-677.

[3] WANG Y R, QU Z, HU Z D, et al. Cross-domain multilevel feature adaptive alignment R-CNN for insulator defect detection in transmission lines[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 6001112.

[4] 刘开培，李博强，秦　亮，等. 深度学习目标检测算法在架空输电线路绝缘子缺陷检测中的应用研究综述[J]. 高电压技术，2023，49(9)：3584-3595.
LIU Kaipei, LI Boqiang, QIN Liang, et al. Review of application research of deep learning object detection algorithms in insulator defect detection of overhead transmission lines[J]. High Voltage Engineering, 2023, 49(9): 3584-3595.

[5] 李　斌，曾筠婷，朱新山，等. 基于多尺度上下文感知的绝缘子缺陷检测网络[J]. 高电压技术，2022，48(8)：2905-2914.
LI Bin，ZENG Junting，ZHU Xinshan，et al. Detection network for insulator defects based on multi-scale context awareness[J]. High Voltage Engineering，2022，48(8)：2905-2914.

[6] GIRSHICK R. Fast R-CNN[C]//2015 IEEE/CVF International Conference on Computer Vision. Santiago, Chile: IEEE, 2015: 1440-1448.

[7] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[8] 顾超越，李　喆，史晋涛，等. 基于改进 Faster-RCNN 的无人机巡检架空线路销钉缺陷检测[J]. 高电压技术，2020，46(9)：3089-3096.
GU Chaoyue，LI Zhe，SHI Jintao，et al. Detection for Pin defects of overhead lines by UAV patrol image based on improved faster-RCNN[J]. High Voltage Engineering，2020，46(9)：3089-3096.

[9] ZHAO W Q, XU M F, CHENG X F, et al. An insulator in transmission lines recognition and fault detection model based on improved faster RCNN[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 5016408.

[10] 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. Las Vegas, USA: IEEE, 2016: 779-788.

[11] JOCHER G. YOLOv5 by ultralytics[EB/OL]. 2020[2025-01-07]. https://github. com/ultralytics/yolov5.

[12] PANIGRAHY S, KARMAKAR S. Real-time condition monitoring of transmission line insulators using the YOLO object detection model with a UAV[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 2514109.

[13] CAO Z, CHEN K H, CHEN J Z, et al. CACS-YOLO: a lightweight model for insulator defect detection based on improved YOLOv8m[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 3530710.

[14] SONG Z W, HUANG X B, JI C, et al. Deformable YOLOX: detection and rust warning method of transmission line connection fittings based on image processing technology[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 2504321.

[15] LUO B H, XIAO J, ZHU G Y, et al. Occluded insulator detection system based on YOLOX of multi-scale feature fusion[J]. IEEE Transactions on Power Delivery, 2024, 39(2): 1063-1074.

[16] LI D H, LU Y, GAO Q, et al. LiteYOLO-ID: a lightweight object detection network for insulator defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5023812.

[17] 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. Vancouver, Canada: IEEE, 2023: 7464-7475.

[18] HUANG Z L, ZHANG C X, GE L Y, et al. Joining spatial deformable convolution and a dense feature pyramid for surface defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5012614.

[19] 王韵琳，冯天波，孙　宁，等. 融合注意力与多尺度特征的电力绝缘子缺陷检测方法[J]. 高电压技术，2024，50(5)：1933-1942.
WANG Yunlin, FENG Tianbo, SUN Ning, et al. Defect detection method for power insulators based on attention and multi-scale context information[J]. High Voltage Engineering, 2024, 50(5): 1933-1942.

[20] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 936-944.

[21] ZHANG X T, ZHANG Y Y, LIU J F, et al. InsuDet: a fault detection method for insulators of overhead transmission lines using convolutional neural networks[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 5018512.

[22] HE M, QIN L, DENG X L, et al. MFI-YOLO: multi-fault insulator detection based on an improved YOLOv8[J]. IEEE Transactions on Power Delivery, 2024, 39(1): 168-179.

[23] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 2999-3007.

[24] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]//16th European Conference on Computer Vision. Glasgow, UK: Springer, 2020: 213-229.

[25] SUN P Z, ZHANG R F, JIANG Y, et al. Sparse R-CNN: end-to-end object detection with learnable proposals[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE, 2021: 14449-14458.

[26] GE Z, LIU S T, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[J]. arXiv preprint arXiv, 2021: 2107.08430.

[27] LYU C Q, ZHANG W W, HUANG H A, et al. RTMDet: an empirical study of designing real-time object detectors[J]. arXiv preprint arXiv, 2022: 2212.07784.

[28] WANG Y R, SONG X K, FENG L L, et al. MCI-GLA plug-in suitable for YOLO series models for transmission line insulator defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 9002912.



孙　航
1986—，男，博士，副教授，硕导
主要从事目标检测、电力设备缺陷检测等方面的研究工作
E-mail: sunhang@ctgu.edu.cn

SUN Hang
Ph.D.
Associate professor



吴　田(通信作者)
1983—，男，博士，高工，博导
主要从事带电作业、输电线路外绝缘等方面的研究工作
E-mail: wutian_08@163.com

WU Tian
Ph.D.
Corresponding author

收稿日期　2025-04-08　在线出版日期　2025-07-25　　编辑　曹昭君