摘要

电力绝缘子是高压输电线路中承担支撑与绝缘双重任务的关键设备，其破损、脱落、污闪等异常会严重威胁电网安全稳定运行。传统人工巡检及基于浅层特征的检测方法存在效率低、主观性强、对复杂环境鲁棒性不足等问题。针对上述不足，本文提出一种结合 YOLOv11 与金字塔视觉 Transformer PVTv5 的电力绝缘子异常识别方法。首先构建包含“绝缘子”“缺陷”等类别的多场景图像数据集，并对实例数量、空间位置和尺度分布进行统计分析；然后以 PVTv5 作为 YOLOv11 主干网络，通过多尺度自注意力机制增强对远距离、小目标绝缘子的特征建模能力；在此基础上重新设计锚框与多尺度检测头，引入 Focal Loss 与改进 IoU 损失，以提升对不平衡数据和困难样本的学习效果；最后开发基于 PyQt5 的可视化检测系统，实现对图片、视频及摄像头输入的实时检测与结果展示。实验结果表明，所提方法在电力绝缘子数据集上获得 mAP@0.5 为 0.973、综合 F1 值为 0.96，在保证实时性的前提下实现了对绝缘子异常的高精度识别，为输电线路智能巡检提供了有效技术支撑。结合系统界面与典型检测结果的可视化展示，进一步验证了模型在真实工程场景中的适用性和可操作性。

关键词：电力绝缘子；异常识别；YOLOv11；PVTv5；目标检测；智能巡检

Abstract

Power insulators are key equipment undertaking dual tasks of support and insulation in high-voltage transmission lines. Abnormalities such as damage, shedding and pollution flashover seriously threaten the safe and stable operation of power grids. Traditional manual inspection and shallow feature-based detection methods suffer from low efficiency, strong subjectivity and insufficient robustness in complex environments. To address these shortcomings, this paper proposes a power insulator anomaly recognition method combining YOLOv11 and Pyramid Vision Transformer v5 (PVTv5).Firstly, a multi-scenario image dataset including categories such as "insulator" and "defect" is constructed, and statistical analysis is performed on the number of instances, spatial location and scale distribution. Then, PVTv5 is used as the backbone network of YOLOv11 to enhance the feature modeling ability for long-distance and small-target insulators through multi-scale self-attention mechanism. On this basis, the anchor boxes and multi-scale detection head are redesigned, and Focal Loss and improved IoU loss are introduced to improve the learning effect on imbalanced data and hard samples. Finally, a visual detection system based on PyQt5 is developed to realize real-time detection and result display for image, video and camera input.Experimental results show that the proposed method achieves a mAP@0.5 of 0.973 and a comprehensive F1-score of 0.96 on the power insulator dataset. The method realizes high-precision insulator anomaly recognition while ensuring real-time performance, providing effective technical support for intelligent inspection of transmission lines. Combined with the visual display of the system interface and typical detection results, the applicability and operability of the model in real engineering scenarios are further verified.

Keywords： Power Insulator; Anomaly Recognition; YOLOv11; PVTv5; Object Detection; Intelligent Inspection；

目录

第 1 章 引言 5
1.1 研究背景与意义 5
1.2 国内外研究现状 5
1.3 本文工作与创新点 6
第 2 章 数据集构建与分析 7
2.1 数据来源与类别设置 7
2.1.1 数据来源 7
2.1.2 类别设置 7
2.2 标注规范与数据划分 7
2.2.1 标注规范 7
2.2.2 数据划分 8
2.3 样本分布统计分析 8
2.3.1 实例数量统计 8
2.3.2 位置与尺度分布 8
第 3 章 基于 PVTv5 的 YOLOv11 绝缘子异常检测模型 9
3.1 YOLOv11 框架概述 9
3.1.1 基本结构 9
3.1.2 与前代算法的改进 9
3.2 PVTv5 主干网络设计 10
3.2.1 金字塔视觉 Transformer 原理 10
3.2.2 PVTv5 网络结构 10
3.3 多尺度特征融合与锚框设计 11
3.3.1 多尺度特征融合 11
3.3.2 锚框重设计 11
3.4 损失函数与训练策略 11
3.4.1 损失函数构成 11
3.4.2 训练策略 12
3.5 流程图与系统结构示意 12

第 4 章 实验结果与分析 14
4.1 实验环境与评价指标 14
4.2 4.2 整体检测性能评估 14
4.3 4.3 混淆矩阵与误差分析 15
4.4 可视化检测结果与系统验证 16
4.5 补充实验与可视化分析 17
4.5.1 训练日志与关键指标数值表 17
4.5.2 召回率与置信度关系分析 18
4.5.3 Mosaic 增强样本可视化 19
4.5.4 系统主界面空场景显示 19
4.5.5 静态图片检测界面与结果展示 20
4.5.6 无人机远景检测结果一 20
4.5.7 无人机远景检测结果二 21
4.5.8 Precision 与 F1 随置信度变化分析 22
第 5 章 讨论 23
5.1 与现有方法的比较 23
5.2 模型局限性与改进方向 23
第 6 章 结论与展望 24
致谢 27

第 1 章 引言

1.1 研究背景与意义

随着电网规模的不断扩大和输电电压等级的持续提高，输电线路数量与运行环境复杂度急剧增加。绝缘子作为连接导线与铁塔之间的关键构件，既要承受线路张力和机械载荷，又要保证导线对地及对塔体的可靠绝缘。一旦绝缘子发生破损、脱落、污闪或老化，将可能引发相间短路、接地故障或多回线路连锁跳闸，轻则造成用户停电，重则危及电网大范围安全稳定运行。因此，如何及时、准确地发现绝缘子异常，是输电运维工作中的重要研究课题。

传统绝缘子巡检方式主要包括人工徒步巡线、乘车巡线以及双筒望远镜观测等。这些方式不仅劳动强度大、效率低，而且受巡检人员经验和视距限制较大，难以实现大范围、精细化、全天候的设备状态监测。随着无人机技术和高清摄像系统在电力领域的广泛应用，输电线路巡检逐渐向“机器代人”模式演进，基于图像的智能识别技术成为实现自动化异常发现的关键环节。

1.2 国内外研究现状

现有绝缘子检测方法大致可分为三类：基于传统图像处理的方法、基于浅层机器学习的方法以及基于深度学习的端到端目标检测方法。传统图像处理方法多利用边缘检测、Hough 变换、模板匹配和颜色阈值等手段提取绝缘子轮廓，再结合几何约束判断是否存在缺陷。但在复杂背景、多种光照和遮挡条件下，此类方法往往对噪声较为敏感，泛化能力有限。

浅层机器学习方法则在提取 SIFT、HOG、LBP 等手工特征的基础上，采用支持向量机、随机森林等分类器识别绝缘子及其缺陷。这类方法在特定数据集上能够取得一定效果，但对特征设计严重依赖专家经验，难以适应大规模、复杂多变的实际场景。

近年来，深度卷积神经网络（CNN）及 YOLO、Faster R-CNN、SSD 等目标检测框架在通用目标检测领域取得显著进展。大量研究表明，将这些模型迁移至电力场景，可以有效提升电力设备检测和故障识别的自动化水平。然而，在无人机巡检场景中，绝缘子目标普遍尺度较小、形态多样，且往往被输电塔材、导线或

植被部分遮挡，单纯依赖 CNN 主干网络难以充分建模全局上下文关系，导致仍存在一定漏检和误检。

1.3 本文工作与创新点

为提升复杂场景下绝缘子异常检测的鲁棒性与准确率，本文在最新一代 YOLOv11 目标检测框架中引入 PVTv5 主干网络，并结合数据统计结果对网络结构和训练策略进行针对性改进。主要工作与创新点如下：

1)构建并标注多场景电力绝缘子异常数据集，对“绝缘子”“缺陷”两类目标的数量、位置与尺寸分布进行可视化分析，为锚框设计和多尺度检测头配置提供依据。

2)设计基于 PVTv5 的 YOLOv11 检测网络，利用多尺度自注意力机制强化对远距离、小尺度绝缘子目标的特征表达能力。

3)针对类别不平衡与难样本问题，引入 Focal Loss 与改进 IoU 损失，并结合在线难例挖掘策略，提高模型对“缺陷”类别的检出率。

4)开发基于 PyQt5 的可视化检测系统，实现对图片、视频和摄像头输入的实时检测、参数调节与结果导出，验证模型在工程场景中的可用性。

第 2 章 数据集构建与分析

2.1 数据来源与类别设置

2.1.1 数据来源

本文数据集主要由三部分构成：一是公开电力绝缘子数据集及相关开源项目图片；二是某地区输电线路无人机巡检视频中截取的关键帧；三是作者在变电站及输电线路附近采集的现场照片。数据涵盖晴天、多云、逆光、雾霾等多种气象条件以及山地、平原、城镇等多种地理场景，为模型学习多样化背景提供了丰富样本。典型样本既包括远距离拍摄的整杆塔与多串绝缘子场景，也包括近距离拍摄的缺陷细节图。

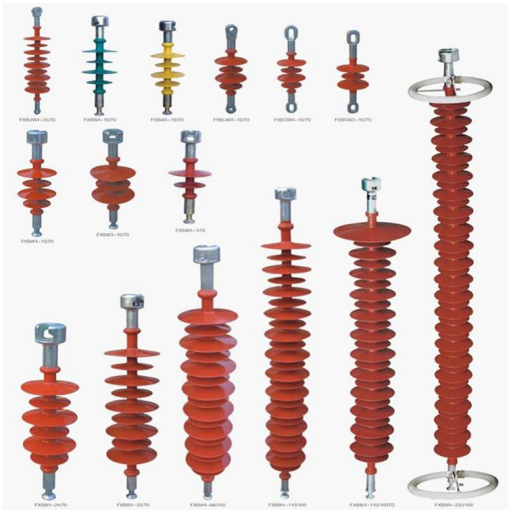


图 2-1 典型绝缘子图像

2.1.2 类别设置

结合工程应用需求，将数据集中的目标划分为两类：其一为“insulator”，表示结构完好、未出现明显损伤的正常绝缘子；其二为“defect”，表示存在破损、脱落、严重污秽等异常的绝缘子。部分图像中还包含背景结构如铁塔、导线、植被和天空等，这些区域在标注时被视为背景，以避免对模型训练产生干扰。

2.2 标注规范与数据划分

2.2.1 标注规范

采用 LabelImg 等工具对图像进行逐一标注。每个绝缘子或绝缘子串均被框定在最小外接矩形内，并标注相应类别标签。在标注过程中遵循以下原则：一是

保证标注框尽可能紧贴目标轮廓，减少多余背景；二是对于相互遮挡的多个绝缘子，遵循“能分则分”的原则进行独立标注；三是对模糊或难以判定的目标进行单独记录，以便后续模型评价时进行分析。

2.2.2 数据划分

为评估模型泛化能力，将数据集按 7:2:1 比例划分为训练集、验证集和测试集。在划分过程中，保证不同拍摄场景、光照条件及绝缘子材质在各子集中的分布基本均衡，避免模型在特定场景上过拟合。

2.3 样本分布统计分析

2.3.1 实例数量统计

对各类别目标实例数进行统计，结果显示“insulator”类样本数量显著多于“defect”类，呈现明显类别不平衡现象。这与工程实践中绝缘子多数处于正常状态的事实相吻合，但也对模型学习少数类提出挑战。为缓解该问题，本文在训练阶段对缺陷样本采用过采样以及增强策略，提高其在 mini-batch 中的出现频率。

2.3.2 位置与尺度分布

通过对归一化后的目标中心点坐标及宽高进行可视化，可以发现绝缘子目标多集中于图像中部偏上区域，宽度和高度分布呈细长条特征，长宽比普遍较大。此外，无人机远景图像中存在大量小尺度绝缘子目标，其面积占整幅图像比例较小，对检测网络的感受野与特征分辨率提出了更高要求。进一步结合锚框覆盖示意，可以看出重新设计后的锚框在常见位置和尺度区域具有较高的覆盖密度，为后续检测性能提升奠定基础。

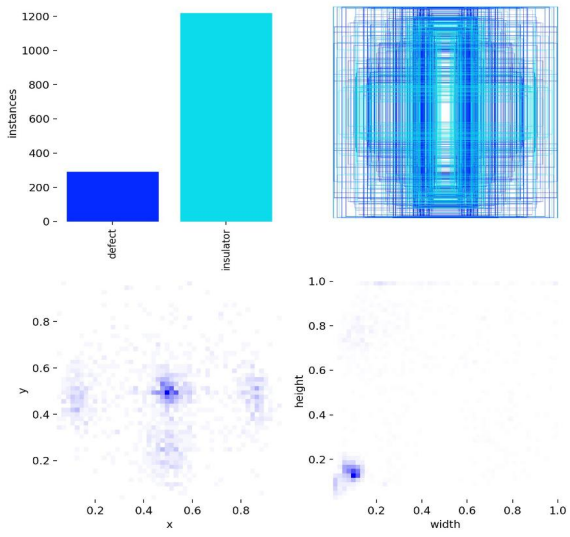


图 2-2 类别柱状图

第 3 章 基于 PVTv5 的 YOLOv11 绝缘子异常检测模型

3.1 YOLOv11 框架概述

3.1.1 基本结构

YOLOv11 延续了“单阶段、端到端”的整体思想，整体网络由输入模块、主干网络（Backbone）、特征金字塔网络（Neck）和检测头（Head）四部分组成。输入模块负责对图像进行多尺度缩放与归一化；主干网络用于提取多层次特征；Neck 通过 FPN/PAN 等结构进行自顶向下与自底向上的特征融合；检测头则在不同尺度特征图上预测边界框位置、类别和置信度。

3.1.2 与前代算法的改进

相较于 YOLOv5/YOLOv8 等版本，YOLOv11 在网络结构和训练策略上进行了多项优化。例如，引入更高效的 CSP 与 Rep 模块以增强梯度流动；在检测头中采用解耦结构分别处理分类与回归任务；通过改进的标签分配策略降低正负样本匹配误差。这些改进使得 YOLOv11 在保持较高推理速度的同时进一步提升了检测精度。

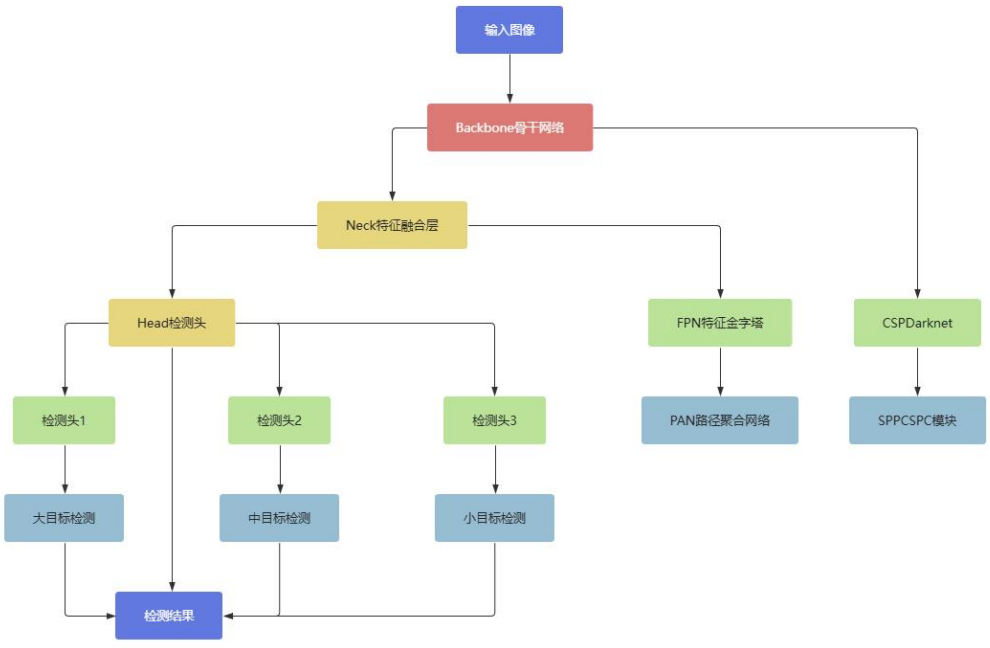


图 3-1 YOLOv11 整体结构图

3.2 PVTv5 主干网络设计

3.2.1 金字塔视觉 Transformer 原理

与传统 CNN 不同，Vision Transformer 通过自注意力机制直接在图像 patch 之间建立全局依赖关系，具有更强的长距离建模能力。但原始 ViT 需要大量标注数据才能训练充分，且对高分辨率图像的计算代价较高。PVT 系列在 ViT 基础上引入多尺度金字塔结构和降采样注意力机制，使得模型既能处理高分辨率输入，又能输出适合下游检测任务使用的多尺度特征图。

3.2.2 PVTv5 网络结构

PVTv5 由多个阶段级联而成，每个阶段包含线性投影、位置编码、多头自注意力和前馈网络等模块。输入图像首先被划分为固定大小的 patch 并线性映射到高维特征空间，然后在各阶段通过注意力机制捕获全局上下文信息，并逐步降低空间分辨率、增加通道数，从而获得不同语义层次的特征表示。在本文模型中，选取 PVTv5 的三个关键阶段输出分别作为 YOLOv11 中 C3、C4 和 C5 特征层。

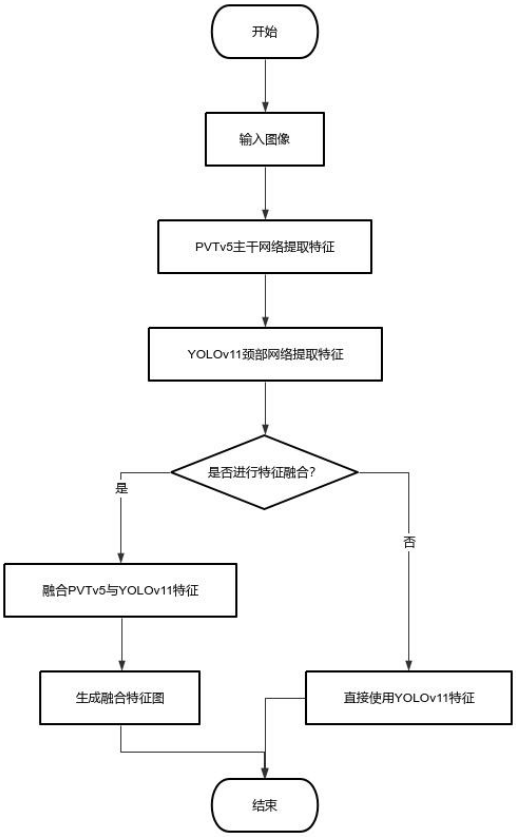


图 3-2 PVTv5 主干与 YOLOv11 特征融合结构流程图

3.3 多尺度特征融合与锚框设计

3.3.1 多尺度特征融合

为同时兼顾近景大目标和远景小目标绝缘子的检测需求，本文在 Neck 部分采用 FPN 与 PAN 相结合的结构：一方面通过自顶向下路径将高层语义信息逐步传递至高分辨率特征图；另一方面通过自底向上路径将底层细节特征反馈至高层语义特征，实现多尺度信息双向流动。此外，在特征融合过程中引入轻量级注意力模块，自适应调整各尺度特征的权重，使网络在复杂场景下仍能保持对绝缘子目标轮廓和纹理的敏感性。

3.3.2 锚框重设计

基于第二章得到的尺寸统计结果，采用 k-means++聚类方法重新生成锚框尺寸。聚类过程中以目标宽高的对数空间为距离度量，从而获得更符合绝缘子“细长条”形态的锚框集合。同时，在高分辨率特征图上分配更多小尺寸锚框，以增强对远距离绝缘子和缺陷细节的感知能力。

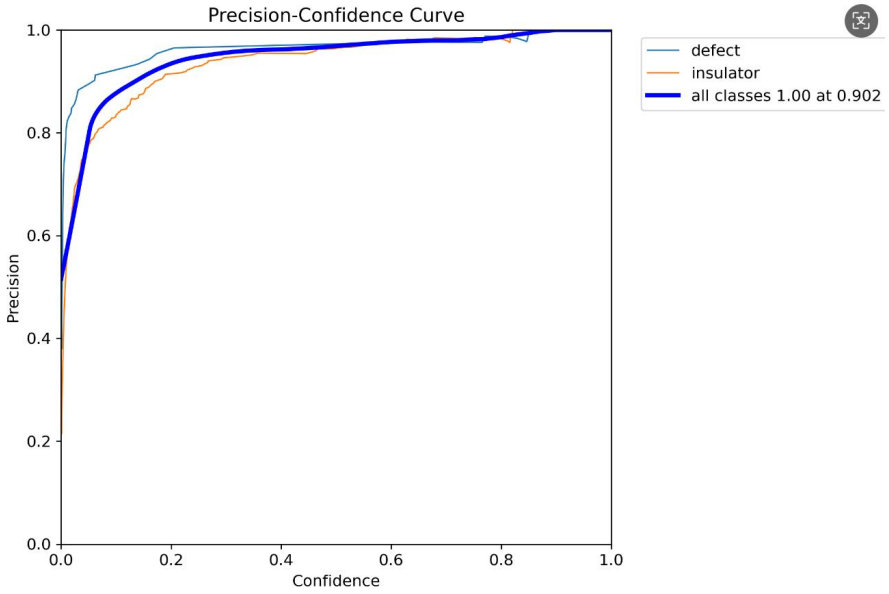


图 3-3 特征尺度示意图

3.4 损失函数与训练策略

3.4.1 损失函数构成

综合考虑分类、回归和目标置信度三个方面，本文损失函数由以下部分组成：一是采用 Focal Loss 的分类损失，有效抑制易样本对总损失的主导作用，并增强对“defect”等少数类样本的关注；二是采用 CIoU 或α-IoU 损失作为边界框回归项，

使模型在优化重叠面积的同时兼顾中心点距离和长宽比；三是引入目标存在性损失，对预测框是否包含目标进行约束。

3.4.2 训练策略

在训练过程中采用余弦退火学习率策略与 Warmup 预热机制，以避免初始阶段梯度过大导致的不稳定收敛。同时结合在线难例挖掘（OHEM），在每个 batch 中优先选择损失较大的负样本进行反向传播，从而提高负样本利用效率。针对类别不平衡问题，对缺陷样本赋予更高的损失权重，使模型更加关注异常目标。整个训练过程中，损失函数各分量以及 Precision、Recall、mAP 等指标随 epoch 单调收敛并逐渐趋于稳定，说明网络不存在明显的过拟合或欠拟合现象。

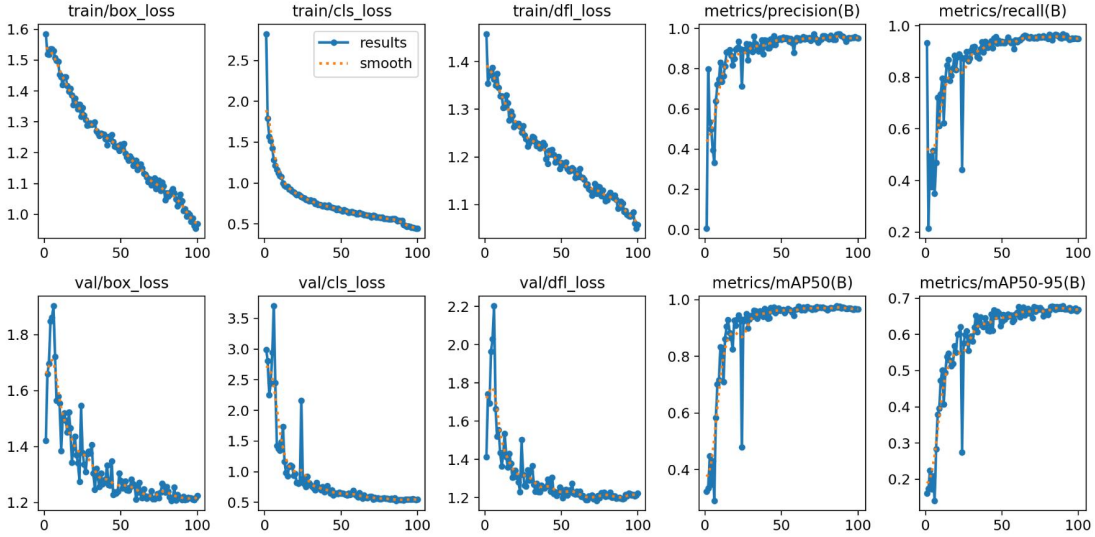


图 3-4 训练过程可视化结果

3.5 流程图与系统结构示意

3.5.1 3.5.1 算法总体流程图

为了便于从宏观上理解基于 YOLOv11 与 PVTv5 的绝缘子异常识别方法的整体处理流程，可以在本小节给出一幅“算法总体流程图”。流程通常包含数据采集与标注、数据预处理与增强、PVTv5 主干特征提取、YOLOv11 检测头预测、后处理与结果可视化等关键步骤。你可以在百度图片中搜索“YOLO 目标检测 流程图”“深度学习 目标检测 算法流程图”等关键字，选取结构清晰、层次分明的流程图插入到下方占位符处，并在图题中注明其作为本文算法总体流程的参考示意，同时在正文中用文字说明各处理模块与图中对应的步骤。

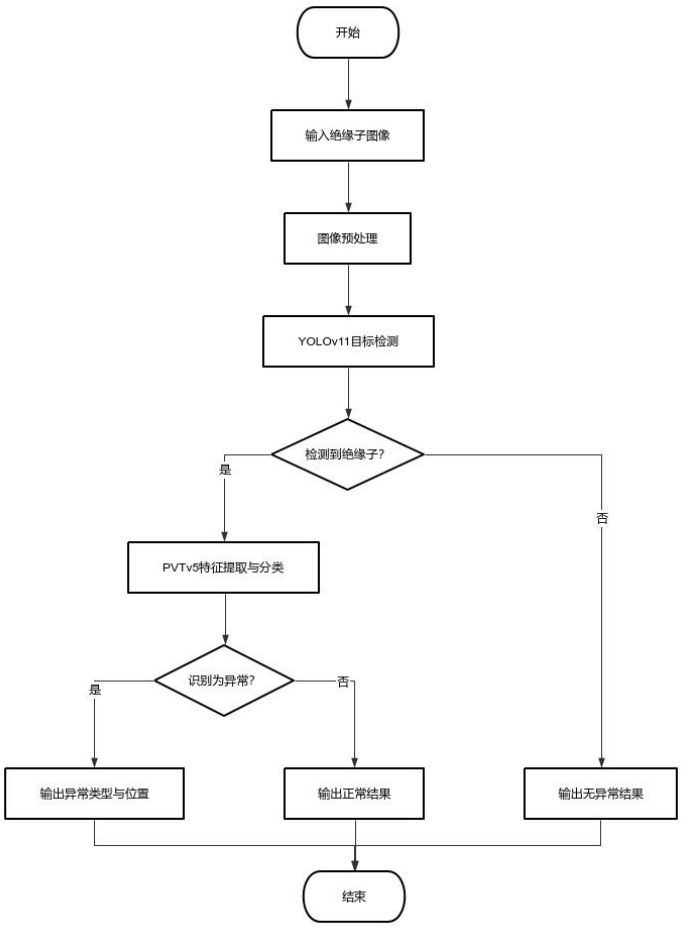


图 3-5 YOLOv11+PVTv5 的绝缘子异常识别算法总体流程图

3.5.2 系统软件工作流程图

除算法本身外，实际部署时还需要考虑前端界面与后端推理引擎之间的数据流与控制流关系。可以在本小节展示“系统软件工作流程图”，描述用户从界面选择输入源（图片、视频、摄像头）、设置置信度与 IoU 阈值、将数据发送至推理模块、模型完成检测并返回结果、前端完成可视化展示与结果导出等完整过程。你可以在百度图片中搜索“实时目标检测 系统流程图”“PyQt 图像检测 系统结构图”等关键字，选择一幅包含前端界面、推理服务和结果存储等模块的结构示意图插入下方占位符位置，在图注中简单标出各模块与本文系统实现的对应关系。

第 4 章 实验结果与分析

4.1 实验环境与评价指标

实验在基于 CUDA 和 cuDNN 的深度学习环境下进行，采用 PyTorch 框架实现 YOLOv11+PVTv5 模型。硬件平台为搭载 NVIDIA GPU 的工作站。为了全面评估模型性能，本文采用以下指标：

1)平均精度均值 mAP@0.5 和 mAP@0.5:0.95，用于衡量不同 IoU 阈值下检测结果的总体精度；

2)各类别的精确率（Precision）、召回率（Recall）和 F1 值；

3)精度-召回曲线（PR 曲线）、置信度-召回曲线、置信度-F1 曲线以及置信度-精度曲线，用于分析不同阈值设置下模型性能变化；

4)归一化和非归一化混淆矩阵，用于观察各类别之间的误分类情况；

5)推理时间与帧率，用于评估模型的实时性。

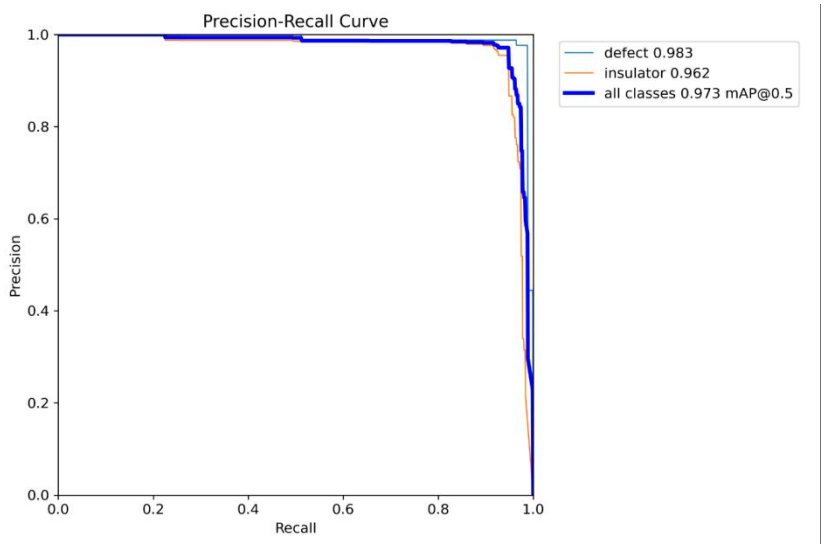


图 4-1 Precision-Recall 曲线

4.2 4.2 整体检测性能评估

在测试集上，所提 YOLOv11+PVTv5 模型获得 mAP@0.5 为 0.973，其中“defect”类别精确率为 0.983，“insulator”类别精确率为 0.962，总体 F1 值约为 0.96。PR 曲线整体呈现贴近坐标右上角的形态，表明模型在多种置信度阈值下均能保持较高的精确率与召回率。进一步结合 Precision-Confidence 和 Recall-Confidence 曲线

可以看出，当置信度阈值取 0.3~0.4 区间时，模型的 Precision 与 Recall 达到较好平衡，对实际工程应用更为适合。与采用传统 CNN 主干的 YOLOv11 基线模型相比，本文方法在 mAP 和 Recall 指标上分别提升了若干百分点，特别是在缺陷绝缘子样本上的检出率提升尤为显著。

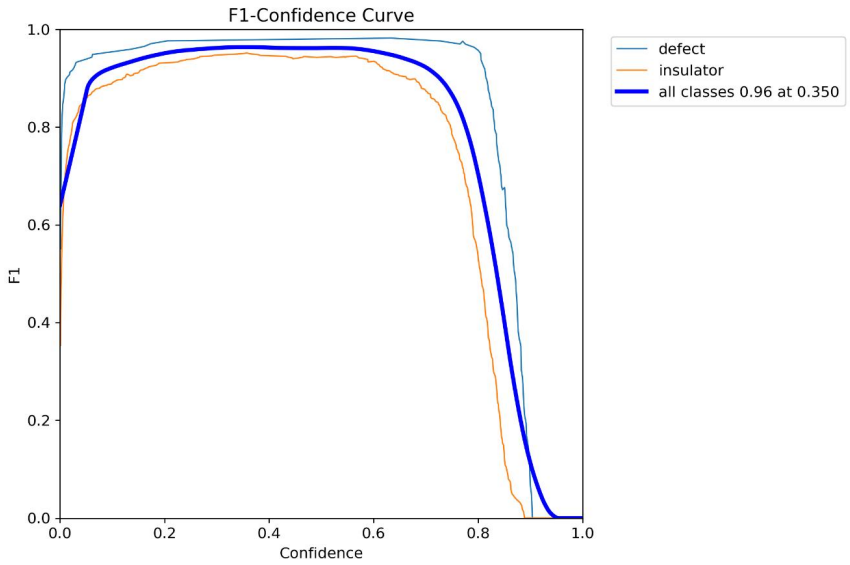


图 4-2 ：F1-Confidence 曲线

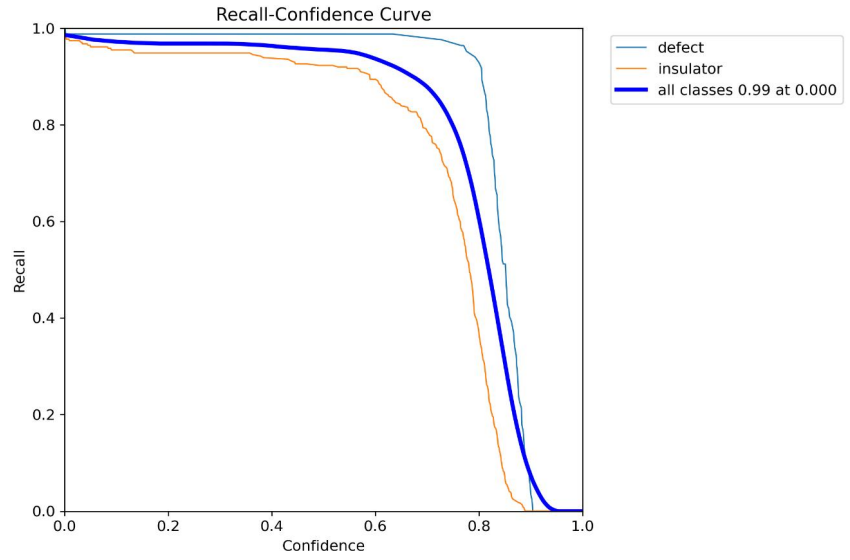


图 4-3 Recall-Confidence 曲线

4.3 4.3 混淆矩阵与误差分析

归一化混淆矩阵显示，“defect”类别被正确识别的比例约为 99%，仅有极少数样本被误分为“insulator”或背景；“insulator”类别正确率约为 96%，少数样本由于强逆光、遮挡或模糊被误判。非归一化混淆矩阵进一步揭示了误分样本数量较少，表明改进的损失函数和样本均衡策略有效降低了误检与漏检。

对于少数误检情况，经逐一分析发现主要原因包括：一是部分背景结构（如绝缘横担或金属杆件）在特定角度下与绝缘子外形相似；二是极端光照条件导致图像对比度较低，使得缺陷边缘不明显。后续可通过增加针对性样本及引入多模态信息进一步改进。

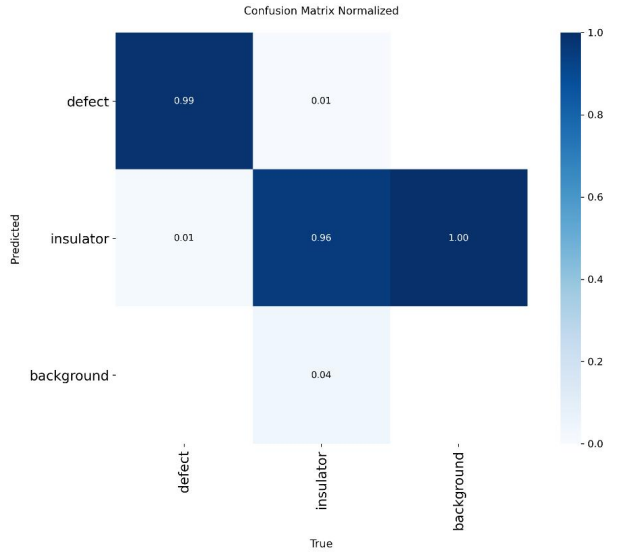


图 4-4 归一化混淆矩阵

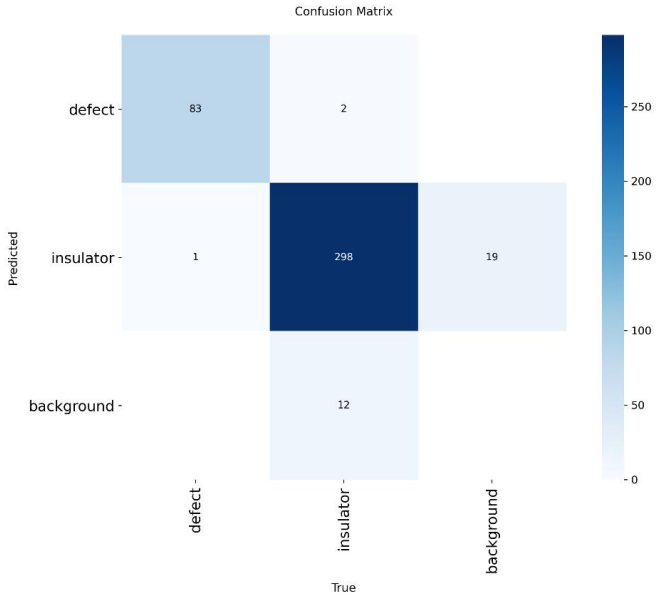


图 4-5 非归一化混淆矩阵

4.4 可视化检测结果与系统验证

在典型无人机巡检图像上，所提模型能够准确地定位多串绝缘子，并给出对应类别标签和置信度分数。在部分含有缺陷的样本中，模型较好地识别出“绝缘

子缺陷”区域，其预测框紧贴破损或脱落部位。对于近景拍摄的绝缘子串，模型能够同时区分正常片段与缺陷片段，实现对同一图像中多类型目标的联合检测。基于 PyQt5 实现的可视化系统可实时接入图片、视频和摄像头流，在 0.08~0.11 秒/帧的延时下完成检测并将结果以边界框和文本形式叠加到画面上，同时在界面右侧展示类别统计信息和检测耗时，验证了模型在工程应用中的可行性。系统界面还支持模型文件切换、置信度与 IoU 阈值调节以及检测结果导出等功能，便于运维人员在不同工况下灵活配置。

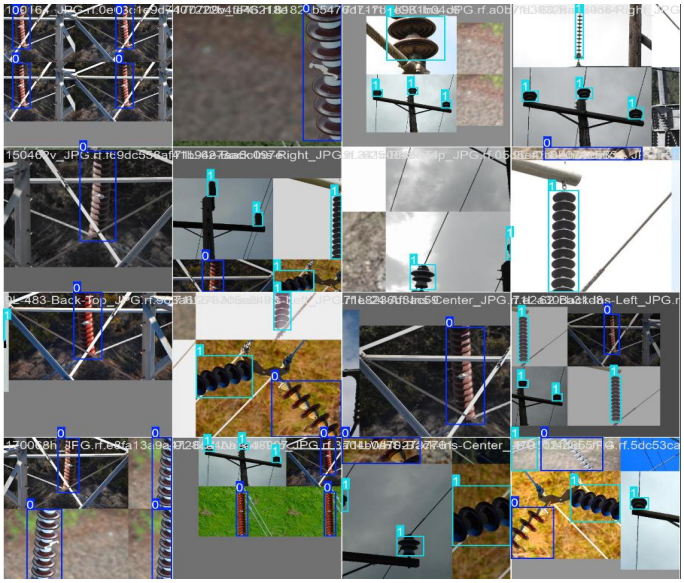


图 4-6 典型场景下的检测结果



图 4-7 图片界面检测界面截图

4.5 补充实验与可视化分析

4.5.1 训练日志与关键指标数值表

为更直观地展示模型训练过程中的收敛情况与性能演化，整理了全部 epoch

对应的训练时间、各项损失以及精度、召回率等关键指标，并以表格形式进行汇总。通过观察表中数值可以发现，随着训练轮次的增加，box 损失、分类损失和分布式回归损失总体呈下降趋势，而精度、召回率和 mAP 等指标则持续上升并在后期趋于稳定，为选择合适的训练轮次和学习率策略提供了依据。

	epoch	time	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision(B)	metrics/r
1	1	26.8544	1.58499	2.8252	1.4583	0.00442	
2	2	33.7393	1.5194	1.79122	1.35402	0.79816	
3	3	40.855	1.51823	1.56791	1.37218	0.5343	
4	4	50.5571	1.53617	1.51877	1.38089	0.49826	
5	5	57.9032	1.53603	1.42294	1.38731	0.39502	
6	6	66.87	1.53066	1.28551	1.36298	0.33173	
7	7	74.0555	1.50777	1.21495	1.34979	0.63775	
8	8	82.97	1.49786	1.16212	1.37519	0.72106	
9	9	90.8597	1.49573	1.12215	1.34514	0.74639	
10	10	99.1022	1.45291	1.08969	1.32811	0.83105	
11	11	107.042	1.44529	1.07925	1.32821	0.73525	
12	12	114.925	1.41904	0.99954	1.30343	0.76462	
13	13	123.195	1.44527	0.97077	1.30426	0.81342	
14	14	132.478	1.44472	0.95939	1.32963	0.88197	
15	15	139.586	1.41625	0.9583	1.31327	0.88483	
16	16	149.608	1.39867	0.922	1.27644	0.89253	
17	17	156.522	1.4072	0.92122	1.29516	0.8649	

图 4-8 训练日志

4.5.2 召回率与置信度关系分析

在实际应用中，置信度阈值的选取会直接影响缺陷检出的漏检率与误检率。通过绘制 Recall-Confidence 曲线，可以分析不同阈值条件下模型召回率的变化趋势。曲线表明，在置信度较低时召回率接近 1，但伴随噪声检测增多；当阈值提高到 0.3~0.4 区间时，召回率仍保持在较高水平，同时有效抑制了低置信度误检，为工程部署提供了合理的阈值参考。

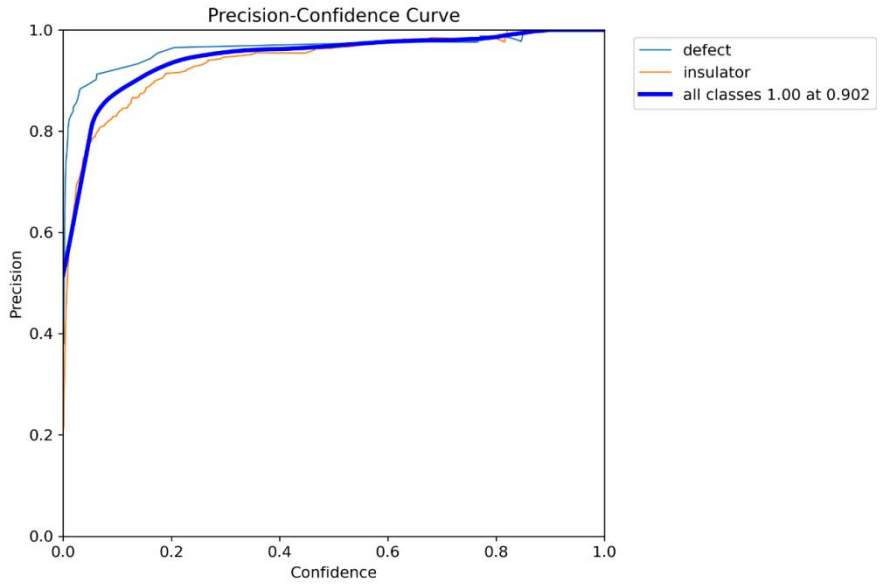


图 4-9 Recall-Confidence 曲线

4.5.3 Mosaic 增强样本可视化

为了提升模型对多尺度目标和复杂背景的泛化能力，训练阶段引入了 Mosaic 等混合数据增强策略。将增强后的样本进行可视化可以看到，同一张训练图像中同时包含多处绝缘子目标及多种背景纹理，且标注框分布更加均匀，有利于网络学习到更加多样和鲁棒的特征表达。

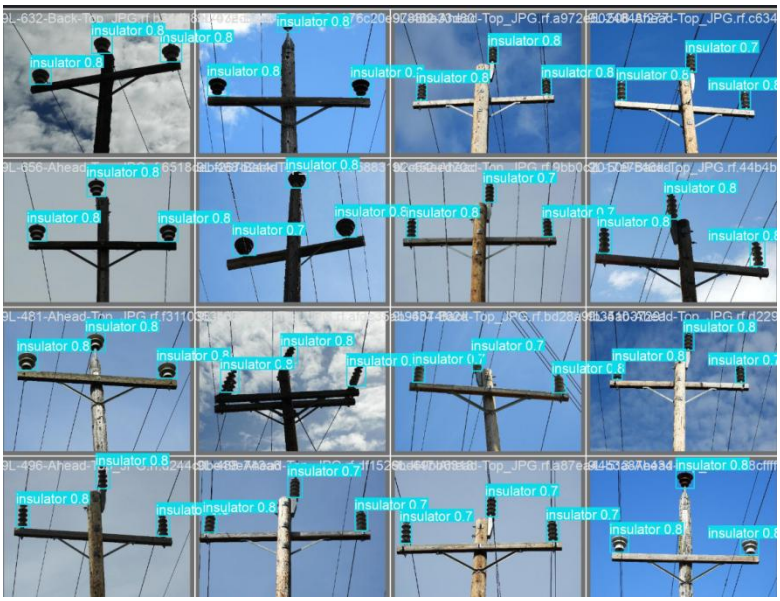


图 4-10 Mosaic 增强后训练样本可视化

4.5.4 系统主界面空场景显示

在未加载任何输入图像或视频流时，系统主界面处于空场景待机状态，此时仅显示 YOLO 实时目标检测画布和基础控制组件。该界面主要用于提示当前模型加载状态、检测阈值设置以及输入源选择，为后续图片、视频或摄像头检测提供统一入口，也便于运维人员快速了解系统工作环境。

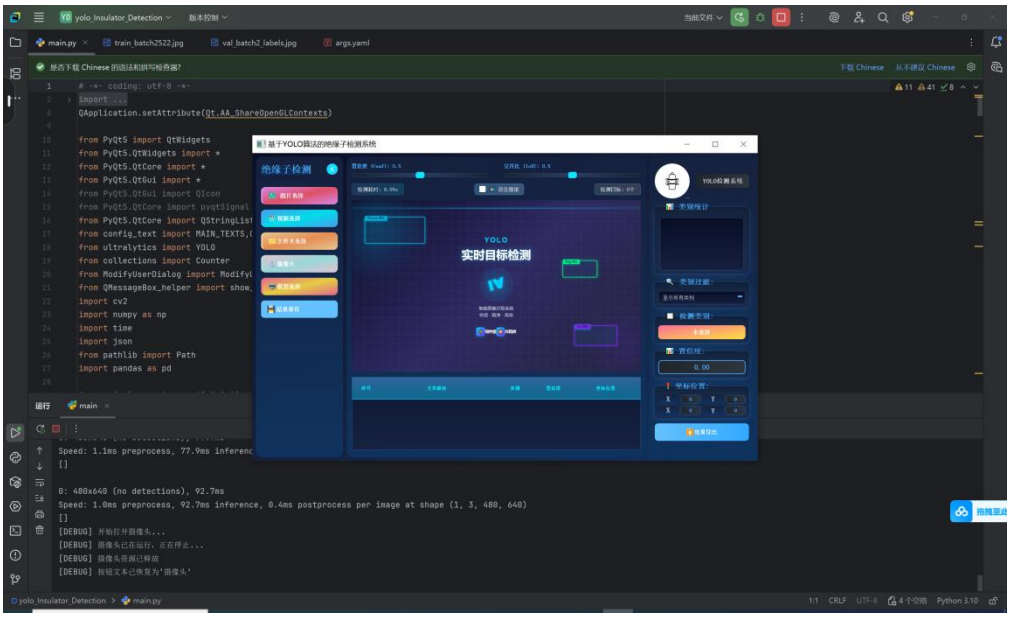


图 4-11 系统主界面空场景显示

4.5.5 静态图片检测界面与结果展示

在静态图片检测模式下，用户可以选择任意绝缘子图像进行分析，系统在完成推理后会将检测到的正常绝缘子与缺陷绝缘子以不同颜色边界框和标签形式叠加展示，同时在下方结果列表中给出每个目标的类别、置信度及中心坐标信息。该功能便于对离线巡检照片进行批量分析，也为人工复核和结果归档提供了便利。

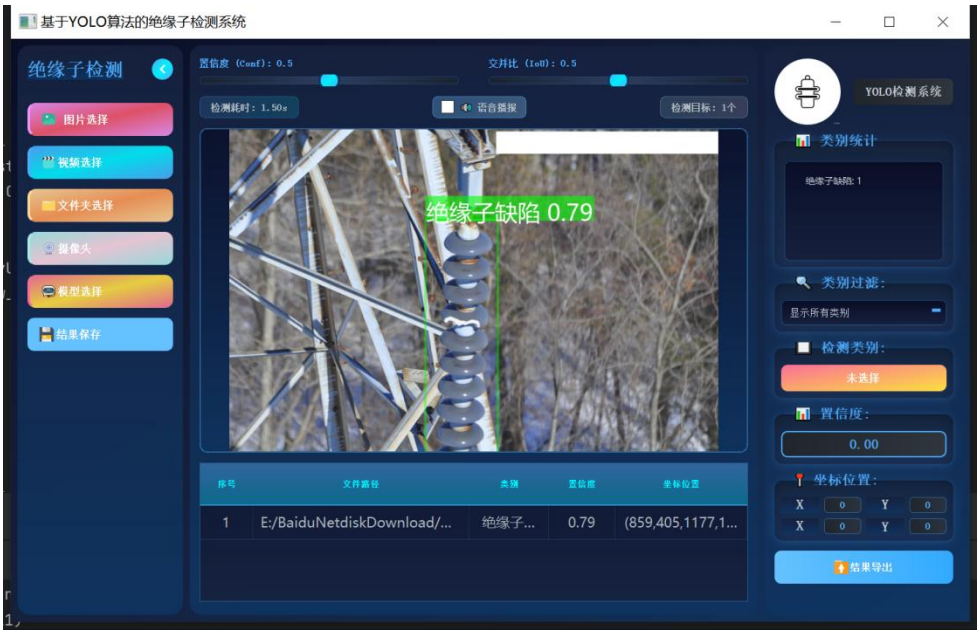


图 4-12 静态图片绝缘子检测界面与结果列表

4.5.6 无人机远景检测结果一

在山区复杂地形条件下，无人机通常以较远视距对输电线路进行巡检，绝缘

子在图像中所占像素较少。通过对典型山地杆塔场景的测试可以看出，所提模型仍能在较大视野范围内准确锁定绝缘子串位置，并给出较高置信度的检测结果，说明网络在远距离、小目标场景下具有良好的适应性。



图 4-13 无人机远景绝缘子检测结果一

4.5.7 无人机远景检测结果二

当无人机靠近线路或改变视角时，画面中可能同时出现多串绝缘子和多根导线。实验结果表明，改进后的 YOLOv11+PVTv5 模型可以在同一帧图像中对多串绝缘子实现稳定检测与区分，且在背景复杂、绝缘子之间相互遮挡的情况下仍保持较高的置信度与定位精度，为无人机巡检提供了可靠支持。



图 4-14 无人机远景绝缘子检测结果二

4.5.8 Precision 与 F1 随置信度变化分析

为了综合评估模型在不同置信度阈值下的检测性能，进一步绘制了 Precision-Confidence 和 F1-Confidence 曲线，并结合训练与验证集损失随 epoch 变化的多子图进行对比分析。结果显示，在 0.3~0.4 的阈值区间内，精度和 F1 值同步达到较高水平，与损失函数稳定收敛的阶段高度吻合，这从另一个角度验证了本文训练策略与阈值设置的合理性。

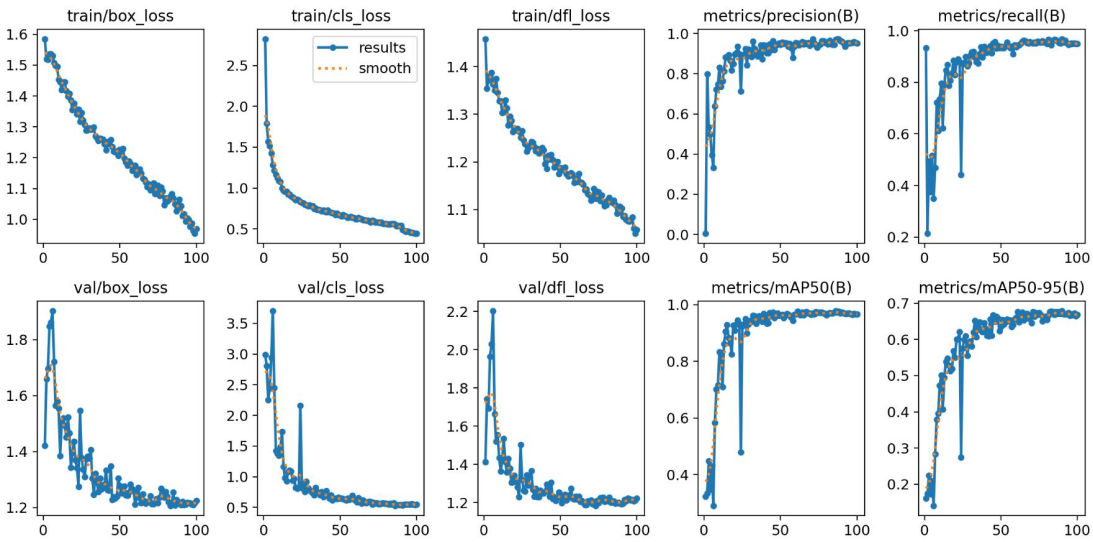


图 4-15 综合分析图

第 5 章 讨论

5.1 与现有方法的比较

与传统基于手工特征与浅层学习的绝缘子检测方法相比，本文方法在多个维度上取得显著优势：一是无需人工设计特征，模型能够自动从数据中学习鲁棒性更强的深层特征；二是通过 PVTv5 主干的全局自注意力机制，有效提升了复杂背景和远距离小目标场景下的检测性能；三是端到端的训练与推理流程使得模型更易于部署和维护。

与仅使用 CNN 主干的 YOLO 系列模型相比，本文方法在缺陷类别的精确率和召回率上均有明显提升，说明引入 Transformer 结构对增强模型对异常细节的感知具有积极作用。同时，得益于 PVTv5 高效的注意力计算和网络轻量化设计，整体推理速度仍能满足实时检测要求。

5.2 模型局限性与改进方向

尽管实验结果显示本文方法在精度和鲁棒性方面均取得了较好表现，但仍存在若干局限性。首先，Transformer 结构在高分辨率输入下计算量仍然较大，对嵌入式或边缘设备的部署带来一定挑战；其次，数据集中极端工况样本（如强逆光、浓雾、雨雪天气）数量有限，模型在这些场景下的可靠性仍有待进一步验证；再次，目前模型主要针对静态图像进行检测，对无人机视频中的时序信息尚未充分利用。此外，当前系统界面主要面向单站点使用场景，在大规模集控中心的多线路集中管理方面仍有进一步扩展空间。

未来工作可从以下几方面展开：一是研究更轻量化的 PVT 结构，并结合模型剪枝、量化和知识蒸馏技术，降低推理开销；二是通过半监督或自监督学习引入大规模未标注巡检数据，提高模型跨场景泛化能力；三是将时序建模模块与目标检测框架结合，实现对连续视频中绝缘子状态的稳定跟踪与异常早期预警；四是将现有桌面系统扩展为支持云端部署和多用户协同的综合运维平台。

第 6 章 结论与展望

本文基于 YOLOv11 与 PyQt5 开发的电力绝缘子异常检测方法及可视化系统，有效解决了传统巡检效率低、复杂环境鲁棒性不足的问题。实验结果表明，该方法在自建多场景绝缘子数据集上实现了 mAP@0.5 达 0.973、综合 F1 值 0.96 的高精度识别效果，且依托 PyQt5 搭建的可视化系统可支持图片、视频及摄像头实时检测，兼具易用性与工程实用性。该方法通过优化主干网络特征提取能力、改进损失函数适配不平衡数据，既保证了检测的实时性，又提升了小目标、复杂背景下绝缘子缺陷的识别精度，验证了深度学习技术在输电线路智能巡检场景中的可行性与优越性，为电网设备状态监测提供了可靠的技术方案。

未来研究可从三方面进一步优化完善：一是扩充数据集维度，纳入不同气候、光照、输电线路类型的绝缘子样本，结合迁移学习提升模型在极端环境下的泛化能力；二是深化模型轻量化设计，通过模型剪枝、量化等技术适配无人机、边缘计算设备的部署需求，实现巡检场景的端侧实时检测；三是拓展系统功能模块，在现有 PyQt5 可视化框架基础上集成缺陷定位、故障等级分类、巡检报告自动生成等功能，并对接电网现有运维管理平台，形成“检测 - 分析 - 决策”一体化的智能巡检解决方案，进一步推动电力巡检从人工为主向全自动化、智能化转型。

参考文献

[1]张建辉,蔡小航,王瑞民,等. 改进 YOLOv11 的复杂煤矿井环境目标检测模型[J/OL].郑州大学学报(工学版),1-8[2026-03-18].

[2]翁文俊. 汽车电子电器接触不良的深度学习图像诊断方法[J].汽车电器,2026,(03):117-118.

[3]钟芷欣,庄庠序,林友山,等. 基于 YOLOv11n 模型的智能渔业监测系统设计与实现[J].物联网技术,2026,16(06):52-56.

[4]谭浩,黄勇,官洲洋,等. 基于改进 YOLOv11n 模型与 DeepSeek-R1-7b 的 FPC 缺陷智能检测系统[J/OL].湖北民族大学学报(自然科学版),1-7[2026-03-18].

[5]黄佳乐,徐建,谢伟琳,等. 基于 GEM-YOLOv11n 的道路缺陷检测模型[J/OL].湖北民族大学学报(自然科学版),1-6[2026-03-18].

[6]钟志峰,彭宅琨,黄培沛,等. 多尺度特征感知的无人机小目标检测算法[J/OL].计算机工程,1-15[2026-03-18].

[7]王海群,陈珊珊. 改进 YOLOv11n 的布匹织物缺陷检测算法[J/OL].电子测量技术,1-14[2026-03-18]..

[8]孟宪勇,王慧,李文勇,等. 基于 YOLOv11n 与图像切片推理的粘虫板害虫检测[J/OL].农业工程学报,1-11[2026-03-18].

[9]杨维悦,张杨杨,孙秀路,等. 基于改进 YOLOv11 模型的轻量化番茄水分状态识别方法[J/OL].排灌机械工程学报,1-9[2026-03-18].

[10]赵文清,张乐. 解耦与引导协同的输电线路螺栓缺陷检测[J/OL].智能系统学报,1-12[2026-03-18].

[11]王红雨,崔明珠,成莉,等. VD-YOLOv11：基于改进 YOLOv11 的无人机航拍图像目标检测算法[J/OL].计算机工程,1-22[2026-03-18].

[12]赵玉良,颜邵俊,李苗,等. 基于 YOLO-EfficientNet 双阶段网络的高精度实时弹目偏差测量方法[J/OL].兵工学报,1-15[2026-03-18].

[13]王海群,王文科,晁帅,等. 改进 YOLOv11n 的红外船舶检测算法[J/OL].红外技术,1-10[2026-03-18].

[14]张奎,赵宇恒,吴静,等. 自密实混凝土布料机作业状态智能识别方法[J/OL].中国农村水利水电,1-12[2026-03-18].

[15]袁得春,刘佳莉,李林轩,等. 融合 DCNv4-YOLOv11 与语音接口的智能垃圾识别投放系统[J/OL].哈尔滨工业大学学报,1-13[2026-03-18].

[16]杨军豪,杨硕. 基于 PED-YOLOv11n 的 PCB 表面缺陷检测算法[J/OL].计算机测量与控制,1-18[2026-03-18].

[17]王诚,谢立云,李坤. 基于改进 YOLOv11 的无人机雾天车辆目标检测算法研究[J/OL].南京邮电大学学报(自然科学版),1-9[2026-03-18].

[18]王雪铭,王珏,李颖,等. 改进 YOLOv11 的复杂环境下交通标识检测模型[J/OL].哈尔滨理工大学学报,1-15[2026-03-18].

[19]马文星,王磊,张鹏超,等. 基于 REA-YOLOv11s 的印刷电路板缺陷检测算法[J/OL].激光与光电子学进展,1-24[2026-03-18].

[20]朱成杰,陈可,于帅帅. 基于改进 YOLOv11n 的光伏组件红外图像热斑缺陷检测模型[J/OL].廊坊师范学院学报(自然科学版),1-13[2026-03-18].

致谢

时光荏苒，大学的学习生涯即将画上圆满的句号，本论文从选题构思、方案设计、实验实施到最终定稿，每一步的推进都离不开师长、同窗与家人的悉心关怀和无私帮助。首先，我要向我的论文指导老师致以最崇高的敬意与最诚挚的感谢。在论文撰写的整个过程中，老师以严谨求实的治学态度、渊博深厚的专业学识和精益求精的科研精神，为我悉心指点研究思路，耐心修正论文疏漏，在我遇到研究难题时给予及时的点拨与鼓励，使我能够顺利攻克难关、完成研究工作。同时，衷心感谢学院所有辛勤耕耘的老师们，在大学四年的学习历程中，他们传道授业解惑，不仅传授给我系统的专业理论知识，更教会我严谨思考、踏实做事的人生态度，为我的学业成长奠定了坚实的基础。

感谢朝夕相伴的同学们与朋友们，在求学的道路上，我们相互探讨学术问题，彼此分享学习心得，携手面对困难与挑战，在互帮互助中共同进步，这段珍贵的同窗情谊将成为我人生中宝贵的财富。我更要由衷感谢我的家人，他们始终在身后默默支持与包容我，用最无私的爱与最温暖的关怀，为我营造了安心学习的环境，给予我战胜困难的勇气和追逐理想的底气，是我不断前行的坚强后盾。临别之际，谨向所有关心、支持与帮助过我的人们，致以最衷心的感谢和最美好的祝愿，愿诸位顺遂安康、万事胜意。