

基于改进 YOLOv10 的输电线路缺陷检测算法

陈 诺, 徐懂理

(南京工程学院 电力工程学院, 南京 211167)

摘要: 针对无人机进行电力巡检时对于输电线路缺陷的检测精度较低的问题, 提出了一种基于 YOLOv10n 的改进缺陷检测算法; 其具体结构为在 Backbone 中添加轻量级卷积神经网络注意力模块 CBAM, 使得改进后的网络模型在通道和空间两个方面更加关注输电线路导线缺陷的特征, 降低漏检、错检率; 将 YOLOv10n 中原来的特征融合框架替换为双向特征金字塔网络 BiFPN, 该网络在原始的 FPN 模块中添加了上下文信息的边, 并对每个边乘以一个相应的权重, 通过不同的权重映射不同的学习特征, 因此增加对贡献较大的特征映射; 在空间金字塔池化模块通过结合 ELAN, 使模型能更有效地识别小目标特征; 经过一系列的实验证明, 改进后的模型准确率达到 85.8%, 召回率达到 80.8%, mAP 达到 87%, 各种指标在一定程度上都得到了提升; 由此可见改进的算法提高了检测精度, 在输电线路巡检中具有较广泛的应用前景。

关键词: 电力巡检; 目标检测; 注意力机制; YOLO

A Transmission Line Defect Detection Algorithm Based on Improved YOLOv10

CHEN Nuo, XÜ Dongli

(School of Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: An improved defect detection algorithm based on YOLOv10n is proposed to address the issue of low detection accuracy for transmission line defects during UAV power inspections. The specific structure is to add a lightweight convolutional neural network (CNN) attention module, CBAM, to the Backbone, enabling the improved network model to focus more on the features of transmission line conductor defects in both the channel and spatial dimensions, which reduces the rates of missed and false detection. Additionally, the original feature fusion framework in YOLOv10n is replaced with a bi-directional feature pyramid network (BiFPN). This network adds context information edges to the original FPN module and multiplies each edge by a corresponding weight. By assigning different weights to various learning features, the network emphasizes the feature mappings with greater contributions. In the spatial pyramid pooling module, combining with the ELAN to make the model more effective in detecting small target features. Experimental results show that the improved model achieves an accuracy of 85.8%, a recall rate of 80.8%, and a mAP of 87%. These indicators have made an increase to a certain extent, indicating that the proposed algorithm enhances detection accuracy and has broad application prospects in transmission line inspection.

Keywords: power inspection; object detection; attention mechanism; YOLO

0 引言

随着经济的快速发展, 我国的电力系统规模不断扩大, 这就对其供电可靠性提出了更高的要求。高压输电线路在电力系统中承担着传输、调节和分配等关键职能, 是确保我国电网安全与稳定运行的重要组成部分。

目前, 我国的高压输电线路导线普遍采用钢芯铝绞线, 这些导线长期暴露在自然环境中, 容易受到恶劣天气的影响, 会导致表面损伤甚至断股。电力巡检是保证电力系统供电可靠性的关键环节, 也是保证电力线路安全运行的核心部分。目前, 针对输电线路导线的缺陷检测方法主要有传统人工巡检、直升机巡检^[1]、机器人巡检^[2]

收稿日期: 2024-10-13; 修回日期: 2024-11-20。

基金项目: 山东省重点研发计划(科技示范工程)课题(2021SFGC0701); 青岛市海洋科技创新专项(22-3-3-hygg-3-hy)。

作者简介: 陈 诺(2000-), 女, 硕士研究生。

引用格式: 陈 诺, 徐懂理. 基于改进 YOLOv10 的输电线路缺陷检测算法[J]. 计算机测量与控制, 2025, 33(11): 104-110, 117.

以及无人机巡检^[3]。虽然传统的人工巡检方式较为精准,但由于电网容量不断扩大,设备大量增加,人工输电线路巡检方法也越来越困难^[4]。因此,直升机、机器人、无人机巡检逐渐取代了人工巡检,但直升机的成本高昂且培训相关人员也需要一定的资源投入,因此在巡检任务中逐渐被淘汰。机器人虽然大大降低了巡检成本,但其移动范围和速度受限,寿命有限,传感器性能和操作维护的复杂性等等限制了其在电力巡检中的应用范围。相比之下,无人机可以在不同的气候条件下作业,做到实时监控,达到远程操作,因此,无人机正逐渐成为输电线路检测的首选方案,是电力行业巡检方式的重大创新和突破^[5]。

利用无人机进行输电线路图像采集的同时还需要结合图像处理技术对采集的导线图像进行识别与分类,这种方法有效解决了许多传统检测中遇到的问题。目前,图像处理方法主要包括传统图像处理技术^[6]、图像分割技术以及基于深度学习图像检测技术等等。传统检测通常侧重于提取输电线路的颜色、纹理和形状等特征,其过程繁琐,耗时,因此逐渐被基于深度学习的图像处理技术所取代。深度学习是机器学习的一个子领域,通过多层神经网络模型模拟人脑进行数据分析和模式识别,能够自动从大量数据中提取复杂特征,用于图像识别、自然语言处理等多种应用,显著提升了人工智能的性能和能力,同时也为输电线路巡检工作做出极大贡献。目前,基于深度学习的输电线路巡检的算法主要分为两大类:单阶段方法(One-stage)和两阶段方法(Two-stage)。两阶段方法通常分为两个步骤:第一阶段是候选区域生成,即利用区域生成网络(RPN, region proposal network)快速扫描整个图像以生成一组潜在的目标区域;第二阶段是对这些候选区域进行进一步的特征提取和精细分类,从而确定目标类别和精确位置。这种方法典型代表是 R-CNN 系列。文献[7]中所采用的检测方法就是将 Faster R-CNN 应用于无人机进行电力巡检工作,尽管其检测效果显著,但在实时性方面仍存在不足。单阶段方法的特点就是在一个单一的神经网络中同时完成目标位置预测和类别分类,从而实现快速且高效的检测。其代表性算法包括 SSD (Single Shot MultiBox Detector) 和 YOLO (You Only Look Once)。SSD 算法^[8]具有检测速度快和适用于实时应用的优点,但在小物体检测上的精度存在局限性。为解决以上难题,Joseph Redmon 等在 2015 年首次提出 YOLOv1。但 YOLOv1 在识别物体位置精准性方面存在局限性,检测较小物体时的性能相对较差。后续更新的 YOLO 版本在预测精度方面都有很大的提升。文献[9]中对于输电线路的异物检测,采用了改进的 YOLOv3 算法,该算法将 Dense-net 网络与 YOLOv3 网络相结合,从而

建立新的深度学习模型,使得识别准确率大幅提升。罗潇等^[10]分析了复杂环境下各类算法对于输电线路部件的检测效果,提出了改进的 YOLOv3 网络模型,与原模型相比精确度提高了 6.7%,具有更优的识别精度和检测速度。

目前 YOLO 系列已迭代到 v10 版本,在小目标检测准确性和训练速度上都有了很大的改善。YOLOv10 在网络架构方面引入了更深更宽的网络结构,增强了模型的表达能力,同时使用了轻量化设计,减少计算复杂度。其中 YOLOv10 的一大显著特点是采用了特征金字塔网络 FPN (Feature Pyramid Network) 和路径聚合网络 PANet (Path Aggregation Network),提高了对不同尺度目标的检测能力。并且引入自注意力机制,增强了对全局上下文信息的理解,提高了检测精度。该模型还在数据增强、损失函数等环节都进行了优化,使得在保持实时检测速度的同时,显著提升了检测的准确性和鲁棒性,这使得 YOLOv10 成为了输电线路巡检的理想选择。为了使模型在面对电力设备的复杂场景时,能够实现进一步的精确性和鲁棒性,提出了改进的 YOLOv10 输电线路缺陷检测方法。本文主要贡献如下:

1) 为了更好地验证改进算法的有效性,将利用图像增强等技术手段对数据进行增强与扩充,并使用 Labeling 对数据集进行标注。

2) 由于电力巡检实际场景背景复杂,输电线路缺陷自身特征不足,因此在 YOLOv10n 网络模型的 Backbone 部分加入注意力机制 CBAM (Convolutional Block Attention Module)。该方法通过协同通道与空间注意力,全局分析特征图并自适应加权关键通道,以增强模型对复杂背景中输电线路缺陷的甄别能力。提高模型对输电线路缺陷的检测精度。

3) 针对输电线路缺陷形状、大小不一,使用更优的 BiFPN (Weighted Bi-directional Feature Pyramid Network) 替换原来的特征金字塔网络。BiFPN 通过赋予不同尺度不同的权重值旨在优化多尺度特征的平衡性,重点提升模型对输电线路小尺寸缺陷的检测能力。

4) 引入改进的空间金字塔池化结构 SPPFELAN (Spatial Pyramid Pooling with Efficient Layer Aggregation Network),该结构在 SPP 的基础上融合 ELAN (Effective Long-Range Aggregation Network) 注意力机制,通过在多个尺度上进行池化,使得网络模型可以进行多尺度特征提取,增强模型在复杂背景下的小目标识别能力。

1 改进型缺陷检测算法

1.1 YOLOv10 算法概述

YOLOv10 是 YOLO 系列中最新且最先进的目标

检测模型, 改进了以往 YOLO 模型必须依赖 NMS 的后处理, 从而导致部署推理效率不理想的问题, 实现了高效和有竞争力的性能。其模型结构和工作原理体现了深度学习在计算机视觉领域的前沿进展。YOLOv10 的模型结构主要由 3 个部分组成: Backbone、Neck 和 Head, 各部分协同工作, 以实现高效、准确的目标检测。Backbone 部分负责从输入图像中提取基本特征。该部分主要包括 C2f、C2fCIB、SPPF、PSA 等模块。C2f 模块由多个卷积层连接操作来提取特征, 并将这些特征融合在一起。C2fCIB 模块通过在特征映射上添加恒等映射, 可以更好地保留特征信息, 同时加快收敛速度。SPPF 模块通过不同尺寸的池化窗口, 能够捕捉图像中不同尺度的特征, 增强模型的鲁棒性。PSA 模块用于关注图像中的重要区域。它通过并行空间注意力机制, 增强了模型对重要特征的关注, 提升了检测精度。Neck 部分, 它负责进一步处理和融合 Backbone 提取的特征图。在 YOLOv10 中, Neck 部分采用了结合 PANet 和 FPN 的设计。FPN 通过不同层次的特征融合, 可以增强模型对不同尺度目标的检测能力, 而 PANet 则通过路径聚合的方式进一步提升了特征的表达和利用。这种组合有效地提高了小目标检测的性能, 同时保持了大目标检测的精度。Head 部分, 它负责进行最终的目标检测和分类。YOLOv10 的 Head 部分结合一对一和一对多匹配的优势, 引入额外的一对一 Head 结构, 该结构与原始的一对多分支相同, 并采用相同的优化目标, 但使用一对一分配方式来确定标签分配, 在训练过程中两个 Head 联合优化, 享受一对多匹配的丰富监督, 推理时只使用一对一头, 避免额外推理成本。这种设计使得 YOLOv10 可以在不牺牲性能的情况下, 实现端到端部署, 减少推理成本。总之, YOLOv10 通过结构设计与训练策略的创新, 在目标检测任务中取得了卓越性能。其高效的多尺度检测能力, 使之成为计算机视觉领域的重要基准模型。




图 1 YOLOv10 模型结构简图

1.2 卷积神经网络注意力模块

研究证明, 添加注意力机制能够非常有效地增强卷积神经网络的表征能力。在含有各种输电线路缺陷的数据集中, 许多图像中包含了复杂的背景与高相似度的目标。为在这种复杂背景中更加精准地识别出目标的特征, 本文在 Backbone 部分引入 CBAM 模块^[10]。CBAM 神经网络模块主要用于图像分类和目标检测, 其旨在通过引入注意力机制来提升网络的表达能力和泛化能力。CBAM 包含两个顺序子模块分别是通道注意力模块和空间注意力模块, 这种机制能够进一步突出输电线路缺陷的标志性特征, 其结构如图 2 所示。




图 2 CBAM 注意力机制

图中 CBAM 模块包括两个部分: 第一部分是通道注意力模块 CAM (Channel Attention Module), 第二部分是空间注意力模块 SAM (Spatial Attention Module)。在通道注意力部分, 首先对输入特征图 F 进行全局最大池化和全局平均池化下采样, F 由原来的 $H \times W \times C$ 变成两个 $1 \times 1 \times C$ 的特征图, 接下来将这两个特征图送入到两个全连接层 [MLP] 中, 最终会输出两个 $1 \times 1 \times C$ 的特征图, 再将这两个特征图相加后, 通过 sigmoid 激活函数处理, 生成通道注意力特征图, 即图中的 M_c , 其尺寸为 $1 \times 1 \times C$ 。以上过程的公式表示如下:

$$M_c(F) = \sigma\{\text{MLP}[\text{AvgPool}(F)] + \text{MLP}[\text{MaxPool}(F)]\} = \sigma\{W_1[W_0(F_{\text{avg}})] + W_1[W_0(F_{\text{max}})]\} \quad (1)$$

式中, M_c 为通道注意力特征图; σ 为 sigmoid 函数; MLP 为共享神经网络; AvgPool 为平均特征点; MaxPool 为最大特征点; F_{avg}^c 为平均池化特征; F_{max}^c 为最大池化特征。

第二部分空间注意力更加关注目标的位置信息, 该机制与通道注意力形成互补, 二者结合进一步强化特征融合, 使得最终输出的特征图含有更丰富、更全面的高层特征。该部分首先将前一步的得到的特征图像 M_c 与

F 相乘, 得到特征图 F' 作为输入图像, 并对其进行最大池化和平均池化操作得到两个 $1 \times H \times W$ 的特征图, 在经过卷积操作对两个特征图进行拼接, 通过 7×7 卷积变为 1 通道的特征图, 再经过一个 sigmoid 得到空间注意力的特征图 M_s , 其尺寸为 $H \times W \times 1$ 。这个过程用公式表示为:

$$M_s(F) = \sigma\{f^{7 \times 7} \{[\text{AvgPool}(F); \text{MaxPool}(F)]\}\} \\ = \sigma\{f^{7 \times 7} [F_{\text{avg}}^s; F_{\text{max}}^s]\} \quad (2)$$

式中, M_s 为空间注意力特征图; $f^{7 \times 7}$ 为 7×7 的卷积运算; F_{avg}^s 为平均池化特征; F_{max}^s 为最大池化特征。

1.3 改进的特征金字塔网络 (BiFPN)

在视觉检测任务中, 特征金字塔网络 FPN 是一种常用的方法, 它通过构建不同尺度的特征图来捕获不同尺度的目标。然而, 传统 FPN^[11] 仅具备自上而下的单向信息流 (结构如图 3 (a) 所示), 导致底层特征语义信息不足。为此, 研究者提出了路径聚合网络 PANet, 增加自底向上的路径增强特征, 在较低层中使用准确的定位信息来增强整个特征层次结构, 从而缩短了较低层与最高特征之间的信息路径, 其结构如图 3 (b) 所示。FPN 和 PANet 在融合时会添加不同的输入特征, 其输入分辨率的不同, 导致融合效果不一致。为解决此问题, 在原网络的基础上引入加权双向特征金字塔 BiFPN。在 BiFPN 中, 每个级别都包含两个路径: 一个是自底向上的路径, 用于增强底层特征; 另一个是从顶部到底部的路径, 通过跨层级融合的方式, 使得顶层的高级语义信息能够传达给底层。这样做的目的是为了捕获更丰富、更大范围的上下文信息, 提高特征表示的精确性和鲁棒性, 其结构如图 3 (c) 所示。




图 3 特征金字塔结构对比图

PANet 在特征融合时仅采用简单的相加操作 (如下式所示), 未能考虑不同分辨率输入对特征贡献的差异性。为此, BiFPN 引入了可学习的权重来调整不同特征的重要性。以下以该网络中第 6 层的两个融合特征为例进行说明。其计算过程如下式所示:

$$P_6^{\text{nl}} = \text{Conv}(P_6^{\text{m}} + \text{Resize}(P_7^{\text{out}})) \quad (3)$$

$$P_6^{\text{out}} = \text{Conv}(P_6^{\text{nl}} + \text{Resize}(P_5^{\text{out}})) \quad (4)$$

$$P_6^{\text{nl}} = \text{Conv}\left(\frac{\omega_1 P_6^{\text{m}} + \omega_2 \text{Resize}(P_7^{\text{m}})}{\omega_1 + \omega_2 + \varepsilon}\right) \quad (5)$$

$$P_6^{\text{out}} = \text{Conv}\left(\frac{\omega'_1 P_6^{\text{m}} + \omega'_2 P_6^{\text{nl}} + \omega'_3 \text{Resize}(P_5^{\text{out}})}{\omega'_1 + \omega'_2 + \omega'_3 + \varepsilon}\right) \quad (6)$$

式中, P_6^{nl} 是自上而下路径级别 2 的中间功能, P_6^{out} 是自下而上路径级别 6 处的输出特征。

1.4 改进的空间金字塔池化模块

Yolov10 结构中采用的是 SPPF 模块, 该模块是在空间金字塔池化 (SPP) 结构的基础上, 进一步增强了基准模型中的空间金字塔池化-FAST 模块 (SPPF)。SPPF 模块包含 3 个连续的池化层, 通过结合大核卷积和非膨胀卷积来扩大感受野。同时, 相较于 SPP 模块, SPPF 降低了计算复杂度并显著提高了处理速度, 能够实现自适应的输出尺寸。然而, 尽管持续的池化操作有助于减少参数, SPPF 在有效整合小且细粒度的特征信息方面仍然存在挑战^[12]。为了进一步提高模型对目标的关键特征提取能力, 避免特征在信息融合过程中被稀释, 进而影响检测精度的问题。提出了一个改进方案——SPPELAN, 该结构引入高效层聚合网络 (ELAN) 的注意力机制, 与原来的 SPPF 结构相结合, 其结构如下图所示。其中 ELAN 模块是一种用于捕捉长距离依赖性的神经网络模块。该模块的核心思想是引入注意力机制, 以便模型能够有效地捕捉全局上下文信息。经研究证明, 改进后的模块使得模型对目标细节的捕捉能力, 尤其是对小目标的识别能力有了显著的提升, 同时还保持了较高的运算效率。




图 4 SPPELAN 模块

1.5 改进的 YOLOv10 算法

无人机在检测输电线路缺陷的过程中, 拍摄得到的输电线路缺陷图片背景复杂, 缺陷的形态与尺寸各异, 传统网络难以充分提取关键特征, 易导致漏检与误检。为此, 本文构建了基于 YOLOv10n 的改进网络结构 (见图 5)。具体改进如下: 在骨干网络 (Backbone) 中引入 CBAM 注意力机制, 以抑制复杂背景干扰, 提升目标定位准确性; 同时改进空间金字塔模块, 增强局部与全局特征的融合能力, 在保持计算效率的同时丰富特征表征。在检测头 (Head) 部分, 采用双向特征金字塔网络 (BiFPN) 替代原结构, 通过加权融合不同尺度的特征, 增强了对小尺寸缺陷的检测性能。




图 5 基于 YOLOv10 的改进算法网络结构图

2 实验准备

2.1 数据集预处理

采用无人机拍摄的输电线路照片组成的数据集，含有 852 张原始图像，其中每张图像的分辨率为 1 152×864，图像中包含不同背景下的大小不一的缺陷。然而，由于原始数据集的规模有限，可能导致模型出现过拟合，因此本文将通过对原始数据集进行图像增强、翻转、缩放等数据增强技术，将数据集扩充至 2 900 张。图 6 中展示了数据增强的结果。使用 Labelimg 工具对数据集中导线的缺陷部分进行了标注，并制定标签。最后将标好的数据按照 8 : 1 : 1 的比例划分为训练集、验证集和测试集，目的是为了提高网络模型的泛化能力。

2.2 模型训练参数配置

实验在 Windows11 上运行，硬件采用 NVIDIA GeForce RTX 4060、i7-13650HX、16 GB 内存。使用 PyTorch 框架对 YOLOv10 网络模型进行训练，CUDA 版本为 11.8。训练过程中，输入图片尺寸大小为 640×640，每训练一次的 Batch-size 为 4，共训练 300 个 Epoch，训练时长约为 4 h。训练的其他超参数设置如表 1 所示。

表 1 训练模型参数设置

名称	数值	注释
Learning Rate	0.01	学习率
Momentum	0.937	动量
Epoch	300	迭代次数
weight_decay	0.005	权重衰减




图 6 数据增强

2.3 模型训练评价指标

为了更加客观准确地验证模型的效果以及稳定性，采用精度（Precision）、召回率（Recall）和平均精度（mAP）作为模型性能的评估指标，其计算公式如下。其中，TP 代表被正确预测的缺陷样本数量；FP 代表将非缺陷样本错误预测为缺陷的数量；FN 代表将缺陷样本错误预测为非缺陷的数量；TN 代表被正确预测的非缺陷样本数量。即预测为非缺陷且实际也是非缺陷的样本。AP 是针对单个检测对象的精度，而 mAP 则是对所有检测对象的平均精度：

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

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

$$AP = \int_0^1 P(R) dR \tag{9}$$

$$mAP = \frac{\sum P_A}{N_c} \tag{10}$$

3 实验分析

3.1 不同权重模型实验对比

预训练权重是在大规模数据上预先训练好的模型参数，这些权重通常用于初始化模型，以便在特定任务上进行微调。这一策略极大地加快了训练过程，并能提高模型在特定数据集上的表现。使用预训练权重在加快收敛速度的同时还能提高模型的泛化能力，避免过拟合。

因此，选择合适的权重模型是提升国家电网输电线路检测性能的关键。不同权重模型在数据集上的性能对比结果如表 2 所示。

从表 2 中可以看出，不同的权重模型对于数据集的检测精度和检测速度均有影响。yolov10n.pt 对数据集检

表 2 不同权重模型对比试验结果

权重模型	$P/\%$	$R/\%$	$mAP@0.5/\%$
yolov10m.pt	77.2	76.3	82.6
yolov10n.pt	79.2	77.4	83.9
yolov10l.pt	76.0	65.4	76.3
yolov10b.pt	70.5	65.2	78.9

测的 mAP 值为 83.9%，精度为 79.2%，召回率为 77.4%，指标都略高于其他权重模型。由此可见 yolov10n.pt 是最适合本文数据集的权重模型，因此后续的消融实验以及对比试验将在 yolov10n.pt 上进行。

3.2 不同注意力机制实验对比

为评估 CBAM 注意力机制的有效性，本实验在 YOLOv10 模型上对比了 SE、EMA 及 CBAM 三种模块的性能表现。SE 注意力机制是一种通道注意力，该结构通过学习通道权重来增强网络对不同通道的注意力，因此它需要对每个通道进行一次卷积操作，这就增加了计算量，降低了模型的训练速度；EMA 注意力机制是通过利用滑动平均来计算每个通道的重要性，从而对输入进行加权，更好地关注重要的通道，因此就避免了对每个通道进行卷积，降低了计算量，且提高了模型的训练速度。以上两种算法都只是关注了通道上的目标特征，而 CBAM 注意力机制不仅关注通道上的目标特征，还对空间维度上的目标特征进行加权，因此结合 CBAM 注意力机制改进的 YOLOv10 模型在训练时更加全面地关注输电线路上的缺陷区域。表 3 中数据是加入不同注意力机制的实验结果。

表 3 不同注意力机制对比实验结果

模型	$P/\%$	$R/\%$	$mAP@0.5/\%$
yolov10n	79.2	77.4	83.9
yolov10n+SE	80.7	78.6	85.0
yolov10n+EMA	76.9	77.9	82.7
yolov10n+CBAM	84.6	78.7	88.7

表 3 结果表明，引入注意力机制后，模型检测精度得到显著提升。结合 CBAM 注意力机制的模型性能提升的更加显著，与原网络模型相比 mAP 值（即平均精度）增加了 4.8%，精度值增加了 5.4%，召回率增加了 1.3%。实验表明，在背景复杂的输电线路图像检测中，CBAM 注意力机制展现了其能够综合通道和空间维度上的输电线路导线缺陷特征的优势，证明了该机制在强化关键特征识别上的有效性。

3.3 模型改进的消融实验

为验证 CBAM 注意力机制、BiFPN 特征融合模块及改进的 SPPELAN 模块的有效性，本研究设置了消融实验。各模型配置的迭代次数与 mAP 值对比如图 7 所示。

本研究以 YOLOv10n 为基线模型，通过消融实验，




图 7 消融实验 mAP 结果

依次嵌入各改进模块以评估其性能贡献，实验结果如表 4 所示。其中模型 1 为加入 CBAM 注意力机制的 YOLOv10 模型，模型 2 为加入 BiFPN 的 YOLOv10 模型，模型 3 为加入 SPPELAN 的 YOLOv10 模型。“×”表示未加入相应模块，“√”表示加入了相应模块。

表 4 消融实验结果

模型	CBAM	BiFPN	SPP-ELAN	$P/\%$	$R/\%$	$mAP@0.5/\%$
yolov10n	×	×	×	79.2	77.4	83.9
yolov10n+CBAM (模型 1)	√	×	×	84.6	78.7	84.9
yolov10n+BiFPN (模型 2)	×	√	×	83.1	79.5	86.2
yolov10n+SPPELAN (模型 3)	×	×	√	84.7	77.6	84.4
改进算法(模型 4)	√	√	√	85.8	80.8	87.0

由上述实验数据可知，原 YOLOv10 网络模型在本文数据集上的 $mAP@0.5$ 为 83.9%，模型 1、模型 2、模型 3 和模型 4 的 $mAP@0.5$ 相比于原模型分别提升 0.8%、2.3%、0.5%、3.1%。由此可见，各项改进均有效提升了模型性能，最终验证了本次算法改进方案的有效性。

原网络模型与改进的网络模型进行检测对比，检测结果如图 8 所示。




图 8 网络模型改进前后检测对比图

3.4 对比试验

为验证所提算法的性能优势，将其与当前电力巡检中常用的几种缺陷检测算法进行对比，包括 YOLOv3、改进的 YOLOv5、YOLOv6 及改进的 YOLOv8。模型性能对比结果如表 5 所示。

表 5 不同算法对比试验结果

算法	$P/\%$	$R/\%$	$mAP@0.5/\%$
yolov3	82.6	70.4	78.7
yolov4	80.8	66.2	75.7
改进 yolov5	83.9	77.3	80.1
yolov6	82.3	80.1	80.3
改进 yolov8	84.7	78.6	84.1
改进算法	85.8	80.8	87.0

由表 5 中数据可知，所有对比模型在输电线路缺陷检测任务中均表现良好，其 mAP 值均超过 75%。本文所提改进模型的 mAP 值达到 87%，优于其他五种对比方法，体现出更优的综合检测性能。

其中 YOLOv3 和 YOLOv4 的召回率较低，分别为 82.6%，80.8%，因此这两个网络模型对于本文采用的数据集存在一定的漏检。就网络模型的精度而言，所有的网络模型的精度都相差不大，但改进的网络模型的检测精度要高于其他模型。改进的 YOLOv8 的召回率与其他模型对比相对较高，但其性能指标相对于改进网络模型略差一些。




图 9 不同网络模型检测结果图

4 结束语

在输电线路巡检中，由于其背景复杂，线路的缺陷大小不一，为实现精准检测，本文提出一种基于 YOLOv10n 的改进算法。其一，在骨干网络中嵌入 CBAM 注意力机制，以增强关键信息的表征能力；其二，引入 BiFPN 双向特征金字塔网络替代原结构，以优化多尺度特征融合，进一步加强了特征融合，提高模型对小目标的识别能力。此外，还在 SPP 模块中引入

ELAN，提高模型的检测能力。通过一系列的消融实验、与其他电力巡检主流算法的对比实验证明，本文提出的改进算法与其他算法相比具有优越性，其检测精度为 85.8%，与原模型相比提高了 6.6%；召回率为 80.8%，与原模型相比提高了 3.4%； mAP 为 87.0%，比原模型提高了 3.1%。不仅如此，改进后的网络模型还可以利用根据数据集训练好的模型参数进行实时检测。因此，本文中的改进算法在输电线路巡检中具有良好的应用前景^[13-20]。

参考文献：

[1] YANG L, FAN J, LIU Y, et al. A review on State-of-the-Art power line inspection techniques [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69 (12): 9350 – 9365.

[2] KATRASNIK J, PERCUS F, LIKAR B. A survey of mobile robots for distribution power line inspection [J]. IEEE Transactions on Power Delivery, 2010, 25 (1): 485 – 493.

[3] NGUYEN V N, JENSSEN R, ROVERSO D. Automatic autonomous vision-based power line inspection: A review of current status and the potential role of deep learning [J]. International Journal of Electrical Power & Energy Systems, 2018, 99 (JUL.): 107 – 120.

[4] 吴功平, 肖晓晖, 申瑞刚. 高压输电导线的损伤检测与故障诊断 [J]. 仪器仪表学报, 2006 (10): 1204 – 1208.

[5] MATIKAINEN L, LEHTOMAKI M, AHOKAS E, et al. Remote sensing methods for power line corridor surveys [J]. Isprs Journal of Photogrammetry & Remote Sensing, 2016, 119: 10 – 31.

[6] 刘新慧. 输电线路导线断股与损伤的图像识别算法研究 [D]. 西安: 西安工程大学, 2018.

[7] 王万国, 田兵, 刘越, 等. 基于 RCNN 的无人机巡检图像电力小部件识别研究 [J]. 地球信息科学学报, 2017, 19 (2): 8.

[8] SIDDQUI Z A, PARK U. A drone based transmission line components inspection system with deep learning technique [J]. Energies, 2020, 13 (13): 3348.

[9] 杨剑锋, 秦钟, 庞小龙, 等. 基于深度学习的输电线路异物入侵监测和识别方法 [J]. 电力系统保护与控制, 2021, 49 (4): 37 – 44.

[10] 罗潇, 於锋, 彭勇. 基于深度学习的无人机电网巡检缺陷检测研究 [J]. 电力系统保护与控制, 2022, 50 (10): 132 – 139.

[11] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] //Proceedings of the 15th European Conference on Computer Vision, 2018: 3 – 19.

(下转第 117 页)