

架空输电线路外观缺陷检测方法的 研究与试验

赵翔飞 方 余 徐仲征 王丽嫻 房文龙
(江苏省送变电有限公司)

摘要：在输电线路中，螺栓松动和导线破损是常见的故障类型，及时检测这些故障对电力系统的安全运行至关重要。为了识别和定位输电线路上的破损导线，本文提出一种基于深度卷积神经网络的 YOLOv5 检测方法，YOLOv5 是一种高精度、实时性强的目标检测算法。通过对 YOLOv5 算法的参数和结构进行适应性的改进，使得输电线路上的检测任务更加快速和准确。实验结果显示，该方法具有高实时性和高准确率，能够有效满足自动检测输电线路螺栓和破损导线的需求，极大地提升了电力系统检修工作的“智能化”。

关键词：输电线路；缺陷检测；YOLOv5

2025.08.dqgy
63

0 引言


输电线路在电力系统中起着关键作用，确保电力从发电厂高效传输至用户。然而，输电线路设备的损坏和老化会对其性能和可靠性产生显著的负面影响。这不仅可能导致电力传输效率的降低，还可能引发电力供应的不稳定，甚至造成大规模停电等严重后果。因此，定期对输电线路及其设备进行检测和维护显得尤为重要。传统的输电线路设备检测多依赖于人工巡检，这种方式不仅效率低下，成本高昂，而且存在很大的安全隐患。

近年来，深度学习技术取得了显著进展，特别是在图像识别和目标检测领域的广泛应用，极大地推动了相关技术的发展。基于深度学习的输电设备自动检测技术因此受到了广泛关注。这种技术不仅提高了检测的准确性和效率，还为输电线路设备的检测提供

了全新的解决方案，显著提升了电力系统的可靠性和安全性。通过利用深度学习算法，自动检测系统能够快速识别和定位设备中的潜在问题，从而及时进行维护和修复，避免了传统检测方法中的诸多局限性。其中，YOLO（You Only Look Once）系列算法因其检测速度快、准确度高而成为该领域的研究热点。YOLO 算法将目标检测任务视为一个单一的回归问题，直接从图像像素到目标类别概率和边界框坐标的预测，极大地提高了检测的速度。随着 YOLOv5、YOLOv6、YOLOv7 到 YOLOv8 的不断迭代，算法的性能也在不断提升，对于复杂场景下的输电设备检测提供了更加强大的支持。

1 算法原理

YOLO（You Only Look Once）算法将图像划分



PRODUCT AND TECHNIC

|| 产品与技术 ||

为 $S \times S$ 网格，由对应的锚框负责检测目标。YOLO 系列已发展至 YOLOv7，其中 YOLOv5 因其稳定性和低训练成本，被广泛应用，并作为本文的基础算法。本文使用 YOLOv5 的 6.1 版本，其网络结构如图 1 所示。图中已标明： C 表示卷积， B 为批归一化， S 为 Silu 激活函数， 6×6 为卷积核大小， $C3$ 模块用于残差学习，避免梯度消失。Neck 部分的 $C3$ 没有分支，SPPF 模块由卷积和最大池化组成。网络整体由四部分组成：输入、Backbone、Neck 和 Head。输入部分采用 mosaic 增强技术，通过随机缩放和色彩调整，拼接四张图像以增加特征多样性。Backbone 负责特征提取，随着网络加深，特征逐渐抽象，并通过 SPPF 模块输出高维特征。Neck 部分通过 FPN 和 PAN 进行特征融合，提升模型学习能力。Head 部分包含三个检测头，分别负责检测不同尺度的目标，输出前景概率、类别和位置信息。




图 1 YOLOv5 6.1 版本网络结构图

本文使用 YOLOv5 算法检测输电线路上的螺栓和破损导线。在 416×416 分辨率下，YOLOv5 在 MSCOCO 数据集上达到了 55.3% 的 mAP，速度为 35 帧/秒，表现出良好的检测精度和速度。针对识别任务，对 YOLOv5 的网络参数和结构进行改进，提升

了对破损导线的识别准确率和实时性。

2 图像数据集

2.1 图像数据采集

在本研究中，为了提高模型的泛化能力和鲁棒性，考虑到输电线路破损导线可能会受到不同光照条件、背景变化、拍摄角度和拍摄距离等多种因素的影响，在数据采集过程中采取了多样化的方式。通过结合带电作业机器人和人工拍摄两种方式，共采集了 600 张涵盖不同场景的输电线路破损导线图片。这些图片包含不同的光照、背景、拍摄角度和距离，以模拟实际应用中可能遇到的各种环境条件，确保数据集具有较好的代表性和多样性。为了进一步增强数据集的多样性，并避免模型过拟合，对采集到的 600 张原始图片进行数据增强处理。首先，将所有图片裁剪为 416×416 像素的标准尺寸，以确保输入图像的一致性和适应性。然后，针对不同场景中的变化性，实施了两种数据扩展操作：一是对每张图片进行随机旋转，角度范围为 $\pm 45^\circ$ ，二是对图片进行随机的 $\pm 90^\circ$ 或 $\pm 180^\circ$ 的旋转操作。这些旋转变换能够有效地模拟图像在不同角度下的变化，增强模型对不同视角下物体特征的识别能力。通过这两种扩展操作，图片的数量从最初的 600 张扩展至 1200 张，从而显著增加了训练数据的多样性和复杂性。

2.2 图片标注与数据集制作

对 2400 张破损导线图片进行矩形框标注，标注信息包含左上角、右下角坐标及目标类别。随后，将图片及标注转为 PASCAL VOC 格式，按 7:3 比例分为训练集和测试集。

3 实验与分析

3.1 实验环境

本实验采用的配置如表 1 所示。




表 1 实验台平台参数

配置项	配置规格
操作系统	Windows11
处理器	英特尔 i5-13600kf
显卡	NVIDIA GeForce RTX 4070TI
显存	12G
深度学习框架	Pytorch11.0 CUDA12
编程语言	Python3.8
集成开发环境	Pycharm

3.2 评价指标

为了验证本文改进算法的有效性，使用精度（Precision），召回率（Recall）和均值平均精度（Mean Average precision, mAP）作为评价指标，即：

$$\text{precision} = \frac{TP}{TP+FP} \quad (1)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{MAP} = \frac{\sum_{i=1}^n \text{AP}(i)}{n} \quad (3)$$

式中，TP 为预测为正类正样本数量；FP 为预测为负样本正样本的数量；PN 为预测为正类负样本数量。

3.3 实验结果分析

实验中，网络深度设定 0.33，宽度 0.5，batch-size 16，输入图片大小 640×640，原模型训练轮数 100 轮。损失函数如图 2 所示，三类损失值（位置损失、目标损失和类别损失）均接近于零，表明模型已收敛。




图 2 YOLOv5 训练过程三类损失值变化曲线

在输电线路设备检测领域，对训练过程的损失函数进行分析是至关重要的。它不仅反映了模型学习的状况，还指示了模型的性能可能存在的问题。

从图 3 中可以看到，模型训练过程中表现出三种损失：定位损失（box-loss）、分类损失（cls-loss）和置信度损失（dfl-loss）。定位损失主要衡量预测的边界框与真实框之间的差异，关注于目标框的精准定位；分类损失反映模型区分不同类别的能力；置信度损失则与模型对预测结果的置信度相关，评估其对目标存在与否的判断。在整个训练过程中，随着迭代次数的增加，三类损失都显著下降，表明模型在边界框定位、分类和置信度评估等方面的性能得到了逐步优化。尤其是在训练的初始阶段，损失值下降最快，这是由于模型从随机初始化权重开始，迅速学习并适应数据集的特征，导致损失的快速减少。随着训练的深入，损失值的下降速度逐渐放缓，表明模型进入细化和微调阶段，继续提高其精度和表现。





图 3 YOLOv5 损失值变化曲线

通过对比训练损失和验证损失的变化趋势，可以观察到二者均呈现出逐渐下降的趋势，并且整体走势较为一致。这一现象表明，模型在训练过程中成功地学习到了数据的内在规律和特征，并且这些特征不仅



PRODUCT AND TECHNIC

|| 产品与技术 ||

能在训练集上有效地进行拟合，还能够成功地迁移至验证集。这种一致性说明模型具备较强的泛化能力，能够在未见过的数据上保持较好的预测性能，从而验证了模型的有效性。尤其是在面对新的、未见过的数据集时，模型依然表现出较高的准确性，这进一步表明其学习的特征并没有过于依赖训练集的噪声或特定模式，而是捕捉到一般化的规律，使得模型能够应对多样化的数据分布。换句话说，模型在训练过程中并未过度拟合训练集，而是通过合理的正则化和适当的参数调整，达到了较好的训练和验证损失平衡。

从另一个角度看，这种趋势还反映了模型在训练过程中有效避免了过拟合和欠拟合的风险，模型能够自如地调整复杂度，以适应不同的数据集特征。这一现象意味着模型不仅具备较好的预测能力，还具备强大的鲁棒性，能够在不同的实际应用场景中表现出较为稳定和可靠的性能。

在评估分类模型的性能时，精确度和召回率是关键指标。精确度用于衡量模型在识别正样本时的准确性，即模型在所有被预测为正样本的数据中，有多少是真正的正样本。召回率则反映了模型对正样本的覆盖情况，即在所有真实的正样本中，有多少被模型正确识别。随着模型的迭代训练，精确度和召回率的逐步提升表明，模型在不断优化，对目标的检测越来越精确，漏检情况也相应减少。

同时，目标检测领域常用 mAP 作为综合评价指标，它在不同阈值下结合精确度与召回率的表现来评估模型性能。通过观察 mAP@0.5 和 mAP@0.5-0.95 这两个指标的趋势，可以明显看出，模型整体性能随迭代逐渐提升，尤其是 mAP@0.5 的提升更为显著。这意味着在较低的 IoU 阈值（Intersection over Union）下，模型的检测性能得到了更大幅度的改善，反映出它在较宽松条件下的目标识别能力增强。

在评估深度学习模型性能时，精确度 - 召回率

（Precision-Recall, PR）曲线是常用的工具，尤其在目标检测任务中具有重要作用。PR 曲线能够直观地展现模型在不同类别目标上的检测效果，提供有关模型分类能力的详细信息。通过分析图4中的PR曲线，可以深入研究 YOLOv5 模型在输电线路设备检测任务中的表现。具体来说，精确度与召回率的变化能够反映模型在检测不同目标时的优劣势，为评估模型在实际应用中的可靠性和效果提供了重要依据。这种分析有助于更好地理解模型在面对复杂目标时的识别能力和适应性，从而优化后续的改进方向。




图4 YOLOv5 PR 曲线

从图中可以看出，模型在 break 类别上的精确度最高，这表明其对该类别的识别几乎没有误报，能够准确区分 break 类别与其他类别的差异。这种高精确度通常意味着模型在处理该类别时具有较高的可靠性和稳定性。相比之下，Thunderbolt 类别的精确度较低，可能原因是该类别样本数量不足，或样本间差异较大，导致模型难以在不同情况下保持良好的识别性能。

（下转第 70 页）