

[巡检图像]

一种改进的YOLOv8无人机输电线路巡检图像识别检测网络

文/曹成发 安东 马伟荣 王晓磊 李孝春
国网青海省电力公司西宁供电公司

在无人机输电线路巡检过程中，航拍图像质量不均匀，真实输电线路的背景复杂，待检测目标类型多样，目标尺度变化大且尺寸差异大，导致识别和检测难度较大。为解决这些问题，提出一种改进的YOLOv8无人机输电线路巡检图像识别与检测网络。首先，将多头自注意力机制引入到主干网络中，以有效提取检测目标的上下文信息，从而提高复杂背景下输电线路目标的检测能力。其次，在检测头中增加了小目标检测层，并优化边界框损失函数，丰富网络尺度信息，减少误检率和漏检率。实验结果表明，所提出的方法能够准确检测输电线路目标。输电线路六种类型目标的平均准确率、平均召回率和平均 F_1 分数分别为93.34%、93.86%和94.93%，显示出强大的准确性和鲁棒性。

随着智能电网建设的需求和科学技术的进步，无人机已成为输电线路安全检查的主要方法之一，它可以快速、准确地掌握输电线的基本信息，并为输电线路现场操作机器人提供视觉信息辅助。由于输电线部件的大部分图像都是通过航拍拍摄的，背景复杂且目标种类繁多，为提高检测准确性和增强鲁棒性，使用深度学习对象检测算法来检测在线部件已成为行业学者关注的焦点。本文提出一种基于改进YOLOv8的输电线路目标检测方法。通过在主干网络尾部引入多头自注意力（Multi-Head Self-Attention, MHSA）机制，可以有效提取检测目标的上下文信息，提高复杂背景下输电线路目标的检测能力。为丰富网络尺度信息并减少漏检率，在检测头中添加一个小目标检测层，并优化网络边界框损失函数为SIoU，从而提高了网络对复杂背景下输电线的检测效果。

引入多头注意力机制的YOLOv8算法

1. YOLOv8算法

YOLOv8网络结构由主干网络、颈部网络和头

部组成，分别负责特征提取、特征融合和目标检测处理。YOLOv8重构了整体结构，包括轻量级的C2f模块、快速空间金字塔池化层（SPPF）、路径聚合网络（PANet）、解耦头部结构和无锚框设计。在现有的目标检测方法中，YOLOv8网络具有更好的检测性能，但在输电线的典型组件检测任务直接应用时仍存在问题：航检图像的背景更复杂，检测目标尺度变化大，且大多数为小目标，因此模型可能会漏检和误检。为解决上述问题，本文提出了一种基于YOLOv8网络的多尺度输电线目标检测模型，引入多头自注意力机制。

2. 多头自注意力机制

在计算机视觉领域，注意力机制通常用于快速获取图像中的关键信息。受到BoT模型的启发，本文旨在更全面地获取不同尺度物体的图像特征信息，并实现上下文信息整合。在YOLOv8主干网络的最后一层的C2f模块瓶颈中引入多头自注意力机制，形成C2f_MHSA模块。

MHSA的结构如图1所示。MHSA的输入尺寸

为 $H \times W \times C$ ，其中 H 、 W 和 C 分别是输入特征的高度、宽度和维度； H 和 W 的相对位置编码分别由 R_h 和 R_w 表示；查询矩阵、键矩阵和位置矩阵分别由 q 、 k 和 r 表示； $\otimes$ 和 $\oplus$ 代表矩阵的乘法和加法操作。图中 1×1 卷积表示为 1×1 。将通过 qk^T 和 qr^T 计算的语义特征和位置特征相加后，使用Softmax函数进行归一化，然后将归一化结果与值矩阵相乘，最终输出自注意力。MHSA通过线性变换网络将输入图像投影到多个子空间，然后分别计算注意力参数，最后将多头自注意力的计算结果拼接起来，从全局角度关注像素间的重要连接，这可以有效地提高复杂背景下输电线小目标的检测效果。数据渗透主要表现为异常数据的注入、信号特征的伪造及网络延迟导致的错误信号传递等，这些问题严重威胁故障检测的准确性。




图1 MHSA机制的结构

3. 小目标检测层

输电线路场景中的航拍图像通常包含许多小目标，如阻尼器、间隔棒等。原始YOLOv8中的最大特征图仅为 80×80 ，经过YOLOv8的特征融合后，检测层输出不同尺寸的特征图以检测不同大小的目标。为提高小目标检测的准确性并避免因下采样导致细节特征过度丢失，本文改进原始YOLOv8的网络结构。如图2所示，从原始网络主干的P2层特征图中提取，添加一个特征图大小为 160×160 的小目标检测层，并进行更深层次的特征传递和特征融合。




图2 检测头的多尺度改进

边界框损失函数优化

边界框回归损失函数对于目标检测非常重要。通过学习预测边界框的位置，模型使其尽可能接近真实的边界框，并提供有关检测目标准确位置和区域的重要信息。YOLOv8使用CIoU作为边界框回归损失函数，计算公式为

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \left(\frac{v}{(1 - \text{IoU}) + v} \right) v \quad (1)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (2)$$

式中， b 和 b^{gt} 分别为预测框和真实框的中心点； ρ 为两个框中心点之间的欧氏距离； c 为包含两个框的最小框的对角线距离； w^{gt} 和 h^{gt} 为真实框的宽度和高度； w 和 h 为预测框的宽度和高度。

从式(1)和式(2)可以看出，CIoU是基于预测框和真实框之间宽高比的相对比例计算的，当两个框的宽高比一致时，惩罚项无效。为此，本文用SIoU替换了原始的CIoU，SIoU包含了参数，如图3所示。




图3 SIoU示意图

与其他损失函数相比，SIoU考虑了角度因素，使得预测框能更快地接近真实框，并加速损失函数的收敛速度。在计算真实框和预测框之间的宽高关系时，SIoU采用分别计算宽度和高度关系的方法，而不是计算相对比例，以避免当预测框和真实框的宽高比相同时惩罚项为0的情况。

SIoU损失函数包括三部分：角度代价、距离代价和形状代价。

(1) 角度代价

如果角度 $\alpha < 45^\circ$ ，直接代入以下公式计算；如果不是，使用互补角 β 代替。角度代价的计算公式为

$$A = 1 - 2\sin^2\left(\arcsin(x) - \frac{\pi}{4}\right) \quad (3)$$

$$x = \frac{C_h}{\sigma} = \sin(\alpha) \quad (4)$$

式中, x 为 α 的正弦值; σ 为两个框中心点之间的距离; C_h 为两个框的高度差。

(2) 距离代价

距离代价计算公式为

$$\Delta = \sum_{l=x,y} (1 - e^{-\gamma_l}) = 2 - e^{-\gamma_x} - e^{-\gamma_y} \quad (5)$$

式中, ρ_x 为 C_w 与 C_x 比值的二次方; ρ_y 为 C_h 与 C_y 的比值的二次方。

(3) 形状代价

形状代价计算公式为

$$\Omega = (1 - e^{-\omega_w})^\theta + (1 - e^{-\omega_h})^\theta \quad (6)$$

式中, θ 的值定义了形状代价的权重, 控制了应该对形状代价给予多少关注, 在本文中, θ 为 1; ω_w 为两个框宽度差的绝对值与最大值的比值; ω_h 为高度差的绝对值与最大值的比值。

SIoU 的计算公式为

$$L_{\text{SIoU}} = 1 - \text{IoU} + \frac{\Delta + \Omega}{2} \quad (7)$$

实验

1. 数据集介绍和实验环境配置

本文提出的输电线路目标检测算法, 算法编程语言为 Python, 实验平台是 Windows 10 64 位系统, 配备了两块 NVIDIA GeForce RTX 2080 Ti 图形卡。

训练数据集来自无人机收集的真实输电线路目标, 包括 6 种图像数据: 阻尼器、绝缘子、均压环、间隔棒、耐张线夹和悬垂线夹, 总共有 6 010 个。每个图中都包含了需要测试的组件目标, 输电线路目标检测数据集在经过 labelImg 工具标注后构建完成。

在模型训练参数方面, 训练代数设置为 300 轮, 单次训练的样本量设置为 8。优化器采用 Adam, 并采用了迁移学习策略。前 50 代冻结网络骨干进行训练, 学习率设置为 0.001; 50~300 代使用整个网络参与训练, 学习率设置为 0.0001, 并使用余弦退火动态调整学习率。模型训练的损失变化曲线如图 4 所示。




图4 模型训练损失变化曲线

2. 评估指标

为定量分析所提算法的目标检测结果, 并验证网络相关改进的有效性, 采用了精确度 (P)、召回率 (R) 和平均精确度 (AP), 以及平均平均精确度 (mAP) 和 F_1 分数这五个指标对目标检测结果进行客观评估, 各个指标的计算公式为

$$\begin{cases} P = \frac{T_p}{T_p + F_p} \\ R = \frac{T_p}{T_p + F_N} \\ F_1 = 2 \times \frac{P \times R}{P + R} \\ AP = \int_0^1 P(R) dR \\ mAP = \frac{1}{K} \sum_{i=1}^K AP \end{cases} \quad (8)$$

式中, T_p 为检测为正类的正类数量; F_p 为检测为正类的负类数量; F_N 为检测为负类的正类数量; K 为待检测目标的类别数; F_1 为精确度和召回率的调和平均值, 值越高, 模型质量越好; AP 为某类目标的平均检测准确度, 用于衡量检测的质量; mAP 为所有目标 AP 值的平均和。

本文使用置信度阈值为 0.5 的 mAP 来评估算法性能。

3. 实验结果分析

本文中的算法用于检测收集到的输电线路目标图像, 检测结果如图 5 所示。

输电线路上的被检测组件用不同颜色的矩形框标记, 不同矩形框对应的标签名称是被检测目标的类别。几乎可以检测到输电线路上的所有组件, 改善了尺度变化大的小目标检测和识别不佳的问题。




图5 检测结果

为了定量评估改进后的YOLOv8网络的性能，使用了三个客观指标：精确率、召回率和 F_1 分数来分析检测结果，并与原始YOLOv8网络进行了对比实验。评估结果见表1。

表1 六种不同目标检测的评估结果

网络	目标	精确率 (%)	召回率 (%)	F_1 分数 (%)
YOLOv8	均压环	92.47	90.80	93.52
	绝缘子	90.28	92.46	92.79
	悬垂线夹	91.51	93.04	91.22
	耐张线夹	92.83	91.18	92.91
	阻尼器	89.74	92.32	93.73
	间隔棒	90.16	92.94	94.50
	平均	91.16	92.12	93.11
improved YOLOv8	均压环	93.45	91.35	95.06
	绝缘子	95.40	93.91	93.37
	悬垂线夹	92.24	95.13	92.80
	耐张线夹	94.58	92.72	94.46
	阻尼器	92.63	94.20	96.50
	间隔棒	91.78	95.86	97.42
	平均	93.34	93.86	94.93

由表1可知，本文提出的算法针对6种输电线路目标的平均精确率、召回率和 F_1 分数分别为93.34%、93.86%和94.93%。与原始YOLOv8网络的评估结果相比，所提算法的平均精确率和召回率分别提高了2.18%和1.74%，平均 F_1 分数提高了1.82%。总的来说，对比实验结果证明，本文对

YOLOv8网络的相关改进可以提高原始网络在输电线路目标检测中的性能，这是合理且有效的。

为了证明改进后的YOLOv8网络中每个模块对输电线路目标检测效果的影响，在确保数据集和训练方法一致性的基础上，对每个模块进行了消融实验，并使用mAP作为客观评估指标来反映每个改进阶段对应算法的检测性能。实验结果见表2。

表2 消融研究结果

YOLOv8	MHSA	小目标检测层	SIoU	平均准确度 (%)
✓				87.34
✓	✓			90.46
✓	✓	✓		91.08
✓	✓	✓	✓	91.73

表2的结果显示，在复杂的输电线路环境中，以原始YOLOv8网络模型为基线，将多头自注意力机制（MHSA）引入骨干网络后，mAP值增加了3.12%，表明网络获取图像特征信息的能力得到了增强。在此基础上，向网络结构的颈部添加了一个尺度为 160×160 的小目标检测层，并将原始边界框损失函数优化为SIoU，以丰富网络的多尺度信息层次，并提高其在大尺度差异下的目标检测能力。最终形成本文提出的改进模型，其mAP值比原始基线模型高出4.39%，达到91.73%。从上述实验结果可以看出，本文对YOLOv8网络在每个阶段的改进都提高了其对输电线路目标组件的检测能力，增强了网络的鲁棒性，并提高了模型的检测准确度。

结束语

针对无人机输电线路巡检过程中，由于航拍获取的部分图像质量较差、图像背景复杂、待检测目标尺度变化大以及目标尺寸差异大所导致的检测难题，本文提出一种基于改进的YOLOv8的无人机巡检输电线路目标识别检测方法。通过引入多头自注意力机制、增加小目标检测层以及优化边界框损失函数，提高了网络的检测性能和鲁棒性。使用改进后的YOLOv8网络对六种输电线路目标进行检测，平均精确率、召回率和 F_1 分数分别为93.34%、93.86%和94.93%。总的来说，所提出的方法能够改善无人机输电线路巡检过程中目标检测的难题，具有高精度和良好的鲁棒性，在输电线路无人机巡检和输电线路目标检测研究中具有一定的参考价值。EA

(收稿日期：2024-12-27)