

算主要由人工完成。工人完成清障工作后,一般使用钢尺或皮尺等测量工具逐个测量树桩横截面的直径,根据直径的大小对所砍伐树木进行统计并拍照存档;营销管理人员取得存档的作业记录后,还需要对实际砍伐量进行核算,然后支付相应的费用。这种基于人工的核算方法周期长、体力劳动繁重,并且无法保证测量的客观性和准确性。因此,采用自动核算的方法代替人工测量的方法成了电力系统目前迫切需要解决的问题。

通过分析人工核算的步骤,可以将核算任务抽象为以下两步:1)树桩截面的辨别;2)树桩截面直径的测量与树桩计数。因此,要实现自动化的清障工程核算,正确识别树桩截面是获得准确核算结果的前提,本文主要着重第一步进行展开。在截面识别的方面,目前已经存在较多的研究,在基于传统数字图像处理的方式中,官俊等^[8]提出基于圆形约束的 CV-LIF 模型来分割复杂背景下的原木端面,梅振荣等^[4]提出了一种基于非线性最小二乘原理的椭圆拟合方法来分割原木端面,以上两者都简单地将截面检测归类于类圆物体的检测,没有关注形状不规则的截面类型。唐浩等^[5]首先对原木图像使用 K-means 方法进行色差值聚类,对于原木截面、孔隙及背景进行分割,采用逐级开运算与改进分水岭算法,对端面进行分割计数,但在背景干扰较强时效果较差。Kruglov 等^[6]提出了一种快速径向对称算法进行原木检测的改进方法,结合分水岭算法与 Stoer-Wagner 算法,分离错误的目标,达到木材计数与轮廓分割的目的。胡笑天等^[7]利用改进的 K-Means 方法分离端面与背景,并设计了一种自适应逐级开运算的方法,以此来识别并计算原木截面数,平均正检率为 97.26%。

随着人工智能的发展,基于深度学习的截面检测方法也有了一定的进展,余平等^[8]提出了融合 BiFPN^[9]和 YOLOv5s 的方法,用于检测密集型的原木端面^[10],添加了 P2 检测层以应对密集图像中的较小原木端面,并融合了 BiFPN 以保留更多的浅层语义信息,其平均精度分别达到了 97.85%,胡笑天等^[11]提出了基于改进 SSD^[12]的原木端面识别方法,以 SSD 为基础网络,对 conv_fc7 使用上采样后与 conv4_3 融合替换原 conv4_3,将 conv4_3 和 conv_fc7 两个有效特征层进行结合,同时融合多尺度卷积核与空洞卷积,引入卷积块注意力机制,检测精确率为 97.00%,召回率为 92.90%,平均精度达到 95.33%。总的来说,现有的传统图像处理方法只针对了特定场景中的问题,在出现复杂背景和环境干扰时表现较差,缺乏鲁棒性。而基于深度学习的方法虽然可以达到较高的精确度,但上述的方法主要针对于原木堆中的截面检测,任务较为简单。不同的是,树障清理工程仅针对输电线路产生隐患的树木,余留的树桩散落分布,检测背景较为复杂。现存的方法只关注了截面的特征信息,对树干与树桩的区分能力有限,从而造成错检漏检,也无法应对环境干扰多,造成遮挡的问题。

为了应对上述出现的问题,本文提出用于输电走廊树

障砍伐量核算的树桩检测算法。在特征提取阶段,引入上下文引导模块(context guide block, CG Block)来改进骨干网络,使得网络能够通过学习树桩周围的上下文信息,提升模型对树桩和树干的区分能力。在特征聚合阶段,将高效重参数化广义特征金字塔网络(efficient reparameterized generalized feature pyramid networks, RepGFPN)融合 Dysample 作为新的颈部网络,以更多地保留树桩特征的细节,最后,针对被遮挡树桩难以检测的问题,在检测头加入并改进分离和增强注意力模块(multi separated and enhancement attention module, Multi-SEAM)来提高模型的表现。

1 YOLOv8 模型介绍

YOLOv8 是一种速度与精度兼备的实时物体检测器。在特征提取阶段,对输入图像尺寸缩放并归一化后,由骨干网络提取特征,骨干网络由多个卷积层、批归一化层和激活函数组成的 CBS 模块和 C2f(CSPDarknet53 to 2-Stage FPN)模块,以及一个 SPPF(spatial pyramid pooling-fast)构成。C2f 模块强调了低级特征与高级特征的融合,而 SPPF 主要用来控制输出尺寸与通道数。在特征聚合阶段,提取的特征经过上采样、拼接融合等操作,最终送到 3 个检测头进行检测,其中,检测头为 Decoupled 解耦头,将分类与定位任务分离,并采用 Anchor-free 的方式来预测目标。

2 模型改进方法

考虑到实际工程应用,本研究将 YOLOv8n 作为原始模型。针对树桩检测中出现的问题,分别对主干网络的 C2f 模块、颈部网络、检测头进行了改进,实现了对模型精度的提升。本文方法的整体结构如图 1 所示。

2.1 ContextGuide-C2f 模块

在进行树障砍伐作业时,树干常常遗留在作业现场,树干与树桩纵横交错,呈散落分布,由于树干截面、主体与树桩的相似性,不加以区分地检测会导致重复计数、核算结果不准确等问题。CG Block 是 Wu 等^[13]从人类视觉系统得到灵感,从上下文语义信息的角度提出的模块,如图 2 所示,在识别红色区域的树桩截面时,人眼不只关注截面本身(红色框),而是结合树桩周围的信息(黄色框)来辨别树桩和树干。

结合 CG Block 能够学习周围上下文语义信息的特点,引入了 CG Block 来改进骨干网络,提高网络对树干树桩的辨别能力,具体来说,对于骨干网络中的第 2、4、6、8 层中的 C2f 模块,使用 CG block 替换 bottleneck,并保留其残差连接结构,以适应深层网络的学习,ContextGuide-C2f 的结构如图 3(a)所示。

CG Block 的具体结构如图 3(b)所示,在特征传入后,会分别馈送至局部特征提取器 f_{loc} 和周围特征提取器




图 1 算法整体结构图

Fig. 1 The overall architecture of algorithm



图 2 人眼识别树桩的过程

Fig. 2 The process of recognizing stumps by the human eye

f_{sur} , 并通过联合特征提取器 f_{joi} 融合上下文语义信息与局部特征,最后由 f_{glo} 进行残差连接逐元素相乘。其中, f_{loc} 为 3×3 的可分离卷积, f_{sur} 为 3×3 的可分离的膨胀卷积,相比传统卷积,膨胀卷积可以在不降低特征分辨率的情况下扩大感受野。通过 CG Block 增加模型对树桩周围上下文语义信息的学习,从而提高模型对树桩和树干的区分能力。虽然 f_{loc} 和 f_{sur} 使用了可分离卷积,但二者本就需要保持通道独立性,这避免了后续进行 1×1 卷积的通道交互融合,从而节省了额外计算开销,降




图 3 ContextGuide-C2f 与 Context Guide Block 的结构

Fig. 3 The structure of ContextGuide-C2f and Context Guide Block

低了模型的参数量,提高了检测速度。

2.2 RepGFPN-dynamic 模块

1) RepGFPN

颈部网络旨在聚合从主干提取的不同分辨率特征,如图 4(a)所示,YOLOv8 的颈部网络借鉴了路径聚合网络(path aggregation network, PANet)^[14]中主干网络的组织结构,即在相邻层级的同一尺度与相邻尺度的同一层级进行特征融合,考虑到缺少跨层连接,Jiang 等^[15]提出了广义的特征金字塔网络(generalized feature pyramid networks, GFPN),如图 4(b)所示。GFPN 将非相邻层的特征增加了 1b 连接,因此使得高层的特征信息能与底层信息得到充分的交换,并共享高层与底层特征的通道,虽然模型的表现有所提升,但复杂的组织结构带来了额外的上采样与下采样运算,同时也导致了更大的计算量和参数量。2023 年 Xu 等^[16]提出了 RepGFPN,如图 5 所示,相比 GFPN,RepGFPN 舍弃了繁复的跨层连接,删除了额外的上采样操作,在不同尺度的特征层使用不同的通道数,将融合的特征输入到检测头。




图 4 不同颈部网络对比

Fig. 4 The comparison of different neck networks




图 5 RepGFPN 结构

Fig. 5 The structure of RepGFPN

2) Dysample

特征上采样是深度神经网络中最基本的操作之一。其中,最常使用的上采样算子是双线性插值和最邻近插值法,但由于只利用了像素的空间距离来指导上采样过程,二者对密集目标的效果较差,随着深度学习的发展,Noh 等^[17]提出了反卷积(deconvolution),通过构建可学习的上采样算子,以逆运算的方式实现特征的上采样,但这样的方式会造成棋盘伪影,严重影响输出图像的清晰度和质量。Wang 等^[18]提出了内容感知特征重组上采样算子

(content-aware reassembly of features, CARAFE),采用动态生成针对内容的自适应卷积核,使用更大范围的上下文信息进行特征重组,从而更好地恢复细节与语义信息。

Liu 等^[19]从采样的角度重新定义了上采样的过程,摒弃了之前基于动态卷积核的复杂设计,并提出了 Dysample,其结构如图 6 所示,其中 σ 为 Sigmoid 函数。定义 $\mathcal{X}$ 为输入特征, θ 为学习的偏置, $\mathcal{G}$ 为网格采样(grid sample)操作, $\mathcal{S}$ 为采样点生成器, $\mathcal{Y}$ 为输出特征,整个过程可以公式化为:

$$\theta = \text{linear}(\mathcal{X}) \quad (1)$$

$$\mathcal{S} = \mathcal{G} + \theta \quad (2)$$

$$\mathcal{Y} = \text{grid_sample}(\mathcal{X}, \mathcal{S}) \quad (3)$$




图 6 Dysample 结构

Fig. 6 The structure of Dysample

不同于传统上采样的方式,Dysample 通过两个线性层对于原来平均的上采样的线性插值进行偏置学习,并将 grid_sample 与偏置后的像素重组(pixel shuffle)结果逐元素相加,作为上采样集(sampling set),与输入进行 grid_sample 运算得到上采样的结果。

3) RepGFPN-dynamic

具有出色结构的颈部网络可以实现最佳的特征融合和调整,从而在目标检测中提供卓越的性能,有效地整合和优化特征表示。本研究将 RepGFPN 融合上采样算子 Dysample,替换 YOLOv8n 的整个颈部网络。利用 RepGFPN 灵活控制高层和底层特征的表达能力,有效应对不同大小的树桩目标,而 Dysample 能够有效保留树桩的边缘信息,在实时性方面,相比于其他上采样算子如 CARAFE、FADE^[20]和 SAPA^[21],Dysample 无需自定义 CUDA 算子,也避免了动态卷积等耗时的操作,使得模型更加轻量,由表 1 可知,RepGFPN-dynamic 的模型大小相比传统上采样方式只增大了 0.1 MB,且在 GFLOPs 与 mAP_{50} 上实现了更佳的性能。

2.3 LW-SEAM 模块

在输电通道下的树桩检测中,如何解决遮挡导致地漏检、错检问题是本文的难点之一。由于输电通道常常跨越森林,而森林地貌复杂,植被丰富,树桩被树枝落叶或其他

表 1 RepGFPN 与不同上采样算子融合的横向对比
Table 1 The comparison of RepGFPN with different up-sampling operator fusion

颈部网络	模型 大小/MB	GFLOPs	mAP_{50}
RepGFPN	6.8	8.3	73.1
RepGFPN-CARAFE	7.1	8.7	73.2
RepGFPN-dynamic	6.9	8.3	74.1

杂物遮挡的情况十分常见,这可能导致漏检。Yu 等^[22]设计 Multi-SEAM 的初衷是为了解决人脸互相遮挡导致检测精度低的问题,因此,本文将 Multi-SEAM 用于改进检测头,以降低树桩被遮挡导致漏检的影响。具体来讲,将 YOLOv8n 三个检测头中的第 2 个卷积块使用 Multi-SEAM 注意力机制,并适当调整 Multi-SEAM 中通道和空间混合模块(channel and spatial mixing module, CSMM)中 patch 的大小,以降低模型复杂度,构成 LW-SEAM (Light-weight SEAM)。

Multi-SEAM 的结构如图 7 所示,由 3 个不同 patch 的 CSMM 组成,CSMM 的第一部分是带有残差连接的深度可分离卷积。深度可分离卷积虽然可以学习不同通道的重要性,减少参数的数量,但它忽略了通道之间的信息关系。为了弥补这种损失,LW-SEAM 通过两层全连接网络学习特征之间的关联性,并在转化为通道注意力权重时通过指数归一化处理,将值域拓展到 $[1, e]$ 区间。这种单调增加的映射关系,可以使模型对位置误差宽容度更高,从而提高对遮挡树桩的定位精度。




图 7 Multi-SEAM 结构

Fig. 7 The structure of Multi-SEAM

原文中 CSMM 分别设置 patch 为 6、7、8 的形式,其中 patch=6 的意义为在 CSMM 模块中的第一个卷积层使用卷积核大小为 6×6 ,步长为 6 的卷积,虽然大核的卷积能提升感受野,但也带来了更大的计算量和参数量,所以本文设置 patch 为 3、5、7 来降低 Multi-SEAM 的计算开销,

提高模型的检测速度,本文将不同的 SEAM 注意力机制分别改进 YOLOv8n 模型,横向对比结果如表 2 所示,虽然 LW-SEAM 的 mAP_{50} 和 mAP_{50-95} 略低于 Multi-SEAM,且模型大小比添加了 SEAM 的模型更大,每秒传输帧数(frames per second, FPS)更低,但综合检测精度与效率来看,算法在检测头中添加 LW-SEAM 注意力的方式性能更好。

表 2 多种 SEAM 注意力机制对比
Table 2 The comparison of multiple SEAM attention mechanisms

注意力机制	模型 大小/MB	FPS	mAP_{50}	mAP_{50-95}
SEAM	5.9	104	69.4	38.2
Multi-SEAM	13.5	76	75.5	42.3
LW-SEAM	10.2	95	75.2	42.1

3 实验结果及分析

3.1 数据集建立

现有的截面检测工作聚焦伐木场的原木堆检测或整车原木检测,在输电通道树障清理工程下的截面检测表现不佳,如图 8(a)所示,而现有的研究又多采用自建数据集训练与测试,如图为提高模型的鲁棒性和泛化能力,故而收集了清障工程现场的图片数据,数据均来源于武汉大学南方电网智能核算技术项目(广东),其中,一部分来自于工程人员手机拍摄的现场图像,另一部分截取于相机拍摄的图像,得到 1 851 张图像,使用 LabelImg 进行标注(由于实际核算工程仅考虑树桩个数及大小,本数据集仅有一类),使用旋转、雾化的数据增强手段得到 2 521 张图片并随机打乱,并按照 6:2:2 的比例划分为训练集、验证集与测试集,部分数据如图 8(b)所示,构建模型训练与测试使用的数据集。



(a) 原木堆端面与整车原木检测场景
(a) Logs end detection and logs end on vehicle detection



(b) 配电网树障清理工程场景
(b) Detection scene of tree barrier clearance workload

图 8 场景对比

Fig. 8 The comparison with different work scenes

3.2 实验设置

实验基于 Pytorch 实现,实验平台为 2 Nvidia 2080Ti GPUs, Intel i9-9900k CPU。在进行模型训练时,设置 batch size 为 64,训练轮数设置为 300,早停轮次设置为 50 轮,使用 SGD 作为优化器,学习率设置为 1×10^{-4} ,训练与测试输入的尺寸均为 640×640 。

3.3 模型评价标准

为了评估模型的性能,本文将以下指标作为消融研究的度量指标,精确率(precision, P)用于衡量算法准确性,召回率(recall, R)测量所有数据集中正样本的检测,由于本文为单一类别的树桩检测,平均精度(mean average precision, mAP)即为:

$$P = \frac{TP}{TP + FP} \times 100\% \tag{4}$$

$$R = \frac{TP}{TP + FN} \times 100\% \tag{5}$$

$$mAP = \frac{\sum_{i=1}^k AP}{k} \tag{6}$$

其中, TP 是预测的正样本的数量, TN 是预测的负样本的数量, FP 是被划分为正样本的负样本的数量, FN 是被划分为负样本的正样本的数量, k 为类别的数量, 本研究中检测目标只有树桩, 故 $k=1$, AP 的计算方式如下:

$$AP = \int_0^1 P(R) dR \times 100\% \tag{7}$$

mAP 指标有 mAP_{50} 和 mAP_{50-95} 两类。 mAP_{50} 表示检测到的边界框与真实框之间的交集(IoU) ≥ 0.5 时的 mAP 值, 而 mAP_{50-95} 表示在不同 IoU 阈值(从 0.5~0.95, 步长为 0.05)上的平均 mAP 值。

3.4 消融实验

为了验证改进模块对用于树障清理工程核算的树桩检测是否有效,对各个模块进行了实验分析和交叉消融实验,其中,“ $\times$ ”表示在模型中未使用该改进策略,“ $\checkmark$ ”表示在模型中使用了该改进策略。如表 3 所示,在引入了 CG Block 后,模型 A 的 P 值提高了 3.9%, mAP_{50} 提高了 2.6%,这是因为 CG Block 不仅关注检测目标本身,其中的周围特征提取器更能将物体与周围环境联系起来,并融合局部特征信息,加强了对模型对树桩截面以及周围上下文环境特征的理解,以获取更多的信息,从而更好地区分树桩与树干截面。对于模型 B,在引入了新的颈部结构 RepGFPN-dynamic 后 P 提高了 2.7%, mAP_{50} 提高了 2.5%,这得益于 RepGFPN-dynamic 中增加了不同特征层间的连接,而通道不共享的方式能够灵活控制低级特征与高级特征的表达能力。Dysample 通过其可学习的偏置,细化了上采样过程中的边缘特征,加强了模型对树桩边缘信息的捕捉。在添加了多头注意力 LW-SEAM 到检测层后,模型 C 能够学习遮挡与未遮挡树桩特征之间的联系,使得最终结果中 P 提高了 3.3%, mAP_{50} 提高了 3.6%。本文还对以上 3 个模块进行交叉消融实验,分别为模型 D、E、F,结果如表 3 所示。

表 3 消融实验
Table 3 Ablation studies

模型	ContextGuide-C2f	RepGFPN-dynamic	LW-SEAM	模型大小/MB	GFLOPs	P	R	mAP_{50}	mAP_{50-95}
YOLOv8n	$\times$	$\times$	$\times$	6.3	8.1	77.2	73.5	71.6	40.9
A	$\checkmark$	$\times$	$\times$	5.3	6.8	81.1	73.9	74.2	41.6
B	$\times$	$\checkmark$	$\times$	6.9	8.3	79.9	74.2	74.1	40.8
C	$\times$	$\times$	$\checkmark$	10.2	7.4	80.5	74.3	75.2	42.1
D	$\checkmark$	$\checkmark$	$\times$	5.9	7.1	82.4	75.4	77.3	43.1
E	$\checkmark$	$\times$	$\checkmark$	9.3	6.0	81.9	74.4	78.7	43.3
F	$\times$	$\checkmark$	$\checkmark$	10.8	7.6	81.4	74.1	78.1	43.2
本文方法	$\checkmark$	$\checkmark$	$\checkmark$	9.9	6.3	85.5	76.4	80.4	45.1

从消融实验结果来看,3 个改进模块对原始方法 YOLOv8n 的性能均有提升, P 、 R 、 mAP_{50} 和 mAP_{50-95} 分别提升了 8.3%、2.9%、8.8%、4.2%,所提方法在遮挡物多、环境复杂情况下表现更佳。

3.5 模型热力图分析

为了评估改进算法的实际效果,将原始算法 YOLOv8n 和本文方法的热力图进行对比,结果如图 9 所示,有 3 个树桩(上,中,下),对于树桩(上),YOLOv8n 对截面的关注较小,且由于受到杂草遮挡影响,对裸露部分

的树干注意力更强,这也造成了实际结果未能检测到该树桩,而本文方法能够注意到被遮挡的部分。对于树桩(中),YOLOv8n 虽然能够将其检测出,但可以明显观察到,YOLOv8n 的注意延伸到了杂草、倒地的树干等无关区域,而本文方法不仅能正确检测出目标,且精度更高,这是由于 LW-SEAM 注意力机制的改进,使得模型能够学习到遮挡树桩与正常树桩的联系,而改进的 ContextGuide-C2f 结构能够使模型学习到树桩周围上下文的信息,因此,对于树桩(下),这也使得在热力图结果的展现上,本文方法

能够做到注意力不偏离树桩截面及其主体,从而提高了模型应对遮挡以及树干与树桩交错情况的能力。




图 9 热力图可视化对比结果

Fig. 9 Comparison results of heat map visualization

3.6 对比实验

为了验证 CG Block 对模型性能的影响,分别在主干网络 C2f 中的 CBS、颈部网络中的 CBS、以及主干网络中 C2f 和颈部网络的 CBS 模块替换为 CG Block,分别进行了 3 组实验,(简称主干、颈部、主干+颈部)结果如表 4 所示。当 CG Block 的优化位置处在颈部网络时,虽然 GFLOPs 也有所降低,但 mAP_{50} 也有降低;而在对骨干网络与颈部网络处的模块全部进行替换时,模型的 GFLOPs 下降了 18.5%, mAP_{50} 有所上升;在对处在骨干网络的 C2f 进行 CG Block 替换改进后,模型的 GFLOPs 与精度均有不同程度的优化,实验结果表明,CG Block 仅在颈部网络处的 C2f 模块进行改进能取得最优性能。

表 4 CG Block 模块优化位置对算法性能影响
Table 4 The impact of CG Block module optimization location on algorithm performance

优化位置	GFLOPs	P	R	mAP_{50}	mAP_{50-95}
无优化	8.1	77.2	73.5	71.6	40.9
颈部	7.3	77.1	73.2	71.9	40.8
主干	6.8	81.1	73.9	74.2	41.6
主干+颈部	6.6	78.3	73.5	72.4	40.9

为了验证 LW-SEAM 注意力机制对遮挡树桩检测的有效性,本文将多种注意力机制分别添加到检测头,其中卷积注意力模块(convolutional block attention module, CBAM)在文献^[23]中用骨干网络优化,压缩与激励模块(squeeze and excitation, SE Attention)用于文献^[24]中加强主干网络输出特征的表达,可变形注意力(deformable attention, DAttention)与卷积与注意力融合模块(convolution and attention fusion module, CAFM)为近两年较为先进的注意力机制,分别加入到 YOLOv8n 模型中进行测试,对比结果如表 5 所示,从结果来看,添加 SEAttention、DAttention、CAFM 对模型性能的提升有限,而添加 CBAM 的模型,其 mAP_{50} 有所下降,这是因为利用

CBAM 虽然得到浅层特征层更多的信息,提高了对密集树桩与小目标的检测效果,但难以应对本文场景中的异物遮挡问题,加入了 LW-SEAM 的模型较其他改进模型的 P 、 R 、 mAP_{50} 和 mAP_{50-95} 均为最高,这得益于 LW-SEAM 本身适用于遮挡环境的检测,模块中 CSMM 的可分离卷积设计,优化了不同通道特征间的学习,而在注意力权重转化时,将值域拓宽到 $[1, e]$ 区间,这使得模型对位置误差宽容度更高,增强了遮挡树桩的识别能力,从而提高了检测精度。

表 5 多种注意力机制性能横向对比
Table 5 The comparison of the performance of multiple attention mechanisms

注意力机制	P	R	mAP_{50}	mAP_{50-95}
CBAM	77.5	73.6	70.7	41.1
SEAttention	77.9	73.6	71.7	41.2
DAttention	78.1	73.5	72.1	39.7
CAFM	77.9	73.7	72.5	40.8
LW-SEAM	80.5	74.3	75.2	42.1

为了检验本文算法的性能,在相同的实验设置下将所提方法与现今较为先进的目标检测算法进行了对比,与 YOLOv5n^[25]、YOLOv7^[26]、YOLOv8s、YOLOv9^[27]、YOLOv10n^[28]、YOLOv10s、RT-DETR^[29]方法对比的结果如表 6 所示,YOLOv5n 虽然具有最低的模型大小,但在精度表现上逊色于其他模型,YOLOv7 模型大小与且 GFLOPs 最大,且模型精度并不高。尽管 YOLOv10n 的模型大小最小,但在模型精度上表现不佳,而 RT-DETR-r18 虽然未经过任何改进已经具有较高的精度表现,但由于其采用 Transformer 架构,模型的参数量巨大,需要更多计算资源,这使得方法会在后续边缘设备上部署时存在困难。而所提方法不仅在 GFLOPs 中最低,且 P 、 R 、 mAP_{50} 和 mAP_{50-95} 精度最高。相比上述 7 个目标检测模型,本文方法的 mAP_{50} 和 mAP_{50-95} 分别高出 10%、7.4%;5.5%、2.4%;5.9%、3.1%;5.5%、3.5%;9.2%、5.3%;9.5%、7.2%;1.5%、1.7%,综合来看,本文方法拥有更好的性能。

3.7 算法鲁棒性检验

为了验证算法的鲁棒性,本文应用所提出的算法进行了实际测试,并选取了部分具有挑战性的场景进行展示,图 10 第 1 列实验组中树桩受到阴影影响,光线条件较差,图 10 第 2 列实验组为强曝光下的小目标检测,在图 10 第 1 列实验组中,原始算法 YOLOv8n 无法检测出树桩的同时,未能排除复杂背景中的干扰。在图 10 第 2 列实验组中,由于原始算法 YOLOv8n 将光照与树干识别为树桩,这是由于在过曝的环境中,新鲜的树桩锯面亮度较高,与森林中由光照形成的区域相似度很高,从而出现了错检现象,而本文方法的检测结果置信度虽然较低,在这两种场

表 6 对比试验
Table 6 Comparison studies

模型	模型大小/MB	GFLOPs	<i>P</i>	<i>R</i>	<i>mAP</i> ₅₀	<i>mAP</i> ₅₀₋₉₅
YOLOv5n	5.3	7.1	74.7	69.9	70.4	37.7
YOLOv7	74.8	103.5	81.4	73.5	74.9	42.7
YOLOv8s	22.5	28.6	81.2	72.9	74.5	42.0
YOLOv9	24.6	12.1	74.3	73.2	74.9	41.6
YOLOv10n	5.8	8.2	75.3	70.5	71.2	39.8
YOLOv10s	16.5	24.4	74.2	71.5	70.9	37.9
RT-DETR-r18	40.5	56.9	84.4	74.3	78.9	43.4
本文方法	9.9	6.5	85.5	76.4	80.4	45.1




图 10 YOLOv8n 与本文方法鲁棒性检验结果对比
Fig. 10 Comparison of robustness test results between YOLOv8 and the method of this paper

景中都能够识别出树桩目标,因此,改进方法在对抗复杂条件下的树桩检测表现更佳。

3.8 实验效果及分析

为了直观地展示所提方法的有效性,将原始方法 YOLOv8n 与本文方法的实验结果进行了对比。在倒塌的树干与树桩类间遮挡的场景中,如图 11 首列实验组所示的结果,YOLOv8n 仅检测出其中未受到遮挡影响的树桩 2 个,而本文方法在能够检测出所有树桩的同时,拥有比 YOLOv8n 更高的置信度。

在图 11 第 2 列、第 3 列中的两组结果中,由于树干的位置以及特征与树桩具有相似性,YOLOv8n 出现了错检情况,而本文方法检测结果较为准确。由此可以证明,在遮挡物多,检测环境复杂的场景下,相比与 YOLOv8n,本文方法能够减少错检漏检问题的发生,拥有更强的鲁棒性。



图 11 YOLOv8n 与本文方法的对比实验结果
Fig. 11 Comparison experimental results of YOLOv8n and the method of this paper

4 结 论

正确的检测树桩截面是核算结果准确的前提,针对输电通道树障砍伐量核算中出现的环境复杂、遮挡物多的情况,且树桩与树干纵横交错,容易错检造成核算结果不准确的问题,本文提出了用于输电走廊树障清理工程量核算的树桩检测算法,首先,使用 CG Block 改进 C2f 中的 Bottleneck,提高模型对树桩特征的敏感度,然后,基于 RepGFPN 与 Dysample 设计新的颈部网络,最后,利用

LW-SEAM 改进检测头,增强对遮挡树桩的识别效果。

经实验验证,和原始方法 YOLOv8n 相比,本文方法中 P 提升了 8.3%, R 提升了 2.9%, mAP_{50} 提升了 8.8%, mAP_{50-95} 提升了 4.2%,能够更好应对场景中出现的环境干扰、类间或其他因素遮挡问题,所提方法具有较好的可行性和工程使用价值。

参考文献

- [1] 黄维,黄志都,王乐,等. 架空输电线路走廊树障隐患动态管理及预警分析[J]. 广西电力, 2017, 40(3): 39-42.
HUANG W, HUANG ZH D, WANG L, et al. Dynamic management and early-warning analysis of tree barrier hidden danger in overhead transmission line corridor [J]. Guangxi Electric Power, 2017, 40(3): 39-42.
- [2] 黄郑,卞尹蕾,王红星,等. 无先验地图条件下电力管廊无人机自主巡检方法研究[J]. 电子测量技术, 2022, 45(19): 30-35.
HUANG ZH, BIAN Y L, WANG H X, et al. Inspection method employing UAV of electricity pipe gallery based on LiDAR without prior map [J]. Electronic Measurement Technology, 2022, 45(19): 30-35.
- [3] 官俊,任洪娥,宋爽. 基于圆形约束 CV-LIF 模型的原木端面图像分割[J]. 计算机工程与应用, 2014, 50(18): 147-151.
GUAN J, REN H E, SONG SH. Log end image segmentation based on circle dependent CV-LIF model[J]. Computer Engineering and Applications, 2014, 50(18): 147-151.
- [4] 梅振荣,任洪娥,朱朦. 基于非线性最小二乘原理的原木端面识别算法[J]. 计算机工程与应用, 2012, 48(2): 177-178.
MEI ZH R, REN H E, ZHU M. Algorithm of log end recognition based on non-linear least squares principle[J]. Computer Engineering and Applications, 2012, 48(2): 177-178.
- [5] 唐浩,王克俭,李晓烨,等. 基于色差聚类的原木图像端面检测与统计[J]. 计量学报, 2020, 41(6): 682-688.
TANG H, WANG K J, LI X Y, et al. Logs end detection and statistics by color difference clustering [J]. Acta Metrologica Sinica, 2020, 41(6): 682-688.
- [6] KRUGLOV A, CHIRYSHEV Y. The image analysis algorithm for the log pile photogrammetry measurement [J]. WSEAS Transactions on Signal Processing, 2017, 13: 135-145.
- [7] 胡笑天,王克俭,唐浩,等. 一种自适应逐级开运算的原木端面识别方法[J]. 西北林学院学报, 2022, 37(5): 202-209.
- [8] 余平平,林耀海,赖云锋,等. 融合 BiFPN 和 YOLOv5s 的密集型原木端面检测方法[J]. 林业工程学报, 2023, 8(1): 126-134.
YU P P, LIN Y H, LAI Y F, et al. Dense log end face detection method using the hybrid of BiFPN and YOLOv5s[J]. Journal of Forestry Engineering, 2023, 8(1): 126-134.
- [9] 廖丽瑛,刘洪. 基于改进 YOLOv8 的绝缘子自爆缺陷检测[J]. 电子测量技术, 2024, 47(18): 138-144.
LIAO L Y, LIU H. Self-explosion defect detection of insulator based on improved YOLOv8 [J]. Electronic Measurement Technology, 2024, 47(18): 138-144.
- [10] 杨攀,郑积仕,冯芝清,等. 基于 Mask R-CNN 的密集木材检测分割方法[J]. 林业工程学报, 2022, 7(2): 135-142.
YANG P, ZHENG J SH, FENG ZH Q, et al. Dense log detection and segmentation method based on Mask R-CNN [J]. Journal of Forestry Engineering, 2022, 7(2): 135-142.
- [11] 胡笑天,王克俭,王超,等. 一种基于改进 SSD 的原木端面识别方法[J]. 林业工程学报, 2023, 8(1): 141-149.
HU X T, WANG K J, WANG CH, et al. Development of log end face recognition method based on improved SSD [J]. Journal of Forestry Engineering, 2023, 8(1): 141-149.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. Computer Vision-ECCV 2016, 2016: 21-37.
- [13] WU T Y, TANG SH, ZHANG R, et al. CGNet: A light-weight context guided network for semantic segmentation [J]. IEEE Transactions on Image Processing, 2021, 30(30): 1169-1179.
- [14] LIU SH, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [15] JIANG Y Q, TAN ZH Y, WANG J Y, et al. GiraffeDet: A heavy-neck paradigm for object detection [J]. ArXiv preprint arXiv: 2202.04256, 2022.
- [16] XU X ZH, JIANG Y Q, CHEN W H, et al. DAMO-

- YOLO: A report on real-time object detection design[J]. ArXiv preprint arXiv:2211.15444, 2023.
- [17] NOH H, HONG S, HAN B. Learning deconvolution network for semantic segmentation[C]. 2015 IEEE International Conference on Computer Vision (ICCV), 2015: 1520-1528.
- [18] WANG J Q, CHEN K, XU R, et al. CARAFE: Content-aware reassembly of features [C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 3007-3016.
- [19] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample[C]. 2023 IEEE/CVF International Conference on Computer Vision (ICCV), 2023: 6004-6014.
- [20] LU H, LIU W Z, FU H T, et al. FADE: Fusing the assets of decoder and encoder for task-agnostic upsampling [C]. Computer Vision ECCV, 2022: 231-247.
- [21] LU H, LIU W Z, YE Z X, et al. SAPA: Similarity-aware point affiliation for feature upsampling [J]. ArXiv preprint arXiv:2209.12866, 2022.
- [22] YU Z P, HUANG H B, CHEN W J, et al. YOLO-FaceV2: A scale and occlusion aware face detector[J]. ArXiv preprint arXiv:2208.02019, 2022.
- [23] 余鸿晖, 郑积仕, 张世文, 等. 基于改进 YOLOv5 的整车原木数量检测方法[J]. 林业工程学报, 2022, 7(4): 135-143.
- YU H H, ZHENG J SH, ZHANG SH W, et al. Estimation of volume for logs on a vehicle using improved YOLOv5 algorithm[J]. Journal of Forestry Engineering, 2022, 7(4): 135-143.
- [24] 蔡瑞星, 林培杰, 林耀海, 等. 基于改进 YOLOv4-Tiny 的成捆原木端面检测算法[J]. 电视技术, 2021, 45(9): 92-99.
- CAI R X, LIN P J, LIN Y H, et al. A detection approach for bundled log ends based on an improved YOLOv4-tiny network[J]. Video Engineering, 2021, 45(9): 92-99.
- [25] 郑婷婷, 周浩, 王秋忆. 基于改进 YOLOv5 的电力设备检测算法[J]. 电子测量技术, 2023, 46(4): 155-160.
- ZHENG T T, ZHOU H, WANG Q Y. Power equipment detection algorithm based on improved YOLOv5 [J]. Electronic Measurement Technology, 2023, 46(4): 155-160.
- [26] 张泽龙, 林穿, 黄奕钊. 基于改进 YOLOv7 模型的变电站异物入侵识别[J]. 国外电子测量技术, 2023, 42(6): 180-187.
- ZHANG Z L, LIN CH, HUANG Y F. Substation foreign object identification intrusion based on improved YOLOv7 model [J]. Foreign Electronic Measurement Technology, 2023, 42(6): 180-187.
- [27] WANG CH Y, YE H L H, LIAO M H, et al. YOLOv9: Learning what you want to learn using programmable gradient information [J]. ArXiv preprint arXiv:2402.13616, 2024.
- [28] WANG A, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv:2405.14458, 2024.
- [29] ZHAO Y, LYU W Y, XU SH L, et al. DETRs beat YOLOs on real-time object detection [J]. ArXiv preprint arXiv:2304.08069, 2023.

作者简介

吴鹏飞, 硕士研究生, 主要研究方向为计算机视觉、智能工程核算等。

E-mail: 15971103025@163.com

李敏(通信作者), 博士, 副教授, 主要研究方向为计算机视觉、图像处理、目标检测等。

E-mail: 2008031@wtu.edu.cn

罗鹏, 博士研究生, 主要研究方向为计算机视觉与电力智能运维等。

E-mail: thornluo@whu.edu.cn

朱萍, 博士, 副教授, 主要研究方向为人工智能物联网、实时调度、分布式系统等。

E-mail: zhuping@wtu.edu.cn