

基于深度学习的森林火灾隐患识别定位方法研究

欧泽强*, 杨瑞春#, 马涵杰

广东省国土资源测绘院, 广东 广州

收稿日期: 2026年9月21日; 录用日期: 2026年10月15日; 发布日期: 2026年10月26日

摘 要

针对森林场景光照变化剧烈、目标遮挡严重、早期火情目标尺度微小、识别难度大等问题, 以轻量化YOLOv8n模型为基础, 引入MLPA多层级感知注意力机制、C2f_D轻量化特征融合模块及WIoU边界框回归损失函数, 构建改进YOLOv8n森林火灾隐患识别定位模型。以某森林保护区多源影像为数据源, 通过制备烟雾、火焰两类目标样本集, 设计消融实验, 同步构建单一模块改进模型及多模块协同改进模型, 验证了各单一改进模块的独立贡献及多模块协同优化的增益效应; 同时利用多类型复杂场景开展对比实验, 验证了改进YOLOv8n模型在小目标火情、目标遮挡、白云干扰、复杂背景、微弱烟雾及光照干扰等复杂场景下, 均可准确识别烟雾及火焰目标, 模型抗干扰能力与泛化能力显著提升, 为森林火灾早期智能预警与自动化防控提供了可靠技术方案。

关键词

森林火灾, 烟雾, 火焰, 改进YOLOv8n模型, 消融实验

Research on Forest Fire Hazard Detection and Localization Method Based on Deep Learning

Zeqiang Ou*, Ruichun Yang#, Hanjie Ma

Surveying and Mapping Institute, Lands and Resource Department of Guangdong Province, Guangzhou Guangdong

Received: September 21, 2026; accepted: October 15, 2026; published: October 26, 2026

*第一作者。

#通讯作者。

文章引用: 欧泽强, 杨瑞春, 马涵杰. 基于深度学习的森林火灾隐患识别定位方法研究[J]. 地理科学研究, 2026, 15(5): 947-956. DOI: 10.12677/gser.2026.155085

Abstract

To address challenges such as drastic lighting variations, severe target occlusion, small-scale early fire targets, and high recognition difficulty in forest environments, this study proposes an improved YOLOv8n model for forest fire hazard detection and localization. Building upon the lightweight YOLOv8n architecture, the model incorporates the MLPA multi-level perception attention mechanism, the C2f_D lightweight feature fusion module, and the WIoU bounding box regression loss function. Using multi-source imagery from a forest conservation area, we construct datasets of smoke and flame targets, design ablation experiments, and simultaneously develop single-module enhanced models and multi-module collaborative optimization models to validate the individual contributions of each improvement and the synergistic benefits of combined modules. Furthermore, comparative experiments conducted across diverse and complex scenarios demonstrate that the improved YOLOv8n model can accurately detect smoke and flames under challenging conditions including small targets, object occlusion, cloud interference, complex backgrounds, faint smoke, and lighting disturbances. The model exhibits significantly enhanced robustness and generalization capability, providing a reliable technical solution for intelligent early warning and automated prevention of forest fires.

Keywords

Forest Fire, Smoke, Flame, Improved YOLOv8n Model, Ablation Experiment

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

森林作为陆地生态系统的核心组成部分,兼具生态涵养、气候调节与社会经济支撑等多重价值。森林火灾是破坏性极强的突发性自然灾害,具有蔓延速度快、影响范围广、扑救难度大等特征,不仅会造成林木资源大面积损毁,还易引发水土流失、生物栖息地破坏等次生灾害,严重威胁林区生态安全与人民生命财产安全。研究表明,森林火灾初期多以烟雾隐匿萌发为主要特征,火焰多在蔓延阶段逐步形成[1],若能在烟雾初现、火焰萌发的隐患阶段实现精准识别与定位,可极大降低火灾扩散风险,提升防控主动性。传统森林火灾监测主要依赖人工巡护、瞭望塔观测与卫星遥感等手段,存在响应滞后、监测盲区多、易受天气地形干扰等缺[2],难以满足大范围、全天候、实时化的火情防控需求。随着深度学习技术在计算机视觉领域的快速发展,基于卷积神经网络的目标检测算法凭借自适应特征提取、端到端高效推理的优势,已成为林火智能检测的主流技术方向。现有研究中,高源等[3]将改进 YOLOv5 算法用于森林火焰检测,提升了复杂背景下的检测精度;李钦[4]通过引入注意力机制优化 YOLOv7 模型,实现了烟雾与火焰的多尺度检测;吕杰等[5]提出轻量化 FFANet 网络,通过特征融合提升火烧迹地提取效率。YOLOv8n 作为新一代轻量化检测模型,凭借速度与精度的均衡优势,在边缘设备部署中展现出巨大潜力,但在复杂森林场景下,受植被遮挡、光照畸变、云雾干扰、小尺度烟雾及火焰目标占比小等因素影响,原始 YOLOv8n 模型存在特征提取能力不足、多尺度特征融合不充分、小目标漏检误检率高、目标定位偏差较大等问题,模型泛化能力及检测精度难以适配复杂林区的火情识别定位需求。

本次研究为提升森林火灾早期隐患识别定位精度及时效性,通过主干特征增强、多尺度融合优化、损失

函数迭代的系统性改进策略，对 YOLOv8n 轻量化模型进行多维度优化改进，构建适配复杂森林场景的火灾隐患识别模型，在保障模型轻量化、适配边缘设备部署的前提下，提升森林火灾隐患识别的时效性及精准度。

2. 森林火灾隐患检测模型

2.1. YOLOv8n 模型

YOLOv8 在前代 YOLOv5、YOLOv7 的基础上，对网络结构、特征融合策略、损失函数设计及数据增强方式进行全面优化，大幅提升了模型的检测精度及泛化能力。YOLOv8n 是 YOLOv8 系列的轻量化版本，通过精简网络通道数、简化卷积模块结构、降低模型参数量与计算量，实现了检测精度与推理速度的有效平衡，适配无人机、嵌入式终端等林区边缘设备的实时检测部署需求。但在复杂森林场景中仍存在明显局限性，林区存在植被遮挡、光照强弱变化、云雾干扰、背景纹理复杂等干扰因素，且火灾初期烟雾、火焰多为小尺度目标，原始 YOLOv8n 模型特征提取能力受限、多尺度融合不充分，同时损失函数对边界框回归约束能力不足，极易出现小目标漏检、误检及定位偏移等问题。

2.2. 改进 YOLOv8n 模型

为解决原始 YOLOv8n 模型在森林火灾隐患检测中的固有缺陷，本次研究通过在主干网络引入注意力机制强化关键特征提取，优化颈部模块提升多尺度小目标融合能力，替换损失函数优化边界框回归精度，构建适用于复杂林区场景的轻量化火灾检测模型，全方位提升模型对森林烟雾、火焰目标的检测精度。改进 YOLOv8n 模型网络结构如图 1 所示。




Figure 1. The network structure of the improved YOLOv8n model
图 1. 改进 YOLOv8n 网络结构

2.2.1. 主干网络优化

YOLOv8n 原始主干网络以轻量化为核心设计目标,大幅精简特征提取通道数量,导致模型在复杂背景下的深层语义特征提取能力不足,难以有效区分火灾目标与林区复杂背景,是小目标漏检、特征表达薄弱的主要原因。为弥补主干网络特征提取的短板,本次研究在主干网络中引入多层级感知注意力机制 (Multi-Level Perception Attention, MLPA),如图 2 所示。MLPA 具备多层级特征感知与长距离依赖捕捉能力,可同时挖掘特征图空间维度与通道维度的关联信息,通过动态生成自适应注意力权重图,强化火灾目标特征响应,抑制云雾、光照等无效背景干扰,提升目标与背景的特征区分度[6]。同时 MLPA 采用轻量化结构设计,在不破坏模型轻量化优势的前提下,显著增强主干网络对森林火灾微小目标、弱特征目标的提取能力。




Figure 2. MLPA attention mechanism

图 2. MLPA 注意力机制

2.2.2. 颈部结构优化

YOLOv8n 颈部网络采用基础 C2f 模块配合 FPN-PAN 结构进行特征融合, 结构较为简单, 存在感受野受限、跨尺度特征关联挖掘不足等问题, 对初期烟雾、小型火焰等小尺度火灾隐患的特征提取能力较弱。本次研究设计轻量化 C2f_D 模块替换原始 C2f 模块, 重构颈部特征融合结构, 模块整体结构如图 3 所示。C2f_D 模块以扩张残差卷积(Dilated Wrapping Residual Convolution, DWRCov)为核心特征提取单元, 结合动态权重自适应融合机制, 在控制参数量增幅的同时扩大特征感受野, 实现多尺度特征的差异化加权融合, 精准适配森林火灾多尺度目标检测需求。




Figure 3. C2f_D network architecture

图 3. C2f_D 网络结构

1) DWRCov 扩张残差卷积结构。DWRCov 单元将扩张卷积与残差连接深度融合, 在不显著增加计算量的前提下扩大感受野范围, 同时保留浅层细节特征。该单元包含两条并行支路, 主支路采用扩张率 $r=2$ 的 3×3 扩张卷积, 在卷积核参数量不变的条件下将等效感受野从 3×3 扩大至 5×5 , 有效捕捉大范围空间上下文特征, 适配林区分散分布的火情目标; 捷径支路采用 1×1 逐点卷积进行通道维度匹配, 保留输入特征的浅层细节信息, 弥补扩张卷积易造成小目标细节丢失的缺陷。两条支路的输出特征逐元素相加后, 经批归一化(Batch Normalization, BN)与 SiLU 激活函数输出。DWRCov 的计算过程如式(1)所示。

$$F_{\text{dwr}} = \sigma \left(\text{BN} \left(\text{Conv}_{\text{dil}}(F_{\text{in}}) + \text{Conv}_{1 \times 1}(F_{\text{in}}) \right) \right) \quad (1)$$

式中: Conv_{dil} 为扩张率 $r=2$ 的 3×3 扩张卷积; $\text{Conv}_{1 \times 1}$ 为 1×1 逐点卷积; BN 为批归一化运算; σ 为 SiLU 激活函数; F_{in} 为输入特征图; F_{dwr} 为 DWRCov 输出特征图。

2) 动态权重自适应融合机制。为进一步强化小尺度火灾隐患的特征表达, C2f_D 模块引入动态权重自适应调整机制, 对输入的不同层级特征, 首先通过全局平均池化(Global Average Pooling, GAP)计算各层特征的全局响应强度, 表征该层特征对目标检测的贡献程度; 再通过 Softmax 函数生成归一化融合权重, 依据目标尺度的响应强度自动分配融合权重, 对小目标特征占比更高的浅层特征赋予更大权重, 同时弱化冗余背景特征的干扰。特征融合权重与融合过程计算如式(2)~(4)所示。

$$s_i = \text{GAP}(F_i) = \frac{1}{H \times W} \sum_{h=1}^H \sum_{w=1}^W F_i(h, w) \quad (2)$$

$$w_i = \frac{\exp(s_i)}{\sum_{k=1}^N \exp(s_k)} \quad (3)$$

$$F_{\text{fuse}} = \sum_{i=1}^N w_i \cdot F_i \quad (4)$$

式中: F_i 为第 i 层输入特征图; s_i 为该层特征的全局响应强度; H 、 W 分别为特征图的高度与宽度; w_i 为第 i 层特征的归一化融合权重; N 为参与融合的特征层级数; F_{fuse} 为最终融合输出特征图。

2.2.3. 损失函数优化

YOLOv8n 模型采用 CIoU 损失函数进行边界框回归约束, 侧重目标框与真实框的几何匹配程度, 未

对中心点偏移、宽高比失衡、样本质量差异等进行差异化约束,易出现边界框回归偏差、定位精度低、误检率偏高等问题。本次研究采用 WIoU 损失函数替代原始 CIoU 损失函数, WIoU 损失函数引入样本质量动态评估机制,可量化图像清晰度、目标完整性、干扰程度等样本属性,动态调整不同质量样本损失权重,削弱低质量干扰样本对模型训练的负面影响[7];同时优化边界框惩罚机制,针对森林火灾目标尺寸不规则、分布随机等特点,对目标框位置偏移、尺度偏差进行精准分级惩罚,修正定位偏差,提升火灾隐患目标定位精度及检测稳定性。

3. 实验分析

3.1. 数据源

以某森林保护区无人机巡检影像、林区固定点位视频监控影像以及林火监测平台历史存档影像为数据源,覆盖不同时段、不同天气条件及不同林区地貌,涵盖晴天、阴天、强光照射、云雾遮挡、植被密集等多种复杂环境。经筛选剔除模糊、过度曝光、无有效目标的无效样本,共构建有效图像数据集 3260 张,其中含火焰目标样本 1480 张,含烟雾目标样本 1780 张,部分样本同时包含两类目标。目标尺度覆盖大、中、小三级,其中像素占比小于 2% 的小目标样本占比约 42%,充分贴近火灾早期隐患特征。采用 LabelImg 工具进行标注,生成 VOC 格式标注文件,由 2 名专业人员独立标注并交叉校验,标注一致性达 5% 以上。

训练阶段引入随机翻转、尺度缩放、色域抖动、随机裁剪、模拟雾化遮挡等数据增强策略,丰富样本多样性。数据集按 8:1:1 比例随机划分为训练集、验证集、测试集,为模型训练与性能测试提供可靠支撑。相较于公开通用林火数据集,本次实验构建的数据集包含更多弱特征、小目标、复杂背景样本,更贴近真实林区巡检场景。

3.2. 模型构建

本次实验硬件配置为 Intel Core i7-12700F 处理器、NVIDIA RTX 3090 显卡,支撑深度学习模型的特征训练、参数迭代与图像推理任务;基于 Windows 10 64 位操作系统搭建深度学习开发环境,采用 Python 3.8 作为编程语言,依托 PyTorch 1.13.0 深度学习框架构建模型训练体系。

采用迁移学习策略,基于 YOLOv8n 官方预训练权重初始化模型,加速收敛并提升稳定性。优化器采用 AdamW,初始学习率设置为 0.001,权重衰减系数为 0.05;学习率采用余弦退火策略动态调整,批次大小(Batch size)设置为 32,总训练周期为 100 epoch。训练过程引入早停机制,当验证集 mAP 连续 10 轮无明显提升且损失趋于稳定时,终止训练并保存最优权重模型。

3.3. 结果分析

3.3.1. 消融实验

为总结分析 MLPA 注意力机制、C2f_D 跨尺度特征融合模块、WIoU 损失函数三项改进策略的有效性,明确单一模块与多模块协同优化对森林火灾检测性能的增益效果,以 YOLOv8n 为基准模型,设计多组消融对照实验,分别为原始 YOLOv8n、YOLOv8n + MLPA、YOLOv8n + C2f_D、YOLOv8n + WIoU、改进 YOLOv8n 模型(YOLOv8n + MLPA + C2f_D + WIoU),各组实验均在相同数据集、软硬件环境及训练参数条件下进行训练、测试,分别统计火焰、烟雾两类目标的精准率、召回率、mAP@0.5 指标,如表 1 所示;同时对各组实验模型烟雾、火焰目标检测结果进行可视化对比,如图 4 所示。

对表 1 和图 4 分析可知:

1) 原始 YOLOv8n 模型作为基准模型,对火焰目标的检测精度整体优于烟雾目标,其原因为火焰目标具备固定轮廓、显著色彩与纹理特征,特征辨识度较高;烟雾目标则具有弥散性、边缘模糊、形态

Table 1. Ablation experiment accuracy statistics
表 1. 消融实验精度统计

消融实验模型	烟雾目标			火焰目标		
	精准率/%	召回率/%	mAP@0.5/%	精准率/%	召回率/%	mAP@0.5/%
YOLOv8n	84.61	82.39	83.15	86.32	84.15	85.27
YOLOv8n + MLPA	87.29	85.73	86.42	89.15	87.62	88.36
YOLOv8n + C2f_D	86.94	86.35	87.13	88.73	88.21	88.95
YOLOv8n + WIoU	86.27	85.12	85.89	88.16	86.94	87.58
改进 YOLOv8n	90.83	89.65	90.27	92.58	91.36	92.14




Figure 4. Visual comparison of ablation experiments
图 4. 消融实验可视化对比

不规则、纹理微弱等特点，极易与天空、白云、雾气等背景融合，特征区分度低。

2) 三类改进模块均可有效弥补原始模型的检测缺陷，但优化侧重点存在明显差异。引入 MLPA 注意力机制后，模型对烟雾、火焰目标的 mAP@0.5 指标分别提升 3.27%、3.09%，MLPA 通过挖掘特征图通道与空间维度的多层级关联信息，自适应强化火情弱特征、抑制植被与光照背景干扰，对于特征弥散、边缘模糊的烟雾目标特征增强效果尤为显著；C2f_D 模块改进实验组中，烟雾、火焰目标召回率分别提升 3.96%、4.06%，C2f_D 依托扩张残差卷积结构扩大特征感受野，结合动态权重自适应机制强化多尺度特征融合能力，有效改善了小目标漏检问题；WIoU 损失函数优化实验组的性能增益相对温和，但有效弥补了模型边界框回归短板，WIoU 通过样本质量评估机制动态调整损失权重，弱化模糊、遮挡、低质量样本的负面训练影响，同时精准约束目标中心点偏移与尺度偏差，改善火焰、烟雾目标检测框漂移、定位不准等问题。

3) 多模块融合的改进 YOLOv8n 模型实现了性能最大化提升，相较于单一模块改进，呈现显著的协同优化效应；改进 YOLOv8n 模型烟雾目标精准率、召回率、mAP@0.5 分别提升 6.22%、7.26%、7.12%，

火焰目标各项指标分别提升 6.26%、7.21%、6.87%；结合图 3 可视化结果可知，原始模型存在小目标火情漏检、烟雾误检、检测框偏移等问题，单一改进模块仅能解决部分缺陷，依然存在小目标漏检、边界框偏移或背景误检等残留缺陷；改进 YOLOv8n 模型可完整、精准框选各类尺度的火焰与烟雾目标，无明显漏检与误检现象，边界框贴合度更高，极大提升了复杂森林场景下火灾隐患检测的精准性和鲁棒性，验证了多维度改进策略的科学性及有效性。

3.3.2. 不同场景检测分析

森林场景复杂多变，存在小目标火情白云干扰、光照强弱变化等多种干扰因素，为验证改进 YOLOv8n 模型的场景适应性，选取多类型复杂场景，对比原始 YOLOv8n 与改进 YOLOv8n 模型烟雾、火焰目标检测精度，统计 mAP@0.5 指标，如表 2 所示，可视化对比如图 5 所示。

Table 2. Comparison of detection accuracy across different scenarios
表 2. 不同场景检测精度对比

实验场景	YOLOv8n 模型 mAP@0.5/%		改进 YOLOv8n 模型 mAP@0.5/%		精度平均提升幅度/%	
	火焰	烟雾	火焰	烟雾	火焰	烟雾
小目标火焰场景	79.36	78.21	89.72	88.65	10.36	10.44
烟雾遮挡场景	80.15	79.03	88.93	87.86	8.78	8.83
白云背景干扰场景	81.27	80.14	89.65	88.92	8.38	8.78
复杂背景干扰场景	78.94	77.86	88.51	87.43	9.57	9.57
烟雾特征不明显场景	77.62	76.58	87.94	86.89	10.32	10.31
光照干扰场景	80.53	79.47	89.26	88.35	8.73	8.88



Figure 5. Visual comparison of detection results across different scenarios
图 5. 不同场景检测结果可视化对比

对表 2 和图 5 分析可知：

1) 原始 YOLOv8n 模型在各类复杂干扰场景下的适应性短板较为突出，在小目标火焰场景与烟雾特征不明显场景中，火焰目标像素占比极小，烟雾目标淡化弥散、有效特征信息匮乏，YOLOv8n 模型受限感受野范围与弱特征提取能力，无法充分捕捉细微火情特征；在复杂背景干扰场景下，林区密集植被、复杂纹理背景会产生大量冗余噪声，掩盖火情有效特征，导致 YOLOv8n 模型特征区分度不足，漏检、误检严重；在烟雾遮挡场景中，火情目标特征残缺、轮廓不完整，YOLOv8n 模型对不完整目标的特征拟合能力较差，难以有效识别被遮挡的火焰目标；在白云背景干扰场景中，白云纹理、形态、灰度特征与早期弥散烟雾高度相似，YOLOv8n 模型缺乏精细化特征甄别能力，易将白云干扰误判为烟雾目标，误检率显著提升；在光照干扰场景下，强光曝光、弱光阴影等会破坏火情原始色彩及纹理特征，造成目标特征

失真，导致边界框回归偏移、检测稳定性下降。

2) 相较原始 YOLOv8n 模型，改进 YOLOv8n 模型在六类场景中均实现检测精度的大幅提升，针对检测难度最大的小目标火焰与微弱烟雾场景，改进 YOLOv8n 模型火焰、烟雾精度提升幅度均超 10%，优化效果最为显著，其原因为 C2f_D 模块通过扩张残差卷积扩大特征感受野，结合动态权重自适应机制强化小尺度、弱尺度火情特征的融合能力，有效解决了早期微小火情特征提取不充分问题；同时 MLPA 多层级感知注意力机制可精准聚焦微弱火情目标区域，自适应抑制复杂背景、相似纹理、光照畸变带来的无效干扰，显著提升前景目标与背景噪声的特征区分度。在烟雾遮挡、白云干扰、复杂背景及光照干扰场景中，改进 YOLOv8n 模型依然保持稳定的性能增益，火焰与烟雾检测精度提升幅度均在 8.3% 以上；一方面 MLPA 注意力机制可对遮挡残缺目标、失真目标的有效特征进行强化补偿，抑制白云、植被等相似干扰特征响应；另一方面 WIoU 损失函数通过样本质量评估机制弱化低质量、高干扰样本的负面训练影响，精准约束复杂场景下的目标边界偏移问题，大幅提升模型定位精度与检测稳定性。

3) 结合图 4 可视化结果可直观看出，原始 YOLOv8n 模型存在小目标漏检、烟雾误检、遮挡目标失效、检测框漂移等缺陷，改进 YOLOv8n 模型可精准、完整锁定各类干扰场景下的火焰与烟雾目标，检测框贴合度更高，无明显漏检、误检现象，有效解决了传统模型火情漏检、误检与定位不准等问题，更加契合森林火灾隐患实时监测及早期预警的工程应用需求。

3.3.3. 横向算法对比

为进一步分析改进 YOLOv8n 模型的综合性能优势，选取当前主流轻量化目标检测算法 YOLOv5n、YOLOv7-tiny、MobileNetV2-SSD 进行横向对比，在相同数据集与环境下测试 mAP@0.5、参数量、推理速度(FPS)，结果如表 3 所示。

Table 3. Performance comparison of different lightweight algorithms
表 3. 不同轻量化算法性能对比

算法模型	mAP@0.5/%	参数量/M	模型大小/MB	FPS/帧·s ⁻¹
MobileNetV2-SSD	76.83	6.8	26.3	72.5
YOLOv5n	82.46	7.6	29.5	68.9
YOLOv7-tiny	84.12	8.1	31.2	65.3
YOLOv8n	84.21	7.3	28.7	70.6
改进 YOLOv8n	91.20	7.8	30.5	67.2

由表 3 可知，改进 YOLOv8n 模型综合检测精度显著高于对比算法，mAP@0.5 较次优的 YOLOv7-tiny 提升 7.08 个百分点，同时参数量仅增加 0.5M，模型体积增幅小于 6.3%，推理速度仍保持在 67 帧/秒以上，满足实时检测需求。相较于其他轻量化算法，改进 YOLOv8n 模型方法在精度大幅提升的同时，很好地保留了轻量化与高速性优势，更适合边缘设备部署。

4. 结束语

本次研究以森林火灾早期预警与精准识别定位为研究目标，基于轻量化 YOLOv8n 网络模型开展多维度结构优化，引入 MLPA 多层级感知注意力机制、C2f_D 轻量化特征融合模块及 WIoU 边界框回归损失函数，构建适配森林复杂环境的改进 YOLOv8n 火灾隐患识别定位模型。以某森林保护区多源影像为数据源，设计多组消融对照实验，验证了单一改进模块的独立贡献及协同增益效应，多模块融合改进可最大化提升模型综合检测性能；通过多类型场景对比实验，验证了在小目标火情、目标遮挡、白云相似

干扰、复杂地形背景、微弱烟雾及光照干扰等复杂场景下,改进 YOLOv8n 模型均表现出更强的抗干扰能力及泛化性能,能够较好地适配森林复杂环境,有效实现了森林火焰、烟雾目标的高精度检测,且模型综合性能显著优于 YOLOv5n、YOLOv7-tiny 及 MobileNetV2-SSD 等主流轻量化算法,为森林火灾隐患的智能识别与实时预警提供可靠技术支持。

但本次研究数据集仅来源于单一森林保护区的日间可见光巡检影像,场景覆盖范围有限,未纳入夜间低光照、浓雾、强降雨、强逆光等极端气象工况数据,也未涵盖不同植被类型、不同地形地貌的跨林区样本,模型在极端环境与跨地域场景下的泛化鲁棒性尚未得到充分验证;且仅实现了图像像素维度的目标边界框检测定位,未结合无人机位姿数据、相机内参标定结果与地理空间信息完成火情点的经纬度坐标解算,无法直接对接森林防火应急救援的空间定位需求,定位的工程应用价值有待进一步拓展。后续可通过融合可见光、红外热成像与多光谱遥感多源数据,构建覆盖昼夜交替、复杂气象条件的多模态森林火灾数据集,设计跨模态特征对齐与融合算法,突破可见光检测的场景限制,实现全天候、全工况下的火灾隐患精准识别;采集多地域、多林种、多地形的森林火灾样本,构建多元化基准数据集,引入域自适应算法缩小不同场景间的数据分布差异,提升模型跨林区、跨环境的泛化能力,拓展方法的适用范围与应用场景;结合无人机 POS 数据与相机标定技术,建立图像像素坐标与大地坐标系的映射转换模型,实现火灾隐患的地理空间定位;引入时序视频分析与扩散预测算法,开展火情发展等级判别与蔓延趋势模拟,构建集识别、定位、预警于一体的完整技术体系。

参考文献

- [1] 马礼, 罗建松, 王逸凯. 基于多源遥感数据的森林火灾监测研究[J]. 测绘与空间地理信息, 2021, 44(5): 141-145.
- [2] 蒋端, 彭龑. 基于 YOLOv8 改进的轻量化森林火灾检测算法[J]. 兰州工业学院学报, 2025, 32(2): 32-37.
- [3] 高源, 杨堃, 曹磊, 等. 基于改进 YOLOv5 的特征抑制多尺度林火检测算法[J]. 林业工程学报, 2023, 8(6): 145-153.
- [4] 李钦. 基于改进 YOLOv7 模型的森林火灾隐患广域识别方法[J]. 北京测绘, 2025, 39(11): 1636-1641.
- [5] 吕杰, 杜振丹, 邓佳雯, 等. FFANet: 特征融合与注意力机制结合的火烧迹地提取方法[J]. 地球信息科学学报, 2025, 27(12): 2983-2995.
- [6] 王晓靖, 吴俊杰, 郭瑞程, 等. 基于 YOLOv8n 的轻量化森林火灾烟雾检测算法研究[J]. 现代信息科技, 2026, 10(4): 55-59.
- [7] 雷建云, 田祚汉, 夏梦, 等. 基于改进 YOLOv8 的森林火灾检测方法研究[J]. 中南民族大学学报(自然科学版), 2026, 45(1): 97-105.