网络出版时间:2026-03-13 DOI:10.13207/j.jnwafu.2026.09.005

基于改进YOLOv8n的小目标林火监测模型

薛丰昌[1],佟雅慧[1],陈笑娟[2],秦晓波[3],杨猛[1]
(1 南京信息工程大学 遥感与测绘工程学院,江苏 南京 210044;2 河北省气象灾害防御和环境气象中心,河北 石家庄 050021;
3 河北省石家庄市气象局,河北 石家庄 050081)

[摘 要] 【目的】基于传统森林火灾深度学习监测模型对小型火源实时精确监测的局限性,提出一种改进YOLOv8n模型的森林火灾监测模型YOLOv8n_MB。【方法】在YOLOv8n的基础上,引入混合局部通道注意力(MLCA)模块,增强模型对小火源关键特征的敏感度;通过加权双向特征金字塔(BiFPN)实现跨尺度高效特征融合,以提升小目标监测能力,最终建立森林火灾监测模型YOLOv8n_MB。设计消融试验验证各改进模块的有效性,并结合CAM可视化技术及热力图重合度(intersection over Union of CAM,IoU_CAM)、显著性能量比(energy ratio,ER)、最大响应点命中率(pointing-game,PG)等量化指标分析模型,验证"模型关注区域与真实火点"的一致性。【结果】与YOLOv8n相比,YOLOv8n_MB模型的识别精确率(Precision)及平均精确度均值mA@0.5和mA@0.5:0.95分别提高2.8,3.7和2.1个百分点,召回率(Recall)下降了0.2个百分点,火点识别能力优于YOLOv8其他系列模型。改进后的YOLOv8n_MB模型在保持计算效率的同时显著提升了监测精度,能够快速、准确监测地面火源。消融试验表明,与原始YOLOv8n模型相比,YOLOv8n_MB模型的参数量减少0.19 MB,平均精确度(average precision,AP)提升2.4个百分点,具备更优的森林火灾监测性能和较低部署成本。CAM可视化与量化分析显示,YOLOv8n_MB在大范围、小目标及复杂场景下的林火识别能力均优于其他模型。【结论】YOLOv8n_MB模型实现了精度与轻量化的平衡,具备良好的小目标森林火灾监测能力。

[关键词] 森林火灾;火灾监测;YOLOv8;小目标林火
[中图分类号] S762.3+2;S126 [文献标志码] A [文章编号] 1671-9387(2026)09-0049-10

Improved YOLOv8n-based model for small-target forest fire monitoring

XUE Fengchang[1], TONG Yahui[1], CHEN Xiaojuan[2], QIN Xiaobo[3], YANG Meng[1]
(1 *School of Remote Sensing and Geomatics Engineering, Nanjing University of Information Science and Technology, Nanjing, Jiangsu* 210044, *China*; 2 *Meteorological Disaster Prevention and Environmental Meteorology Center of Hebei Province, Shijiazhuang, Hebei* 050021, *China*; 3 *Shijiazhuang Meteorological Bureau of Hebei Province, Shijiazhuang, Hebei* 050081, *China*)

Abstract: 【Objective】 To address the limitations of traditional deep learning models in the real-time and accurate monitoring of small forest fire sources, this study proposes an improved YOLOv8n-based forest fire detection model, named YOLOv8n_MB. 【Method】 Based on the YOLOv8n architecture, a Mixed Local Channel Attention (MLCA) module was introduced to enhance the model's sensitivity to key features of small fire sources. In addition, a Weighted Bidirectional Feature Pyramid Network (BiFPN) was employed to achieve efficient cross-scale feature fusion, thereby improving the small-target detection capability. The resulting forest fire

[收稿日期] 2025-07-04 [修回日期] 2025-08-25
[基金项目] 河北省重点研发计划项目(22375421D)
[作者简介] 薛丰昌(1970—),男,内蒙古呼伦贝尔人,教授,博士,博士生导师,主要从事气象灾害监测预警、气象灾害遥感及城市内涝数值模拟研究。E-mail:001968@nuist.edu.cn
[通信作者] 陈笑娟(1981—),女,河北邯郸人,正高级工程师,硕士,主要从事气象灾害监测与风险评估研究。E-mail:juan2044335@163.com

monitoring model, named YOLOv8n_MB, was further evaluated through ablation experiments to verify the effectiveness of each improved module. Moreover, Class Activation Map (CAM) visualization, together with quantitative metrics such as the intersection over union of CAM (IoU_CAM), Energy Ratio (ER), and Pointing Game (PG), was used to analyze the consistency between the model's attention regions and actual fire locations.【Result】Compared with YOLOv8, the proposed YOLOv8n_MB model achieved improvements of 2.8, 3.7, and 2.1 percentage points in detection precision, mAP@0.5, and mAP@0.5:0.95, respectively, with a decrease of 0.2 percentage points in Recall. This demonstrated its superior accuracy in fire spot detection over other YOLOv8 variants. The improved YOLOv8n_MB model significantly enhanced detection precision while maintaining computational efficiency, enabling fast and accurate monitoring of ground fire sources. Ablation experiments showed that, compared with the original YOLOv8n, YOLOv8n_MB reduced the parameters by 0.19 MB and increased the Average Precision (AP) by 2.4 percentage points, demonstrating superior forest fire detection performance and lower deployment cost. Furthermore, CAM visualization and quantitative analysis revealed that YOLOv8n_MB exhibited stronger forest fire recognition capability across large-scale, small-target, and complex scenarios than other models.【Conclusion】The YOLOv8n_MB model achieves a balance between detection accuracy and lightweight design, demonstrating strong capability on small-target forest fire monitoring.

Key words: forest fire; fire monitoring; YOLOv8; small-target forest fire

森林火灾会对生态系统及人类活动造成巨大影响[1],火灾初期火势和烟雾并不明显[2],传统的地面巡护、瞭望观测、航空巡护和卫星遥感等火灾监测方法时效性较差,准确度较低[3],难以满足早期火灾监测的需要。随着人工智能和计算机视觉技术的快速发展,研究者们开始应用深度学习技术结合视频目标识别技术进行森林火灾监测[4]。与传统方法相比,深度学习技术可以有效减少人力投入,减轻工作人员负担[5]。QIAN等[6]基于加权融合算法,将Yolov5s和EfficientDet-D2进行集成,提升了探测性能和鲁棒性;冷跻峰[7]在YOLOv7的基础上改进卷积模块,在保证监测准确率的情况下减少了算法的参数量和运算量,提升了网络的运算效率;叶铭亮等[8]提出了一种改进的Swin Transformer网络方法,该方法在Swin Transformer网络结构中对窗口自注意力机制进行改进,采用knn自注意力机制对小块噪声的识别,能够有效监测不同环境下的森林火灾;林海峰等[9]提出了一种基于深度学习的小目标森林火灾监测模型SFIRE-DetNet,该模型在航拍角度下监测小目标林火的精度和速度均表现出色。SULTAN等[10]联合使用Grad-CAM++和SmoothGrad,对多阶段深度学习火灾分类系统进行了可视化解释,能够直观呈现模型判断依据。张晓雯等[11]通过改进YOLOv7的结构来提升小目标火源的监测能力和模型轻量化性能,并用CAM技术对不同场景下的特征提取能力进行了可视化分析。

尽管上述技术在一定程度上提高了森林火灾监测的效率和准确率,但在森林背景复杂、多视角干扰等场景下,小目标火焰特征仍难以有效提取,导致小型火源的实时精确监测仍然存在挑战[12]。此外,目前大多数研究仅停留在热力图可视化方面,缺乏对模型关注区域与真实火点一致性的量化评估,限制了模型可解释性和结果的可靠性。

针对上述问题,本研究提出了一种基于改进YOLOv8n算法的森林火灾监测模型YOLOv8n_MB,在YOLOv8n中引入混合局部通道注意力(MLCA)以增强对小型火源显著特征的敏感度并降低背景干扰,采用加权双向特征金字塔(BiFPN)实现跨尺度高效特征融合以提升多尺度和多视角下的小目标监测能力,并结合CAM可视化引入IoU_CAM、ER、PG等量化指标评估模型关注区域与真实火点的一致性,以期通过改进YOLOv8n_MB提升小目标林火的监测性能,并为保证林火监测的实时性及提高监测精度提供支持。

1 YOLOv8模型及其改进策略

1.1 YOLOv8模型

YOLOv8是ultralytics公司于2023年1月推出的目标监测模型,是一个全新的SOTA(state of the art)模型[13],骨干网络采用梯度流丰富的C2f结构[14],头部网络(head)采用无锚点(Anchor-Free)模式[15],损失函数(loss)计算采用任务对齐分配器(Task-aligned assigner)样本分配策略,以有效地提升模型精度[16],并已在农林业中得到了探索应

用[17-18]。按照模型规模的不同，YOLOv8 分为 n、s、l、m、x 等 5 个类型，其中 YOLOv8n 模型规模小、参数数量少、计算量低，适合在资源受限的设备上运行。YOLOv8 网络的结构如图 1 所示。

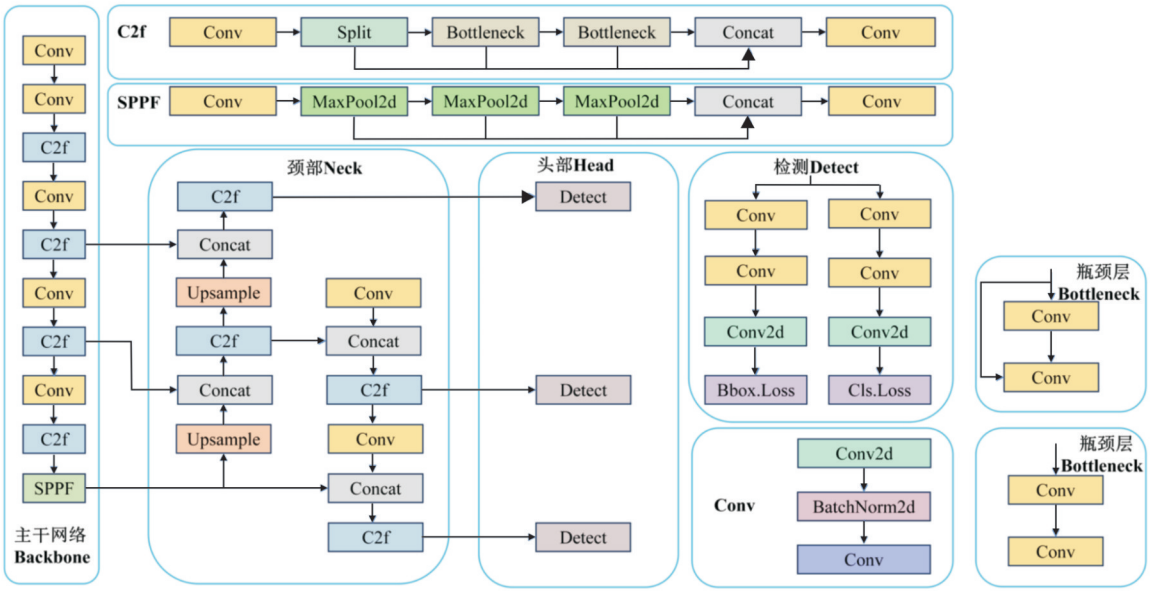


图 1　YOLOv8 模型的网络结构

Fig. 1　Network structure of the YOLOv8 model

1.2　MLCA 注意力机制

MLCA（mixed local channel attention）是一种轻量级混合局部通道注意力机制，能够实现性能和复杂性平衡[19]，其结构如图 2 所示。输入的特征图分别被局部平均池化（LAP）[20]和全局平均池化（GAP）[21]进行局部和全局特征捕捉；池化后的特征通过卷积层（Conv1d）进行压缩，同时保持空间维度不变；局部池化的特征在重新排列后通过“乘法”操作与原始输入特征进行结合，强化对有用特征的关注；全局特征经过重新排列后，通过“加法”操作与局部池化特征进行结合，融合全局上下文信息；经过局部和全局注意力处理的特征图再次通过反池化（UNAP）[22]操作，恢复到原始的空间维度[23]。

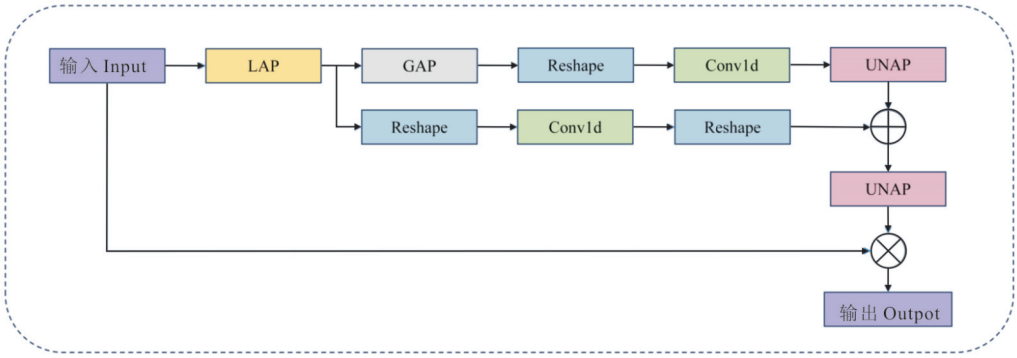


图 2　MLCA 注意力机制流程图

Fig. 2　Flowchart of the MLCA attention mechanism

1.3　BiFPN

BiFPN（双向特征金字塔网络）通过双向跨尺度连接和加权特征融合策略来提高特征融合的效率和效果[24]，其结构如图 3 所示。FPN 的核心特点是自顶向下的特征传递和横向连接，主要通过在深度卷积神经网络中构建自顶向下的特征金字塔，从而增强模型的多尺度特征表示能力[25]，同时通过 BiFPN 将 P2 层与深层特征融合，结合浅层细节与深层语义信息，增强模型对小目标火灾的感知能力。

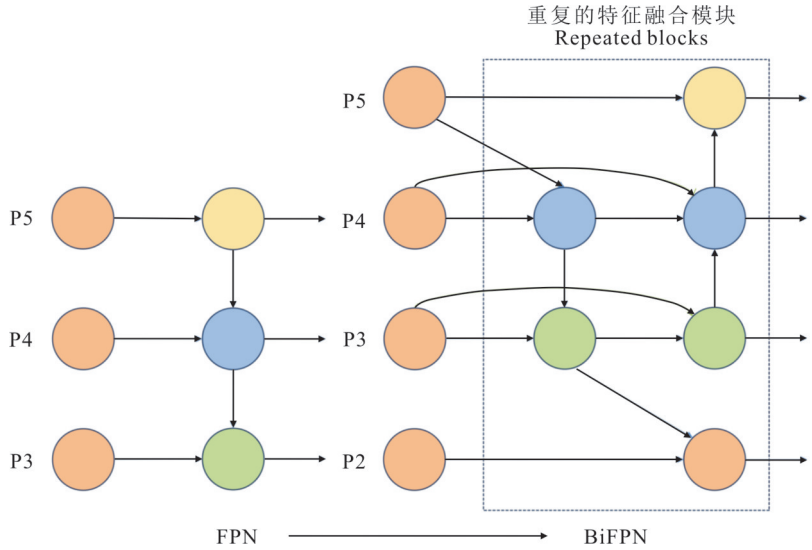


图 3 双向特征金字塔网络结构图

Fig. 3 Diagram of the Bidirectional feature pyramid network structure diagram

2 模型的改进及其性能评价

2.1 数据来源

本研究所用森林火灾图像数据来源于多渠道公开网络平台,包含国内的百度、搜狗以及国外的Google Images、Flickr等网站。初始共收集约4 600张真实火灾场景图像,涵盖多种地理环境、火势规模及拍摄条件。经过人工筛选以剔除重复、低质量及不相关图像后,最终建立了含4 400张高质量森林火灾图像的数据集。其中,3 600张为训练集,400张为验证集,400张为测试集。采用labelImg对其进行标注,标注格式为YOLO。

2.2 模型参数设置

本研究模型环境参数、训练参数设置如表1所示。

表1 模型环境参数和训练参数的配置

Table 1 Configuration of environment and training parameters for the model

参数 Parameter	配置 Configuration	参数 Parameter	配置 Configuration
操作系统 Operating system	Window10	训练轮次/次 Epochs	150
编程语言 Programming language	Python3.8	批次大小 Batch size	16
CPU	i7 14700kf	优化器 Optimizer	adam
GPU	RTX4070 TS	初始学习率 Initial learning rate	0.01
GPU 显存 GPU memory	16 GB	输入图片尺寸/像素 Input image size	640×640
框架 Framework	Pytorch		

2.3 改进后的模型结构

根据MLCA注意力机制和融合BiFPN思想,对YOLOv8n模型进行改进。首先在颈部网络(Neck)中C2f模块后面加入MLCA注意力机制模块,将融合后的特征传递给监测头,确保在不同尺度上都能充分捕捉有用的特征,以提升监测效果;然后用BiFPN替换原Neck中的FPN,使模型可以充分利用上下文信息并加强对P2层特征的表示能力,改进后的模型结构如图4所示。

2.4 模型性能评价

使用精确率(precision,P)、召回率(recall,R)、平均精确度(average precision,AP)、平均精确度均值mAP@0.5和mAP@0.5:0.95、参数量(params)、浮点运算次数(floating-point operations per second,FLOPs)、模型大小(models-size)和帧速率(frames per second,FPS)等指标对深度学习模型进行评价。其中精确率指的是在所有被模型识别为目标的样本中,被正确地识别为目标的样本所占的比例,精确率越高代表模型的误检越少,反之代表误检越多。其计算公式如下:

$$P=\frac{T_P}{T_P+F_P}。\tag{1}$$

式中:T_P表示正确监测到林火的图片数量;F_P表示错误监测为林火的图片数量。

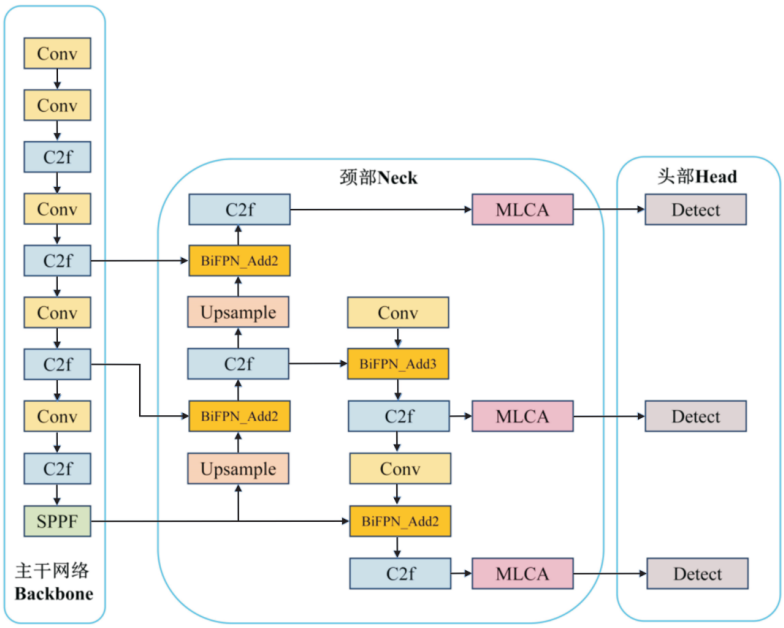


图 4　融合 MLCA 注意力机制和 BiFPN 后的 YOLOv8_MB 模型结构

Fig. 4　Architecture of the YOLOv8_MB model after integrating the MLCA attention mechanism and BiFPN

召回率指的是对于所有目标样本，被正确地监测出来的目标所占的比例，召回率越高代表模型的漏检越少，反之代表漏检越多。计算公式如下：

$$R=\frac{T_P}{T_P+F_N}。\tag{2}$$

式中：T_P 表示正确检测到林火的图片数量，F_N 表示漏检的林火图片数量。

AP 通过计算 P-R（precision-recall）曲线与坐标轴所围面积得出，其计算公式如下：

$$\mathrm{AP}=\int_0^1 P(R)\mathrm{d}R。\tag{3}$$

式中：$P(R)$ 表示召回率为 R 时对应的精度值。

mAP 使用监测框和真实框的交并比（IoU）来衡量置信度，当 IoU 阈值相同时，mAP=AP[26]。mAP@0.5 表示 IoU 阈值为 0.5 时模型的平均精确度，mAP@0.5:0.95 表示 IoU 阈值为 0.5～0.95（步长 0.05）时由 10 个阈值计算得到的模型平均精确度，其计算公式可表示为：

$$\mathrm{mAP@0.5（或mAP@0.5:0.95）}=\frac{1}{N}\sum_{i=1}^{N}\mathrm{AP}_i。\tag{4}$$

式中：N 为识别对象的类别数，AP_i 表示不同召回率时识别的平均精确度，i 表示识别对象的类别。

参数量（params）用于衡量模型复杂度及其对内存的占用情况：浮点运算次数（FLOPs）为推理过程中，模型需要执行的浮点运算数量，其值越小，代表模型对计算资源需求越低。模型大小（models-size）指训练好的模型权重文件所占用的存储空间；帧速率（frames per second，FPS）指模型每秒能够处理并完成推理的图像数量。

3　结果与分析

3.1　消融试验

为了验证对 YOLOv8n 模型改进的有效性，设计 4 组消融试验并进行对比验证。对比指标分别为平均精确度（AP）、参数量（params）、浮点运算次数（FLOPs）和模型大小（models-size），原始模型 YOLOv8n、经双向特征金字塔网络（BiFPN）替换后的 YOLOv8n+BiFPN 模型、应用轻量化 MLCA 注意力机制建立的 YOLOv8n+MLCA 模型及同时采用 2 种模块建立的 YOLOv8_MB 模型的识别效果如表 2 所示。表 2 显示，相较于原始模型 YOLOv8n（FLOPs 为 8.1 GB），YOLOv8n+BiFPN 模型的平均精确度（AP）提升了 1.6 个百分点，FLOPs 增至 8.2 GB，这是由于采用的 BiFPN 网络独有的双向信息传递和可学习的加权机制，使得不同层次的特征能够更高效地融合并保留更多的原始特征细节，从而增强了多尺度目标的监测能力，同时模型计算量和模型大小也有所增加；与原始模型 YOLOv8n 相比，YOLOv8n+MLCA 模型在计算参数量下降的情况下，AP 仍提升了 1.4 个百分点，这是因为采用的 MLCA 注意力机制强化了网络对局部特征与全

局特征的信息融合,同时通过特征池化操作去除了冗余的特征信息,在保持计算效率的同时,降低了复杂背景对火焰特征的干扰,提高了网络对林火特征的提取能力;YOLOv8_MB模型的AP较原始模型提升了2.4个百分点,FLOPs维持8.1 GB不变,在模型计算量不变和模型参数量下降了0.19 MB的情况下,模型大小增加了0.1 MB,仅为6.3 MB。综上所述,本研究提出的YOLOv8_MB模型,在保持轻量化的前提下,AP提升显著,具有良好的森林火灾监测性能和较低的部署成本。

表2 原始模型YOLOv8n及其改进模型识别效果的消融试验验证

Table 2 Ablation study on the recognition performance of the original YOLOv8n model and its improved version

试验编号 Experiment No.	YOLOv8n	BiFPN	MLCA	平均精确度(AP)/% Average precision	参数量/MB Params	浮点运算次数/GB Floating point operations (FLOPs)	模型大小/MB Model Size
1	√			77.3	11.65	8.1	6.2
2	√	√		78.9	11.65	8.2	6.3
3	√		√	78.7	11.46	8.1	6.3
4	√	√	√	79.7	11.46	8.1	6.3

注:表中"√"表示在模型改进中加入该模块。

Note: The "√" in the table indicates that the module is included in the model improvement.

3.2 CAM可视化分析

本研究通过类别激活映射(class activation mapping,CAM)技术对模型识别不同尺度的林火特征能力进行可视化分析[27],结果如图5所示。图5中,第一列代表不同条件下的森林火灾场景的原始图像,2至5列分别为原始模型YOLOv8n及其不同改进模型(YOLOv8n+BiFPN、YOLOv8n+MLCA、YOLOv8_MB)的CAM可视化结果,图中颜色越深代表模型对该区域关注度越高[27]。由图5可以看出,对于大范围的林火特征,原始YOLOv8n模型只能关注到部分林火特征,对于小火点以及在受背景干扰的情况下,模型则未能关注到火源的关键区域。相较于原始模型YOLOv8n,YOLOv8n+BiFPN模型通过对小目标层特征的融合,使得模型加强了对小目标的识别能力,但对于受植被遮挡、复杂背景干扰的林火特征仍然未做到有效的特征提取;与YOLOv8n和YOLOv8n+BiFPN模型相比,加入MLCA注意力机制模块后,YOLOv8n+MLCA模型对不同尺度下林火特征的识别和提取能力得到了有效增强。相比而言,YOLOv8_MB模型对于大范围、小目标以及复杂场景下林火特征,识别和提取能力最强。

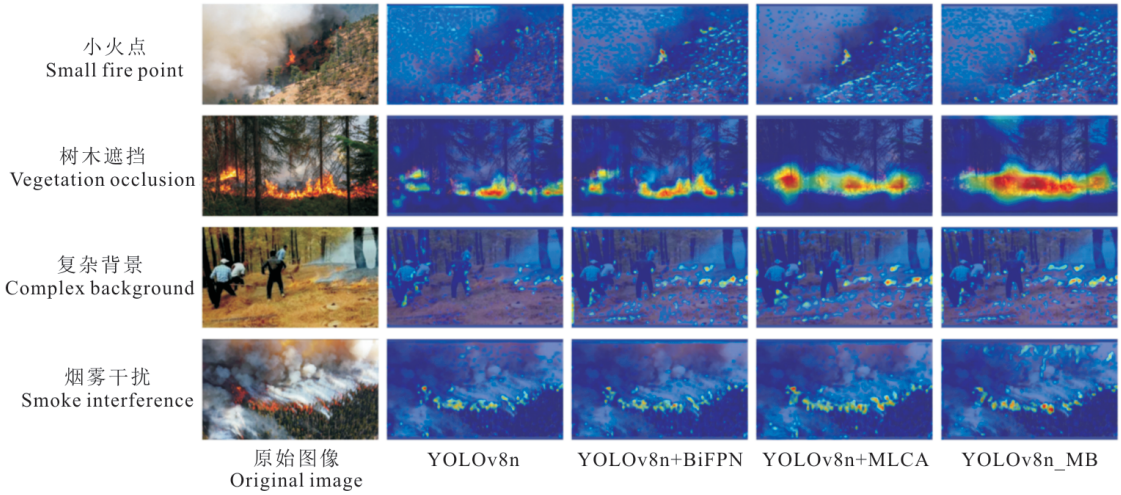


图5 原始模型YOLOv8n及其改进模型林火特征提取能力的CAM可视化分析

Fig. 5 CAM visualization analysis of forest fire feature extraction capability for the original YOLOv8n model and its improved version

CAM可视化热力图能够直观反映模型的关注区域,但缺乏定量指标来评估"模型关注区域与真实火点位置"的一致性。为此,本研究引入了热力图重合度(IoU_CAM)、显著性能量比(energy ratio,ER)和最大响应点命中率(pointing-game,PG)3项指标来进行定量化分析。其计算公式如下:

$$\mathrm{IoU_CAM}=\frac{\mathrm{Area}\left(\mathrm{CAM}_{\mathrm{high}}\cap\mathrm{GT}_{\mathrm{BBox}}\right)}{\mathrm{Area}\left(\mathrm{CAM}_{\mathrm{high}}\cup\mathrm{GT}_{\mathrm{BBox}}\right)}。\quad(5)$$

式中：IoU_CAM 表示热力图重合度，CAM_{high} 表示热力图中的高关注区域（二值化后的显著性区域），GT_{BBox} 为真实火点标注框。

$$ER=\frac{\sum_{(x,y)\in GT_{BBox}} CAM(x,y)}{\sum_{(x,y)} CAM(x,y)}。\tag{6}$$

式中：ER 为显著性能量比，表示模型在真实火点区域内所集中的注意力比例；$CAM(x,y)$ 为热力图在像素 (x,y) 处的响应强度。公式的分子部分表示真实火点区域内的能量总和，分母部分表示整幅图像中的总能量。

$$PG=\frac{S_{Hit}}{S_{Total}}。\tag{7}$$

式中：PG 为最大响应点命中率，S_{Hit} 表示热力图最大响应点落在真实火点框内的样本数，S_{Total} 表示所有测试样本数。

引入 IoU_CAM、ER 和 PG 对原始模型 YOLOv8n 及其改进模型（YOLOv8n+BiFPN、YOLOv8n+MLCA、YOLOv8_MB）关注区域与真实火点位置的一致性进行定量化分析，其结果如表 3 所示。

表 3　原始模型 YOLOv8n 及其改进模型 CAM 量化结果的对比

Table 3　Comparison of CAM quantitative results between the original YOLOv8n model and its improved version　%

模型 Model	IoU_CAM	ER	PG	模型 Model	IoU_CAM	ER	PG
YOLOv8n	50.7	52.2	85.9	YOLOv8n+BIFPM	50.8	53.6	86.4
YOLOv8n+MLCA	51.7	53.8	88.1	YOLOv8n_MB	52.6	54.5	89.9

由表 3 可以看出，YOLOv8n_MB 模型在 3 项指标上均优于其他对比模型，其中 IoU_CAM 提升至 52.6%，较原始 YOLOv8n 提高 1.9 个百分点，说明模型对火点区域的定位更加精确；ER 指标提升至 54.5%，高响应能量更加集中于真实火点区域，显著减少了背景干扰；PG 指标达到 89.9%，较 YOLOv8n 提高 4.0 个百分点，表明模型在大多数情况下能够准确锁定关键火点。

综上可见，YOLOv8n_MB 不仅在视觉上表现出更高的火点关注能力，而且在量化指标上也显著优于其他模型，为“模型关注区域与真实火点一致性”提供了充分的客观依据。

3.3　YOLOv8n_MB 与 YOLOv8n 训练过程中精度指标的变化及对比

为了直观呈现改进模型的各项指标在训练过程中的变化，本研究对精确率（P）、召回率（R）和平均精确度均值 mAP@0.5、mAP@0.5:0.95 进行可视化展示，结果如图 6 所示。

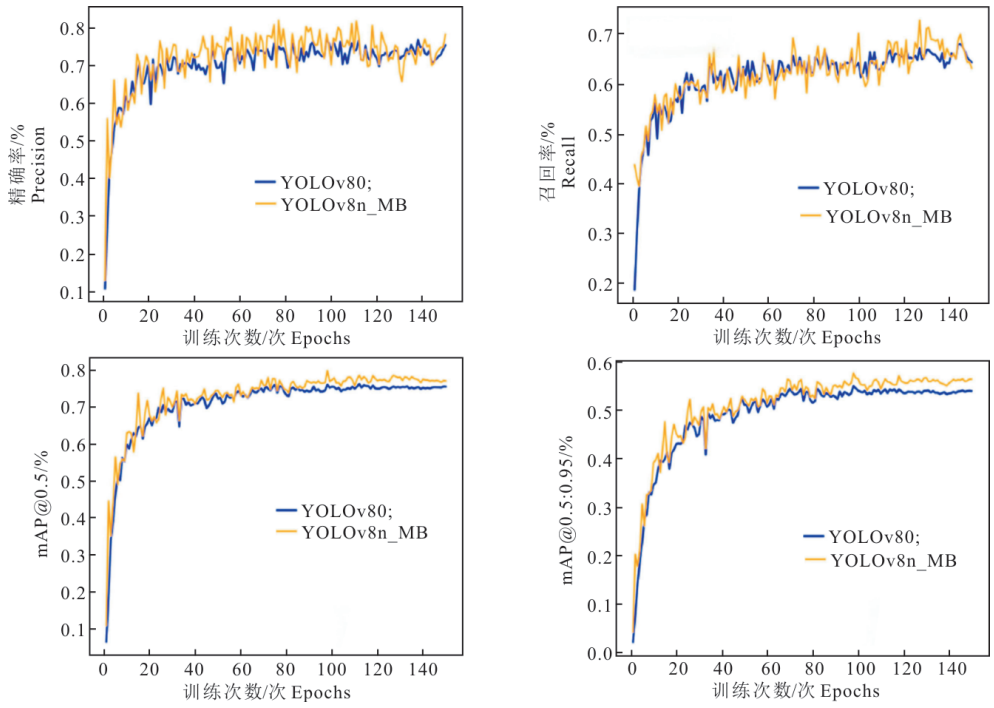


图 6　训练过程中 YOLOv8n 和 YOLOv8n_MB 模型精度指标的变化

Fig. 6　Changes in training accuracy metrics of YOLOv8n and YOLOv8n_MB

由图6可以看出,改进后的YOLOv8n_MB模型在第40轮训练后,其精确率(P)、平均精确度均值mAP@0.5和mAP@0.5:0.95整体上均高于YOLOv8n模型,并在训练后期逐渐稳定;而召回率(R)在前120轮训练中两种模型几乎一致,直到120轮后YOLOv8n_MB的召回率(R)才略高于YOLOv8n。出现这种现象的原因是由于森林火灾图像中小火源目标占比低、形态多变,正样本稀疏且定位困难,模型在训练早期更容易学习到具有显著特征的大面积火焰区域(如亮度和颜色分布),从而使精确率和mAP指标率先提升。随着训练的深入,BiFPN通过加权双向跨尺度连接,逐步增强了对小目标特征的梯度传播与融合能力,对占图像面积较小的稀疏火点,其多层级特征的稳定表征需要在积累足够的负样本并进行对比后才能形成,因此召回率的提升相对滞后。

3.4 YOLOv8n_MB与YOLO系列其他模型火点识别精度的对比

为明确改进后模型对火点的识别精度,将其与YOLO系列其他模型如YOLOv8n、YOLOv5n、YOLOv8l在相同数据集和训练参数下进行对比试验,结果如表4所示。由表4可以看出,相对于原始模型YOLOv8n,改进后模型YOLOv8n_MB的精确率(P)、平均精确度均值mAP@0.5和mAP@0.5:0.95指标分别提高了2.8,3.7和2.1个百分点;召回率(R)下降了0.2个百分点;改进后模型的帧速率(FPS)达到了34帧/s,超过常用视频实时处理标准(30 FPS),因此可实现实时火源的监测。

表4 改进后模型与YOLO其他系列模型火点识别精度的对比

Table 4 Accuracy comparison of fire point detection between the proposed model and other YOLO series models

模型 Model	R/%	P/%	mAP@0.5/%	mAP@0.5:0.95/%	FPS/(帧·s^{-1})
YOLOv8n	62.3	77.6	74.9	53.8	39
YOLOv5n	64.6	77.2	74.7	49.1	29
YOLOv8l	61.4	78.1	71.9	49.7	21
YOLOv8n_MB	62.1	80.4	78.6	55.9	34

3.5 复杂场景林火监测能力的比较

为了直观展示改进后模型YOLOv8_MB对复杂火灾场景下林火监测性能的提升效果,选取了模糊损坏场景和小火源目标场景2种复杂场景进行测试,结果如图7所示。



A、B、C为模糊损坏场景;D、E、F为小火源目标场景。A和D为原始图像;B和E为YOLOv8n模型识别效果;C和F为YOLOv8n_MB模型识别效果。

A, B, and C represent blurred or corrupted scenarios; D, E, and F represent small fire source target scenarios. A and D are the original images; B and E show the detection results of the YOLOv8n model; C and F show the detection results of the YOLOv8n_MB model.

图7 改进模型YOLOv8_MB在复杂场景下的林火监测性能

Fig. 7 Forest fire monitoring performance of the improved YOLOv8_MB model in complex scenarios

比较图7-A、B、C及图7-D、E、F可以看出,在图像背景模糊且与火源色彩相似场景下,原始YOLOv8n模型仅识别出1处火源,而改进后的模型则识别出3处火源。由图7-C和图7-F还可看出,针对

远距离小火源目标背景，相较于改进后的模型，YOLOv8n未识别出其余2处小目标火源。由此可见，在模糊损坏和小目标火源场景下，改进后的模型YOLOv8n_MB对林火的监测识别能力均有明显的提升。

4　结　论

传统森林火灾深度学习监测模型对于实时精确地监测小型火源存在一定局限性，本研究提出一种基于YOLOv8n模型改进的森林火灾监测模型YOLOv8n_MB。该模型在YOLOv8n的基础上加入混合局部通道注意力机制模块MLCA，以此增强模型对目标特征的敏感度并减少火灾背景环境的干扰；引入加权双向特征金字塔BiFPN增强特征融合，提升模型对小目标监测能力。改进后的YOLOv8n_MB模型在保持计算效率的同时，监测精度也有明显提升，能满足地面火源目标快速、精确监测的需求。

1）以YOLOv8n原始模型、YOLOv8n＋BiFPN模型、YOLOv8n＋MLCA模型作为对比模型，以平均精确度（AP）、参数量（Params）、浮点运算次数（FLOPs）和模型大小（models-size）作为对比指标，改进后的YOLOv8_MB模型的AP较原始模型提升2.4个百分点，在模型计算量不变和模型参数量下降了0.19 MB的情况下，模型大小仅增加了0.1 MB（为6.3 MB）。因此YOLOv8_MB模型在保持轻量化的前提下，AP提升显著，具有良好的森林火灾监测性能和较低的部署成本。

2）采用类别激活映射（class activation mapping，CAM）技术，对YOLOv8n、YOLOv8n＋BiFPN、YOLOv8n＋MLCA和YOLOv8_MB模型识别不同场景、不同尺度林火的特征能力进行可视化分析及量化分析。结果表明，改进模型YOLOv8_MB对大范围、小目标以及复杂场景下的林火，识别能力均优于其他模型。

3）将YOLOv8n_MB与YOLO系列其他模型的火点识别能力进行对比，改进后模型的精确率（P）、平均精确度均值mAP@0.5和mAP@0.5:0.95均高于其他3种模型，相对于原模型其上述3个指标分别提高了2.8，3.7和2.1个百分点，召回率（R）下降了0.2个百分点，火点识别能力明显优于YOLO系列其他模型。在模糊损坏和小火源目标2种复杂场景下，相较于原始模型YOLOv8n，改进模型YOLOv8_MB对林火的监测识别能力均有明显提升。

[参考文献]

[1] 王明玉，司莉青，陈锋，等. 森林火灾污染物质释放及其影响研究进展[J]. 生态学报，2024，44(12)：4933-4944.
WANG M Y，SI L Q，CHEN F，et al. Advances of forest fires pollutants release and influence[J]. Acta Ecologica Sinica，2024，44(12)：4933-4944.

[2] 孟军帅，张宇萱，王耀力，等. 基于YOLOv5的森林火灾人员救援识别算法[J]. 电子设计工程，2024，32(14)：189-195.
MENG J S，ZHANG Y X，WANG Y L，et al. Forest fire personnel rescue identification algorithm based on YOLOv5[J]. Electronic Design Engineering，2024，32(14)：189-195.

[3] XU R J，LIN H F，LU K J，et al. A forest fire detection system based on ensemble learning[J]. Forests，2021，12(2)：217.

[4] 毛少华，王文东. 基于深度学习的YOLO系列物体检测算法研究综述[J]. 延安大学学报（自然科学版），2024，43(2)：88-95.
MAO S H，WANG W D. Research review of YOLO series object detection algorithms based on deep learning[J]. Journal of Yan' an University（Natural Science Edition），2024，43(2)：88-95.

[5] ALKHATIB A A A. A review on forest fire detection techniques[J]. International Journal of Distributed Sensor Networks，2014，10(3)：597368.

[6] QIAN J J，LIN H F. A forest fire identification system based on weighted fusion algorithm[J]. Forests，2022，13(8)：1301.

[7] 冷跻峰. 基于改进YOLOv7的森林火灾检测算法[J]. 大众科技，2024，26(6)：8-12.
LENG J F. Forest fire detection algorithm based on improved YOLOv7[J]. Popular Science & Technology，2024，26(6)：8-12.

[8] 叶铭亮，周慧英，李建军. 基于改进Swin Transformer的森林火灾检测算法[J]. 中南林业科技大学学报，2022，42(8)：101-110.
YE M L，ZHOU H Y，LI J J. Forest fire detection algorithm based on an improved Swin Transformer[J]. Journal of Central South University of Forestry & Technology，2022，42(8)：101-110.

[9] 林海峰，马宇晨，蒋玲，等. 基于深度学习的小目标林火检测实验设计与实现[J]. 南京林业大学学报（自然科学版），2025，49(5)：235-241.
LIN H F，MA Y C，JIANG L，et al. Experimental design and implementation of small target forest fire detection based on deep learning[J]. Journal of Nanjing Forestry University（Natural Sciences Edition），2025，49(5)：235-241.

[10] SULTAN T，CHOWDHURY M S，SAFRAN M，et al. Deep learning-based multistage fire detection system and emerging direction[J]. Fire，2024，7(12)：451.

[11] 张晓雯，张福全. 基于SBP-YOLOv7的森林场景下明火检测方法[J]. 南京林业大学学报（自然科学版），2025，49(3)：

103-109.
ZHANG X W, ZHANG F Q. Visible forest fire detection using SBP-YOLOv7[J]. Journal of Nanjing Forestry University (Natural Sciences Edition), 2025, 49(3): 103-109.

[12] 尹俊玥,何瑞瑞,赵凤君,等. 多源卫星遥感影像的林火监测[J]. 光谱学与光谱分析,2023,43(3):917-926.
YIN J Y, HE R R, ZHAO F J, et al. Research on forest fire monitoring based on multi-source satellite remote sensing images[J]. Spectroscopy and Spectral Analysis, 2023, 43(3): 917-926.

[13] 米增,连哲. 面向通用目标检测的YOLO方法研究综述[J]. 计算机工程与应用,2024,60(21):38-54.
MI Z, LIAN Z. Review of YOLO methods for universal object detection[J]. Computer Engineering and Applications, 2024, 60(21): 38-54.

[14] HU J F, SUN J X, LIN Z H, et al. Apanet: auto-path aggregation for future instance segmentation prediction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44(7): 3386-3403.

[15] 陈义啸,沈景凤,仲梁维. 基于改进YOLOv8的森林火灾检测算法研究[J]. 软件工程,2024,27(2):49-54.
CHEN Y X, SHEN J F, ZHONG L W. Research on forest fire detection algorithm based on improved YOLOv8[J]. Software Engineering, 2024, 27(2): 49-54.

[16] 盛威,周永霞,陈俊杰,等. 基于YOLOv8-S的偏光片表面缺陷检测算法[J]. 计算机工程与应用,2025,61(6):128-140.
SHENG W, ZHOU Y X, CHEN J J, et al. Polarizer surface defect detection algorithm based on YOLOv8-S[J]. Computer Engineering and Applications, 2025, 61(6): 128-140.

[17] 齐勇杰,马纪龙,韩林蒲,等. 基于改进YOLOv8s的轻量化玉米苗期杂草识别模型[J]. 西北农林科技大学学报(自然科学版),2025,53(11):58-70.
QI Y J, MA J L, HAN L P, et al. Lightweight maize seedling weed identification model based on improved YOLOv8s[J]. Journal of Northwest A&F University (Natural Science Edition), 2025, 53(11): 58-70.

[18] 吕帅朝,马宝玲,宋磊,等. 基于YOLON网络的多形态油茶果实夜间检测方法研究[J]. 西北农林科技大学学报(自然科学版),2023,51(8):141-154.
LÜ S C, MA B L, SONG L, et al. Nighttime detection method of polymorphic *Camellia oleifera* fruits based on YOLON network[J]. Journal of Northwest A&F University (Na-tural Science Edition), 2023, 51(8): 141-154.

[19] WAN D H, LU R S, SHEN S Y, et al. Mixed local channel attention for object detection[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106442.

[20] PANDA M K, SHARMA A, BAJPAI V, et al. Encoder and decoder network with ResNet-50 and global average feature pooling for local change detection[J]. Computer Vision and Image Understanding, 2022, 222: 103501.

[21] WANG Q L, XIE J T, ZUO W M, et al. Deep CNNs meet global covariance pooling: better representation and generalization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(8): 2582-2597.

[22] SHI X Y, LV F S, SENG DW, et al. Visualizing and understanding graph convolutional network[J]. Multimedia Tools and Applications, 2021, 80(6): 8355-8375.

[23] IBRAHIM E, SHERIDAN T, MANDAVILLI S. Mesonephric like-carcinoma (MLCA) of the uterus with a predominant spindled morphology: a case report[J]. American Journal of Clinical Pathology, 2021, 156(S1): 76.

[24] ZHENG X, CHEN F, LOU L M, et al. Real-time detection of full-scale forest fire smoke based on deep convolution neural network[J]. Remote Sensing, 2022, 14(3): 536.

[25] WANG S K, DONG Q, CHEN X Q, et al. Measurement of asphalt pavement crack length using YOLO V5-BiFPN[J]. Journal of Infrastructure Systems, 2024, 30(2): 04024005.

[26] SHAFIQ M, GU Z Q. Deep residual learning for image recognition: a survey[J]. Applied Sciences, 2022, 12(18): 8972.

[27] ZHANG Z Y, WANG Z, JOE I. CAM-NAS: an efficient and interpretable neural architecture search model based on class activation mapping[J]. Applied Sciences, 2023, 13(17): 9686.

(责任编辑:温晓平)