

DOI:10.19651/j.cnki.emt.2519437

基于轻量化 YOLOv8n 的火焰烟雾检测方法^{*}

路敬祎^{1,2,3,4} 陈波^{1,3} 吴阳^{1,3} 梁棋皓^{1,3} 王鹏^{1,2,3,4}

(1. 东北石油大学三亚海洋油气研究院 三亚 572024; 2. 东北石油大学人工智能能源研究院 大庆 163318;
3. 东北石油大学电气信息工程学院 大庆 163318; 4. 黑龙江省网络化与智能控制重点实验室 大庆 163318)

摘要: 火焰与烟雾检测作为智能监控与灾害预警的重要环节,广泛应用于森林防火、工业安全等领域。然而,现有算法在自然环境下往往面临检测精确率低、速度慢、模型过大等问题。为此,本文提出一种基于轻量化 YOLOv8n 的火焰烟雾检测方法。该方法采用 PP-LCNet 替换原有主干网络以减小模型规模,引入 CARAFE 上采样算子提升特征重建能力,并融合 EMA 注意力机制以增强目标感知能力。实验结果显示,该改进模型相比 YOLOv8n 参数量减少 1.01 M,计算量降低 2.2 G,同时在检测精度和 mAP50 分别达到 94.8% 和 93.6%,在多种主流轻量化检测模型中表现最佳,兼具精确性与实时性,具备较高应用价值。

关键词: 火焰烟雾;深度学习;目标检测;YOLOv8n;轻量化

中图分类号: TN911.73;TN919.8 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Fire and smoke detection method based on lightweight YOLOv8n

Lu Jingyi^{1,2,3,4} Chen Bo^{1,3} Wu Yang^{1,3} Liang Qihao^{1,3} Wang Peng^{1,2,3,4}

(1. Sanya offshore Oil & Gas Research Institute, Northeast Petroleum University, Sanya 572024, China;
2. Artificial Intelligence Energy Research Institute, Northeast Petroleum University, Daqing 163318, China;
3. School of Electrical Information Engineering, Northeast Petroleum University, Daqing 163318, China;
4. Key Laboratory of Networking and Intellectual Control System in Heilongjiang Province, Daqing 163318, China)

Abstract: Fire and smoke detection is a critical component of intelligent surveillance and disaster early warning systems, with wide applications in forest fire prevention, industrial safety and other fields. However, existing algorithms often suffer from low detection precision, slow speed, and large model size under natural environments. To address these issues, this paper proposes a fire and smoke detection method based on the lightweight YOLOv8n. The proposed model replaces the original backbone with PP-LCNet to reduce model size, introduces the CARAFE upsampling operator to enhance feature reconstruction, and integrates the EMA attention mechanism to improve target perception capability. Experimental results show that, compared with the original YOLOv8n, the improved model reduces parameters by 1.01 M and computational cost by 2.2 G, while achieving a detection precision of 94.8% and an mAP50 of 93.6%. It outperforms other mainstream lightweight detection models, achieving an excellent balance between precision and real-time performance, and demonstrates strong practical value.

Keywords: flame smoke; deep learning; object detection; YOLOv8n; lightweight

0 引言

火灾的不可预测性和危险性使其成为全球范围内农业、城市规划以及自然资源管理中的重大挑战。烟雾作为火灾的产物,不仅影响大气质量,更可能引发健康问题。因此在火灾发生的初期阶段进行火灾识别对灾害预防管理至

关重要^[1]。在这一背景下,研究者们致力于开发智能、高效的火灾监测解决方案。

随着深度学习理论的研究和软硬件性能的显著提高,深度卷积神经网络在计算机视觉领域的应用和发展得到了强力推进,其中目标检测技术是该领域的研究热点^[2]。基于深度学习的目标检测方法凭借其具备更强的特征提取与

收稿日期:2025-07-24

^{*} 基金项目:国家自然科学基金(62473096)、中国博士后科学基金(2023MD744179)、海南省自然科学基金(623MS071)、黑龙江省自然科学基金(LH2023H001)项目资助

描述能力,适用于越来越复杂的自然环境中,逐渐成为火灾检测研究的趋势^[3]。在这个背景下 YOLO 算法备受关注, YOLO 是一种高效而强大的目标检测算法,以其实时性和准确性而著称^[4]。

然而,现有研究在兼顾检测精度与模型轻量化方面仍存在不足。罗卿莉等^[5]在 YOLOv5s 网络中引入 P6 特征层与 C3RepGhost 模块显著提升了检测精度并减少了计算量,但多尺度特征融合带来了更高的特征图存取与数据传输开销,导致访存量上升、推理速度下降。刘春霞等^[6]通过优化 YOLOv7-tiny 结构提升了烟火检测精度,并在一定程度上降低参数量和计算量,但其特征融合仍依赖多层卷积堆叠,模型深度较大,整体计算复杂度仍高于 YOLOv8n 等新一代轻量模型。刘振等^[7]在 YOLOv8n 基础上构建了轻量化模型 YOLOv8n-AEM,在提升检测精度的同时降低了参数量,但由于网络结构中同时叠加多种模块,特征融合路径更复杂、内存访问更频繁,导致模型的计算负载增加,浮点计算量由 8.1 G 升至 11.5 G,计算复杂度有所增加。钱伟等^[8]在 YOLOv10n 中引入动态卷积模块和轻量化注意力模块,改善了模型精度与轻量化性能,但整体提升幅度有限,且由于数据集规模较小,泛化能力仍有待验证。王浩宇等^[9]在 YOLO11n 基础上融合 FasterNet 主干网络、局部窗口级联分组注意力机制及双向全局-局部特征融合结构,有效增强了模型的特征提取与多尺度融合能力,改进模型的精确率和平均精度均值分别达到 91.6% 和 94.3%,体现出较好的检测效果与泛化能力,但未对模型规模与轻量化性能进行系统分析,仍存在可优化空间。

综上所述,在保持检测精度的同时实现模型轻量化,仍是火灾检测领域亟待突破的核心难题。这一矛盾推动了轻量化技术的持续演进,当前研究主要围绕“网络结构优化—算法加速—模型压缩”3 大方向展开,形成了涵盖轻量化网络设计、结构化剪枝、量化编码与知识蒸馏等关键技术的完整技术体系。其中,模型压缩类方法能够有效降低参数量与计算量,但在高压缩倍率下易导致特征层过度删减,关键信息提取能力下降,检测精度明显降低,难以在速度与精度之间取得平衡。相比之下,基于网络结构创新与算法优化协同设计的轻量化思路,可在保持特征表达能力的同时提升模型效率,已成为近年来研究的主流方向。

基于上述分析,本研究提出一种基于轻量化 YOLOv8n 的火焰烟雾检测方法。该方法通过融合 PP-LCNet 轻量化网络 (paddlepaddle-lightweight cpu network, PP-LCNet)、CARAFE 上采样算子 (content-aware reassembly of features, CARAFE) 和 EMA 注意力机制 (efficient multi-scale attention, EMA),在提升检测精度的同时显著减少了模型的参数量和计算量。此研究为应对火焰烟雾威胁提供了一种快速可靠的检测模型,有望为应急响应、资源管理和公共安全保障中发挥重要作用。

1 原理及改进

1.1 PP-LCNet 网络

在构建火焰烟雾检测网络时,需要平衡检测速度与精度。常用的主干网络,如 ResNet101^[10] 和 DarkNet53 采用多层卷积残差结构,能够有效提取输入特征,但这也带来了高计算复杂度,降低了实时性。

为了提升检测效率并满足边缘设备对实时性的要求,近年来轻量化网络结构逐渐成为研究热点。如何在保持检测精度的同时,有效提取图像特征并显著降低推理时间,仍是一项关键挑战。为此,本文选用高效的轻量化网络 PP-LCNet 作为特征提取模块,以加快模型推理速度并增强其在资源受限环境下的部署能力。

MobileNetV1 网络通过使用深度可分离卷积替代传统卷积,从而提升了模型的检测速度,并减少计算成本。深度可分离卷积采用深度卷积 (depthwise, DW) 和逐点卷积 (pointwise, PW) 替代传统卷积,从而显著减少了模型的参数量和计算负担。

如图 1(a) 所示,在传统卷积操作中,采用尺寸为 $D_k \times D_k \times M$ 的 N 个卷积核对输入特征图的 M 个通道进行卷积运算,生成尺寸为 $D_w \times D_w \times N$ 的输出特征图。计算显示,传统卷积操作的计算量 C_{cal1} 和参数量 C_{par1} 计算公式分别为:

$$C_{cal1} = D_k \times D_k \times M \times N \times D_w \times D_w \quad (1)$$

$$C_{par1} = D_k \times D_k \times M \times N \quad (2)$$

如图 1(b) 所示,在进行深度可分离卷积时,首先用尺寸为 $D_k \times D_k \times 1$ 的 M 个卷积核对通道 M 的输入特征图进行 DW 处理,接下来,对所获得的特征图进行 PW 处理,并计算所需的计算量 C_{cal2} 和参数量 C_{par2} 计算公式分别为:

$$C_{cal2} = (D_k \times D_k \times M + M \times N) \times D_w^2 \quad (3)$$

$$C_{par2} = D_k \times D_k \times M + M \times N \quad (4)$$

将深度可分离卷积的计算量 C_{cal2} 除以传统卷积的计算量 C_{cal1} 可以得到:

$$\frac{C_{cal2}}{C_{cal1}} = \frac{(D_k \times D_k \times M + M \times N) \times D_w^2}{D_k \times D_k \times M \times N \times D_w \times D_w} = \frac{1}{N} + \frac{1}{D_k^2} \quad (5)$$

式中: D_k 为卷积核的尺寸; M 为输入的通道数; N 为输出的通道数; D_w 为输出特征图的尺寸。

通过前面的分析,发现用深度可分离卷积取代传统的卷积方法能有效地降低模型的计算量和参数量。为此,PP-LCNet 引入类似于 MobileNetV1 的深度可分离卷积模块 DepthSepConv 作为其核心部分。该模块包括 DW、PW 和 SE 网络 (squeeze-and-excitation network, SENet)^[11], DW 负责过滤输入特征图每个通道上的空间信息, PW 用于映射输入特征图的通道信息,而 SENet 则突出输入特征图中的重要通道。为了提高性能,PP-LCNet 将 DepthSepConv 模块中的 $relu$ ^[12] 激活函数替换为 MobileNetV3 中的

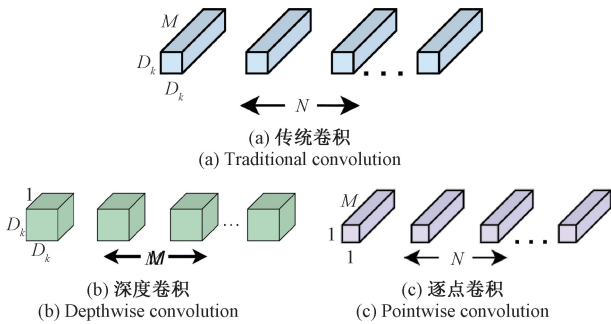


图1 普通卷积与深度可分离卷积的区别

Fig. 1 The difference between ordinary convolution and depth separable convolution

h -swish 激活函数,避免了大量的指数运算。其整体结构如图2所示。

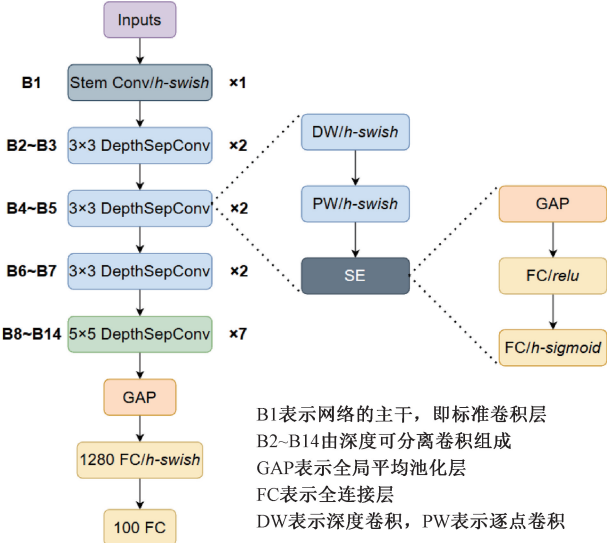


图2 PP-LCNet网络结构

Fig. 2 PP-LCNet network structure

相较于YOLOv8n的CSPDarknet53主干网络,PP-LCNet所采用的深度可分离卷积结构在检测任务中表现出更优的浅层特征保留能力。这种卷积方式通过对空间卷积与通道卷积的分离操作,使网络在提取局部高频信息时减少了通道间特征混叠,从而有效保留了火焰边缘、纹理及亮度梯度等细粒度特征。相反,CSPDarknet53由于层次更深且卷积融合度高,更倾向于形成高层语义抽象特征,在复杂背景下可能导致部分火焰纹理细节的丢失。

为进一步验证这一差异,通过特征图可视化进行对比分析。如图3所示,PP-LCNet的响应区域分布更均匀,且在火焰边缘与细微燃烧区域仍保持较高的激活强度,表明其具有更强的局部特征保持能力。而CSPDarknet53的激活主要集中于火焰主体或高亮中心区域,显示出深层语义偏好特征。由此可见,PP-LCNet在火焰纹理的细节提取与形态保持方面具有明显优势,为后续检测头提供了更丰

富、更细腻视觉特征基础。




图3 模型可视化结果

Fig. 3 Visualization results of the model

1.2 CARAFE 模块

在YOLOv8n算法中,上采样通常采用最近邻线性插值法,以提高特征图的分辨率,从而整合不同尺度的特征。然而,这种方法在复杂场景中仅依赖邻近像素值和简单加权计算,未能充分利用特征图的语义信息,导致细节和纹理信息丢失,结果显得过于平滑。

为解决这一问题,改进了YOLOv8n的最近邻线性插值法,引入CARAFE上采样算子。CARAFE通过分快处理和卷积重组,扩大感知范围,整合上下文信息,同时保留细节和边缘信息,从而提高上采样质量。

其结构如图4所示,包括上采样核预测和特征重组两部分。当改进后的YOLOv8n模型生成 $H \times W \times C$ 特征图后,将其输入到CARAFE上采样算子中。具体上采样流程为:

1)将输入特征图的通道数 C 压缩至 C_m ,以减少计算量。

2)利用 $k_{encoder} \times k_{encoder} \times \sigma^2 \times k_{up}^2$ 的卷积层对压缩后的特征图进行上采样核预测,生成 $H \times W \times \sigma^2 k_{up}^2$ 的上采样核,展开其通道维度至宽、高方向,得到包含上采样倍率 σ 和尺寸参数 k_{up}^2 的上采样核形状 $\sigma H \times \sigma W \times k_{up}^2$ 。最后对上采样核进行 $Softmax^{[13]}$ 归一化,确保卷积核权重和为1。

3)在特征重组模块中,将输出特征图的位置映射回原始特征图 X ,提取以该位置为中心的 $k_{up}^2 \times k_{up}^2$ 区域,并与对应的上采样核点积,不同通道共享同一上采样核,最终生成 $\sigma H \times \sigma W \times C$ 的特征图。

这一改进使得上采样操作更为高效,能够更好地保留原始数据的细节信息。

1.3 EMA 注意力模块

为进一步增强模型的特征提取能力,在Neck部分引入EMA注意力机制进行动态权重调整。同时,选取当前主流的CBAM^[14]、ECA^[15]、CA^[16]与EMA 4种注意力机制,分别嵌入模型进行实验对比,系统评估其在特征提取与性能提升方面的效果。在本文的数据集下,实验结果如表1所示。(实验环境参数和评价指标详见本文2.2节实验环境配置、2.3节性能评价指标)




图 4 CARAFE 结构

Fig. 4 CARAFE structure

表 1 不同注意力机制的结果比较

Table 1 Comparison of results for different attention mechanisms

模型	Precision			mAP50
	Fire	Smoke	All	
YOLOv8n-P	87.1	96.3	91.7	92.7
YOLOv8n-P-CBAM	86.5	97.2	91.8	92.0
YOLOv8n-P-ECA	87.3	96.9	92.1	92.8
YOLOv8n-P-CA	88.9	96.3	92.6	92.7
YOLOv8n-P-EMA	88.8	97.2	93.0	92.6

注: YOLOv8n-P 为主干的特征网络替换为 PP-LCNet 后的新网络

由表 1 可知, 在引入不同注意力机制后, 与仅替换主

干网络的 YOLOv8n-P 相比, 加入注意力模块后模型在保持轻量化的同时进一步增强了对目标区域的关注能力。

在本研究关注的火焰与烟雾检测任务中, 准确识别具有高动态性与不规则性的火焰和烟雾特征, 对检测精度和模型的部署效率提出了更高要求。因此, 综合考虑精度提升与模型复杂度, 本文最终选取了 EMA 模块作为注意力机制的改进方案。

EMA 是一种高效多尺度注意力机制, 其创新性地将部分通道维度转换为批处理维度, 实现跨通道建模, 避免了常规注意力机制中因降维而导致的信息损失。在提升模型表达能力的同时有效控制了计算成本, 兼顾了轻量化与精确性。与此同时, 它通过调整通道权重并融合并行子网络的输出特征, 实现更优的特征表示, 其结构如图 5 所示。

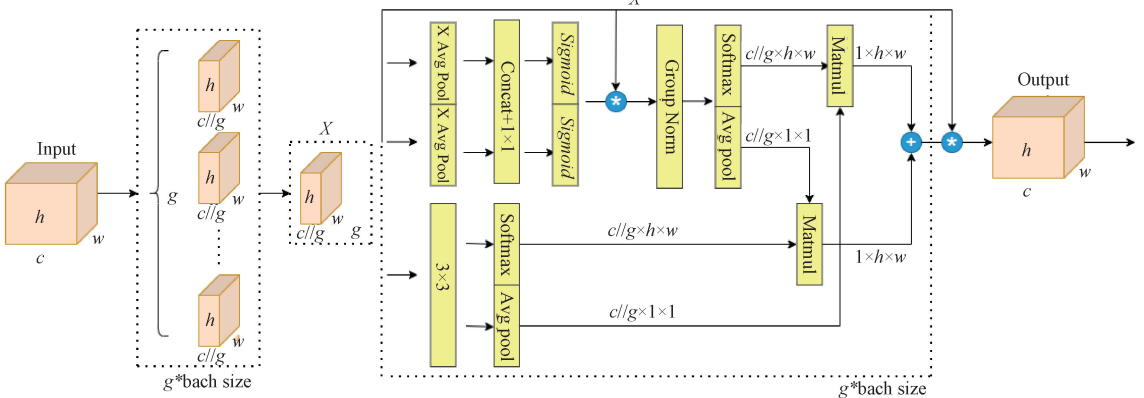


图 5 EMA 结构

Fig. 5 EMA structure

对于输入特征 $X \in \mathbf{R}^{C \times H \times W}$, EMA 根据通道数将其划分为 G 个子特征, 以学习不同语义并与输入特征 $X =$

$[X_0, X_1, \dots, X_{G-1}], X_i \in \mathbf{R}^{C/G \times H \times W}$ 关联。在确保一般性的前提下, 设定 G 明显小于输入特征的通道数 C , 并假定

通过学习的权重描述符增强每个子特征的关注区域。

EMA结构采用两个 1×1 卷积和一个 3×3 卷积的并行路径来提取特征权重。在 1×1 路径中,使用两次一维全局平均池化对信道进行编码,以防止降维。接着,将 1×1 卷积后的输出重新分解为两个向量,并通过两个Sigmoid^[17]非线性函数拟合线性卷积上的2D二进制分布。最终,通过乘法来汇聚通道注意力,实现了跨通道的交互。在 3×3 路径中,使用 3×3 卷积捕捉多尺度特征。对 1×1 和 3×3 路径的输出进行2D全局平均池化,编码全局信息,并转换为相应维度,即 $\mathbf{R}_1^{1 \times C/G} \times \mathbf{R}_2^{C/G \times H \times W}$ 。通过Softmax将两个路径的输出结合,并转换为 $\mathbf{R}^{1 \times H \times W}$ 的形式,通过矩阵点积生成空间注意力图,收集多尺度信息。EMA的最终输出尺寸与输入 \mathbf{X} 一致,便于集成到YOLOv8n网络中。

如图6所示,CARAFE和EMA模块发挥了互补的作用。CARAFE通过内容感知的重构方式实现高分辨率特征的局部细节恢复,提升空间域的结构保真度。而EMA通过跨通道的动态加权实现全局语义的自适应优化,增强通道域的信息选择能力。二者在特征融合阶段形成空间域与通道域的互补机制,CARAFE注重局部细节的精确重建,使特征更具空间辨识度。EMA注重全局语义的权重协调,使特征表达更具一致性与判别力。通过这种“局部—全局”与“空间—通道”的协同,网络既能在小目标检测中保持细节清晰,又能在复杂场景中获得稳健的语义表达,实现对多尺度目标的全面感知与精确识别。

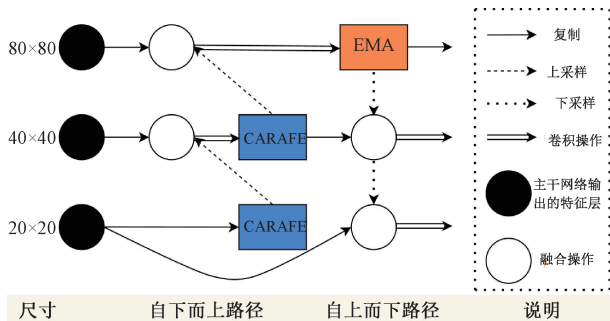


图6 特征融合路径图

Fig. 6 Feature fusion pathway diagram

1.4 改进方案

YOLOv8n以其简洁性和高精度而被视为轻量化检测的基准模型^[18],输入层负责数据增强、自适应锚框计算和图片缩放。主干网络采用CSPDarknet53,引入CSP结构以有效地处理特征图,将其分为两个部分,其中一部分直接传递给下一层,而另一部分在经过一系列处理后再与直接传递的特征图进行合并。颈部网络的作用是引入多尺度信息,以更好地适应不同尺寸的目标,通过在不同层次上获取特征图,并结合不同尺度的信息,使模型能够更全面地理解输入图像。输出层负责生成目标检测的最终结

果,这包括一系列卷积层和全连接层,以及引入锚框的概念,用于预测每个边界框的位置、置信度和类别概率。总体而言,YOLOv8n通过其精心设计的网络结构和模块组合,实现了卓越的目标检测性能。

本文首先将YOLOv8n主干的特征网络替换为PP-LCNet轻量化网络,接着在颈部将原始的Upsample^[19]替换为CARAFE上采样算子,最后加入EMA注意力机制模块。改进后的算法不仅提高了模型的特征提取能力和模型的表达能力,同时也使模型更加轻量化,大大减少了参数量和计算量。具体改进后YOLOv8n的网络结构图如图7所示。

2 实验设计

2.1 数据源

本文研究出一种针对不同环境下的火灾烟雾图像的数据增强技术,采取镜像、对比度变换、剪切、噪声、随机填充等一系列变换方法随机组合,构建了一个规模为5 000张、输入图像分辨率为 640×640 的数据集。该数据集涵盖建筑、森林、车辆等多种场景,具有形状多样与背景复杂等特点。数据标注完成后按照8:1:1将标注好的数据随机分配为训练集、验证集和测试集,分别包含3 121个火焰标注框和2 810个烟雾标注框。通过数据增强,增加样本的多样性,提高模型的泛化能力,减少过拟合^[20]。数据增强后的部分效果图如图8所示,其中镜像、剪切方法解决了目标检测中算法对样本位置敏感的问题,对比度变换、噪声、随机填充方法解决了目标检测中图片质量和遮挡物对算法学习的影响。

2.2 实验环境配置

本研究的所有实验均在统一平台上进行,采用Ubuntu22.04操作系统,基于PyTorch深度学习框架构建了实验环境,具体配置如表2所示。为确保模型达到最佳性能,通过多轮实验验证确定了最优训练配置:网络迭代轮次为300,批处理大小为16,数据加载线程数为8,优化器采用随机梯度下降法(stochastic gradient descent, SGD),初始学习率设为0.01,动量值为0.937,权值衰减值为 5×10^{-4} 。训练初期设3个epoch的学习率预热阶段,动量由0.8逐步提高,以稳定模型收敛。

2.3 性能评价指标

本文的目标是在保持检测精度的同时实现模型的轻量化。为此,实验选取精确度(Precision)、平均精度均值(mean average precision, mAP)、参数量(Parameters)以及浮点计算量(floating-point operations, FLOPs)作为模型检测性能的评估指标。这些指标综合反映了模型在检测精度、计算复杂度、参数规模和运行效率等方面的表现,有助于在火焰与烟雾检测任务中实现更高效、低延迟的目标检测方案,便于模型在边缘设备等资源受限环境中部署应用。

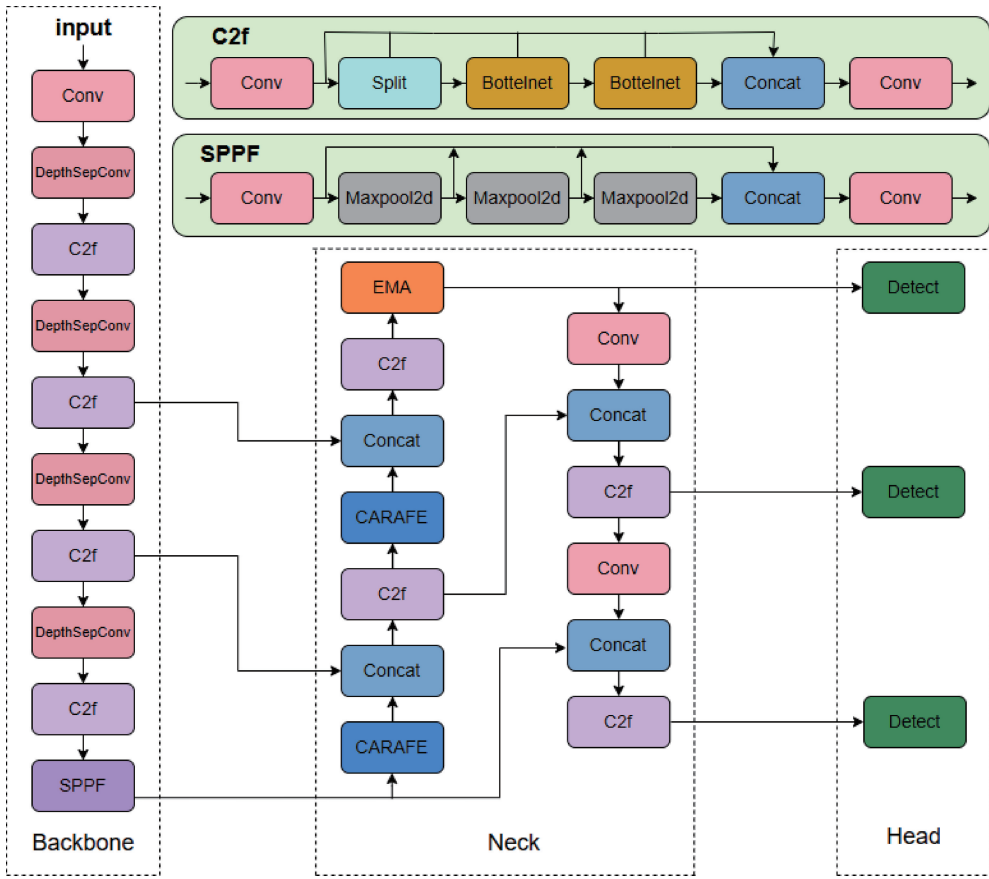


图 7 改进后的 YOLOv8n 网络结构

Fig. 7 Improved YOLOv8n network structure

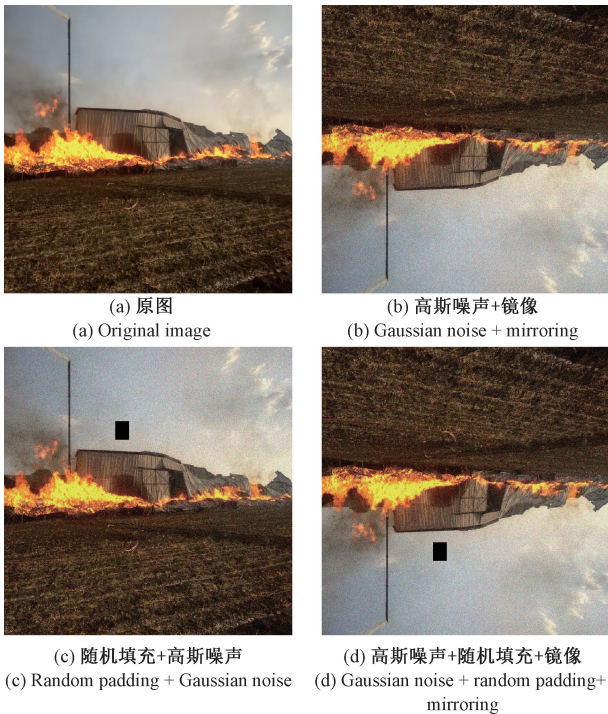


图 8 数据增强后的部分图像效果

Fig. 8 Part of the image after data enhancement

表 2 实验环境配置

Table 2 Experimental environment configuration

参数	值
PyTorch	2.1.2
CUDA	12.8
Python	3.10.8
CPU	IntelXeonPlatinum8352V
GPU	NVIDIAGeForceRTX4090

3 结果分析

3.1 结果可视化分析

为了更加直观地对原始 YOLOv8n 模型与本文所提出改进方法在火焰烟雾检测任务中的性能差异,图 9 展示了两种模型在测试集上的部分可视化检测结果。从图中可以看出,在相同输入图像下,改进后的模型在 fire 和 smoke 两类目标的检测效果明显优于原始 YOLOv8n 模型。

说明改进后的模型在保持模型轻量化的同时,增强了对火焰和烟雾目标的判别能力,具备更强的感知能力和更高的检测可靠性。整体来看,本文模型对 fire 和 smoke 两



(a) YOLOv8n检测结果
(a) Detection results of YOLOv8n

(b) YOLOv8n-Improve检测结果
(b) Detection results of YOLOv8n-Improve

图9 模型检测结果对比

Fig. 9 Comparison of model detection results

类关键目标的检测置信度和精确性均得到提升,能够更好地适用于实际场景中复杂环境下的火焰烟雾智能监测任务。

3.2 消融实验

在不同模块的消融实验中,分别引入PP-LCNet轻量化网络、EMA注意力机制和CARAFE上采样算子后,模型在精度与计算效率方面表现出显著差异,如表3所示。

引入PP-LCNet可有效降低模型参数数量与FLOPs,但在Fire类检测精度上略有下降,反映出轻量化对表征能力的挑战。相比之下,EMA模块引入多尺度注意力机制,通过融合不同感受野下的空间信息,引导模型关注局部细节与判别区域,尤其适用于形态模糊、边界不清的目标如烟雾。实验表明,引入EMA后,Smoke类检测精度由95.5%提升至97.2%,验证了其对于低对比度目标的建模优势。而Fire类提升相对有限,可能因其边缘清晰、亮度高,主干网络已能较好识别,注意力机制带来的增益不明显。

表3 不同模块消融实验

Table 3 Ablation experiments of different modules

PP-LCNet 轻量化网络	EMA 注意力机制	CARAFE上 采样算子	Precision/%			mAP50/%	Parameters/M	FLOPs/G
			Fire	Smoke	All			
—	—	—	89.0	95.5	92.2	93.4	3.01	8.1
✓	—	—	87.1	96.3	91.7	92.7	1.91	5.4
—	✓	—	86.8	97.2	92.0	93.8	3.01	8.2
—	—	✓	89.5	96.3	92.9	93.2	2.09	6.0
✓	✓	—	88.8	97.2	93.0	92.6	1.91	5.5
✓	—	✓	92.2	96.8	94.5	93.7	2.01	5.8
—	✓	✓	90.9	96.9	93.9	93.5	2.09	6.1
✓	✓	✓	90.5	99.1	94.8	93.6	2.00	5.9

CARAFE上采样模块则在保持较小计算开销的同时,全面提升Fire、Smoke和All类检测指标,体现了其对特征细节保留与空间分辨率重建的有效性。

当3种模块联合使用时,模型在Smoke检测精度达到99.1%,mAP50提高至93.6%,参数数量和FLOPs控制在2.0M和5.9G,相比基准模型YOLOv8n参数数量减少1.01M,计算量降低2.2G,表现出最优的精度—效率平衡,验证了多模块协同设计在提升目标检测性能方面的可行性与有效性。

3.3 对比实验

为进一步验证所提检测方法的有效性,本文将YOLOv8n-Improve与多种主流轻量化目标检测算法进行了对比,实验结果如表4所示。

从整体对比分析可知,YOLOv3-tiny的检测精度显著偏低,YOLOv5s与YOLOv7-tiny尽管在部分指标上具有一定优势,但其参数数量和计算开销相对较大,难以满足轻

量化部署需求。YOLOv9-t在精度方面接近本文模型,但其模型复杂度仍处于较高水平,限制了在资源受限设备上的应用。YOLOv10n、YOLOv11n及YOLOv12n在保持较高检测精度的同时,显著减少了模型参数与计算量,展现出良好的轻量化特性,但在综合性能表现上仍略低于本文改进模型。

相比之下,YOLOv8n-Improve在Fire、Smoke和All3类上的精度分别达到90.5%、99.1%和94.8%,mAP50达到93.6%,在精确率方面整体优于对比模型,尤其在烟雾检测中表现最为突出,并且在保持极低参数数量与计算量的同时,在各项检测指标上均表现优异,展现出良好的精度与效率平衡,特别适用于边缘设备与移动终端等对计算资源要求严格的应用场景。

综上,YOLOv8n-Improve在检测精度与模型效率之间实现了高度统一,验证了所提改进策略的有效性,具备在边缘计算与早期火灾预警系统中广泛应用的潜力。

表 4 对比实验
Table 4 Comparative experiments

模型	Precision/%			mAP50/%	Parameters/M	FLOPs/G
	Fire	Smoke	All			
YOLOv3-tiny	57.5	66.2	61.8	67.9	8.67	12.9
YOLOv5s	82.3	96.7	89.5	91.2	7.02	15.8
YOLOv7-tiny	77.3	96.3	86.8	88.1	6.01	13.0
YOLOv9-t	92.7	96.4	94.5	93.1	2.62	10.7
YOLOv10n	89.3	97.0	93.1	92.2	2.27	6.5
YOLOv11n	88.7	95.8	92.3	92.6	2.58	6.3
YOLOv12n	89.9	96.6	93.2	92.6	2.51	5.8
YOLOv8n	89.0	95.5	92.2	93.4	3.01	8.1
YOLOv8n-Improve	90.5	99.1	94.8	93.6	2.00	5.9

4 结 论

本文围绕在保障检测精确性的前提下实现模型轻量化化的问题,提出一种基于轻量化 YOLOv8n 的火焰烟雾检测方法。为了降低参数量和计算量,模型引入了 PP-LCNet 主干网络与 CARAFE 上采样算子。PP-LCNet 具备更强的关键特征提取能力,能够适应不同任务与数据分布,显著提升模型对复杂数据的感知能力。CARAFE 上采样算子通过扩大感受野、减少信息丢失,进一步增强了目标识别与定位的精度。此外,在模型颈部引入 EMA 注意力机制,在不增加参数量与计算开销的前提下,有效增强了局部重要信息的提取能力,使模型在多尺度特征表达上更加聚焦于关键目标区域。

实验结果表明,与多种主流轻量化目标检测算法相比,本文提出的模型在检测精度和模型轻量化方面均表现更优,为火焰与烟雾目标的高效检测提供了有力支持。

尽管改进后的模型在精度与效率方面取得了显著提升,但仍存在一定局限性。例如,模型在小目标与大目标检测方面尚未实现更精细的尺度划分。同时,当前数据集对不同燃烧材料所产生的火焰与烟雾类型覆盖仍不够全面。后续研究将着重扩充多样化火灾场景下的样本数据,特别是针对不同类型火焰和烟雾的收集与标注,并深入研究不同尺度目标的特征表达机制,从而进一步提升模型在复杂实际环境中的鲁棒性与泛化能力。

参考文献

- [1] 陈秋艳,贺敏,张新燕,等.基于图像处理的复杂场景火焰识别与火灾判定方法[J].国外电子测量技术,2024,43(5):144-153.
CHEN Q Y, HE M, ZHANG X Y, et al. Flame recognition and fire determination for complex scenes based on image processing [J]. Foreign Electronic Measurement Technology, 2024, 43(5): 144-153.
- [2] 宋中山,肖博文,艾勇,等.基于改进 YOLOv4 的轻量

化目标检测算法[J].电子测量技术,2022,45(16):142-152.

SONG ZH SH, XIAO B W, AI Y, et al. Improved lightweight YOLOv4 target detection algorithm [J]. Electronic Measurement Technology, 2022, 45(16): 142-152.

- [3] 葛梦莹,陈广华,邹新,等.基于 YOLOv9c 的隧道火灾检测算法研究[J].国外电子测量技术,2025,44(2):25-32.

GE M Y, CHEN G H, ZOU X, et al. Research on tunnel fire detection algorithm based on YOLOv9c [J]. Foreign Electronic Measurement Technology, 2025, 44(2): 25-32.

- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.

- [5] 罗卿莉,王家旭,阚唯,等.改进 YOLOv5s 的烟火检测方法[J].电子测量与仪器学报,2025,39(10):134-141.

LUO Q L, WANG J X, KAN W, et al. The refined YOLOv5s fire and smoke detection method [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(10): 134-141.

- [6] 刘春霞,张凯强,潘理虎,等.改进 YOLOv7 的高效煤矿烟火检测算法[J].计算机工程与设计,2025,46(6):1832-1840.

LIU CH X, ZHANG K Q, PAN L H, et al. Enhanced YOLOv7 algorithm for efficient coal mine fire and smoke detection [J]. Computer Engineering and Design, 2025, 46(6): 1832-1840.

- [7] 刘振,董绍江,罗家元,等.基于双目视觉和改进 YOLOv8n 的火灾检测及测距方法[J].陕西科技大学学报,2025,43(1):152-160.

- LIU ZH, DONG SH J, LUO J Y, et al. Fire detection and ranging method based on binocular vision and improved YOLOv8n [J]. Journal of Shaanxi University of Science & Technology, 2025, 43(1): 152-160.
- [8] 钱伟,罗宏,刘全义,等.改进YOLOv10的轻量化火焰检测方法[J].安全与环境学报,2026,26(3):875-883.
- QIAN W, LUO H, LIU Q Y, et al. Enhanced YOLOv10-based lightweight flame detection method[J]. Journal of Safety and Environment, 2026, 26(3): 875-883.
- [9] 王浩宇,鞠全勇.基于改进YOLO11n的消防机器人火焰检测方法[J].计算机技术与发展,2026,36(3):109-117.
- WANG H Y, JU Q Y. Fire detection method for firefighting robots based on improved YOLO11n[J]. Computer Technology and Development, 2026,36(3): 109-117.
- [10] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [11] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. 2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [12] SCHNEIDER C, VYBIRAL J. A multivariate Riesz basis of ReLU neural networks [J]. Applied and Computational Harmonic Analysis, 2024, 68: 101605.
- [13] YAO Y Q, ZOU J H, WANG H Y. Optimal poisson subsampling for softmax regression[J]. Journal of Systems Science and Complexity, 2023, 36(4): 1609-1625.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision, 2018: 3-19.
- [15] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11531-11539.
- [16] HOU Q B, ZHOU D Q, FENG J SH. Coordinate attention for efficient mobile network design[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13708-13717.
- [17] 火元莲,张乔森,张金石,等.一种用Sigmoid函数进行加权融合的图像去雾算法[J].计算机工程与科学,2023,45(9):1621-1628.
- HUO Y L, ZHANG Q S, ZHANG J SH, et al. An image dehazing algorithm using weighted fusion with the Sigmoid function [J]. Computer Engineering & Science, 2023, 45(9): 1621-1628.
- [18] LIU Q, HUANG W, DUAN X Q, et al. DSW-YOLOv8n: A new underwater target detection algorithm based on improved YOLOv8n [J]. Electronics, 2023, 12(18):3892.
- [19] YU AN F, ZHANG J D, DANG W Y, et al. Learning to upsample smoke images via a deep convolutional network [J]. IEEE Access, 2019, 7: 138932-138940.
- [20] 梁秀满,安金铭,曹晓华,等.基于改进MobileNetV3烧结断面火焰图像识别[J].电子测量技术,2023,46(14):182-187.
- LIANG X M, AN J M, CAO X H, et al. Flame image recognition of sintering section based on improved MobileNetV3 [J]. Electronic Measurement Technology, 2023, 46(14): 182-187.

作者简介

路敬祎,教授,博士,博士生导师,主要研究方向为油气管网检测、信号处理及人工智能等。

E-mail:ljywdm@126.com

陈波(通信作者),硕士研究生,主要研究方向为深度学习、嵌入式开发。

E-mail:238002060381.nepu@vip.163.com