

# 基于改进 YOLOv8 的森林火灾探测技术研究

杜世泽，银皓，丰大军，句海洋，刘天龙，李帅蓉，姚云

(华北计算机系统工程研究所，北京 100083)

**摘要：**森林火灾探测是当前的一个重点研究方向，然而，真实的森林火灾场景中存在大量的负样本数据，严重影响目标探测的性能，同时边端侧部署需要更加轻量化的模型。针对这一问题，提出了一种改进的 YOLOv8 方法，该方法首先引入 EfficientViT 模块到骨干网络（Backbone），通过级联分组注意力模块，减少计算开销；然后，在头部网络（Head）中引入 CBAM 模块，对骨干网络提取的特征进行特征增强，同时抑制噪声和无关信息；最后针对数据集的低质量样本，引入 Wise-IoU 损失函数，增强数据集训练效果。实验结果表明，改进后的 YOLOv8 模型对森林火灾的检测精度达到 79.5%，检测速度达到 75 FPS，整个模型的参数量降低了 5.7%，对森林火灾探测具有重要意义。

**关键词：**YOLOv8；森林火灾探测；图像分析；EfficientViT；注意力机制

中图分类号：TP391

文献标识码：A

DOI：10.19358/j.issn.2097-1788.2024.10.008

**引用格式：**杜世泽，银皓，丰大军，等. 基于改进 YOLOv8 的森林火灾探测技术研究 [J]. 网络安全与数据治理, 2024, 43(10): 49-56, 82.

## Research on forest fire detection technology based on improved YOLOv8

Du Shize, Yin Hao, Feng Dajun, Ju Haiyang, Liu Tianlong, Li Shuarong, Yao Yun

(National Computer System Engineering Research Institute of China, Beijing 100083, China)

**Abstract:** Forest fire detection is a key research direction at present. However, there are a large number of negative sample data in real forest fire scenarios, which seriously affects the performance of target detection. At the same time, edge to edge deployment requires more lightweight models. To address this issue, this article proposes an improved YOLOv8 method, which firstly introduces the EfficientViT module to the backbone network and reduces computational overhead by cascading group attention modules. Then, the CBAM module is introduced into the head network to enhance the features extracted by the backbone network, while suppressing noise and irrelevant information. Finally, for low-quality samples in the dataset, the Wise-IoU loss function is introduced to enhance the training effect of the dataset. The experimental results show that the improved YOLOv8 model achieves a detection accuracy of 79.5% for forest fires, a detection speed of 75 FPS, and a 5.7% reduction in the parameter count of the entire model, which is of great significance for forest fire detection.

**Key words:** YOLOv8; forest fire detection; image analysis; EfficientViT; attention mechanism

## 0 引言

当前受全球气候极端变化影响，森林火灾发生频繁，在应对森林火灾防范阶段，我国投入了大量的人力、物力和财力，通过无人机进行森林火灾巡护正成为一种主要的研究方向<sup>[1]</sup>。然而，使用无人机获取的早期林火目标尺寸较小，成像距离较远，缺少纹理特征，因此，在目标定位识别精度上还存在很大缺陷。

## 1 相关工作

国内外众多学者对森林火灾探测技术进行了研究，王冠博等<sup>[2]</sup>为解决火焰图像检测易被周围环境干扰和火

焰特征复杂等问题，提出了改进型 YOLOv4 火焰图像实时检测模型，通过 K-Means 聚类和注意力机制增强模型在通道和空间的感知力，对检测性能有一定的提升。陈义啸等<sup>[3]</sup>对 YOLOv8 进行了改进，通过卷积块注意力模块（Convolutional Block Attention Module, CBAM）注意力机制对特征通道和空间进行学习，以提升模型对特征的记忆能力。付锦燚等<sup>[4]</sup>为 YOLOv8 模型重新设计了通道特征部分卷积模块，同时在 Neck 层中添加了上下文感知模块（Context Attention Module, CAM），并且引入了 ClIoU 损失函数，优化了模型对小目标的检测性能。皮骏<sup>[5]</sup>等针对

无人机在森林火灾检测的精确率低、适应性差和软硬件限制高的问题,提出使用ShuffleNetv2替换YOLOv5s的骨干网络,减少卷积层的卷积过程,从而减小系统网络开销,通过引入注意力机制(Coordinate Attention, CA)得到特征图的二维位置信息,并利用快速空间金字塔池化(SPPF),提升系统的响应速度和准确率。杨武等<sup>[6]</sup>针对边缘智能检测设备算力弱、内存小、模型推理效率低等问题,提出了一种改进的重参数化YOLOv5s的森林火灾检测算法,结合重参数化、通道重排和深度可分离卷积(Depthwise Separable Convolution, DSC)等轻量化思想分别设计了新的骨干和颈部网络,增强特征提取能力,提高模型检测精度,使参数量和推理权重较大幅度减少。

以上研究对于无人机拍摄的森林背景图像与目标图像高度重合的场景并不适用,并且在轻量化、检测精度以及检测速度方面难以做到有效均衡。

为解决上述问题,本文首先采用数据增强技术,解决实际应用中样本量小的问题;然后,针对YOLOv8算法进行改进,采用EfficientViT<sup>[7]</sup>作为骨干网络,同时将CBAM注意力机制加入到Neck层;在损失函数计算上考虑了角度、形状以及距离的损失,引入Wise-IoU函数,提升森林火灾场景下针对小目标检测对象的检测精度和速度,降低了模型的参数量。

## 2 YOLOv8 模型基础

YOLO系列算法因其检测速度高、实时性强、结构简单等优势被广泛应用于目标检测任务当中,其网络结构在版本迭代中得到了优化,综合性能有了巨大提升<sup>[8]</sup>。当前的YOLOv8模型主要包含骨干网络(Backbone)、颈部网络(Neck)以及头部网络(Head)三个部分<sup>[9]</sup>,其网络结构如图1所示,其中 $w$ 为输出特征图的宽度, $r$ 为特征图在通道维度的数量。

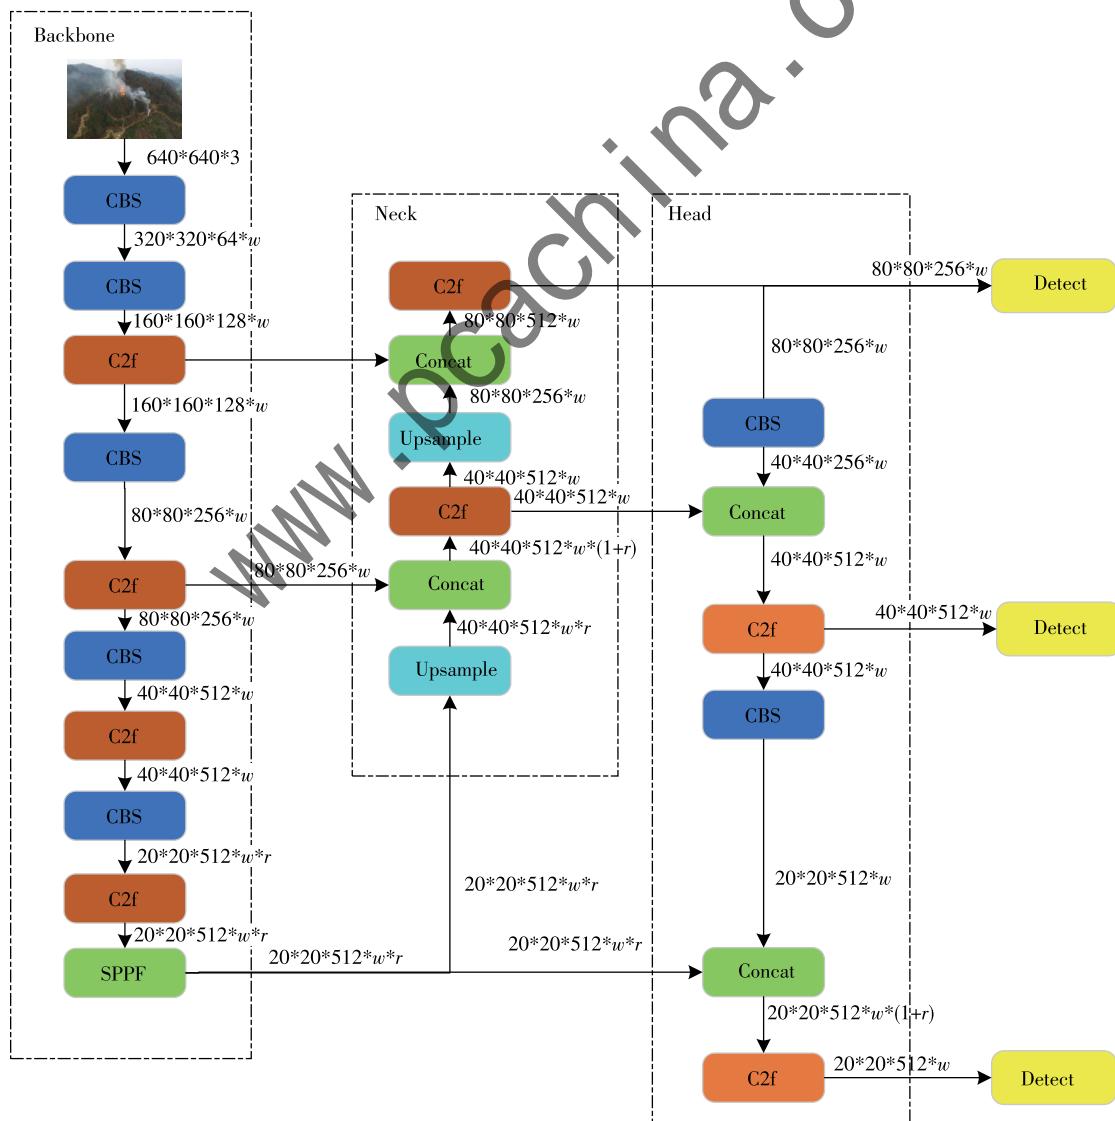


图1 YOLOv8 网络结构图

由图 1 可知，图像首先会输入到 Backbone 层进行特征提取，然后由 Neck 层对输入的特征进行池化和特征融合操作，最后由 Head 层对目标的位置和类别进行检测，输出检测结果。

Backbone 层由 CBS、C2f 以及 SPPF 模块组成<sup>[10-12]</sup>。其中，CBS 沿用 YOLOv5 的网络模块，采用二维卷积（Conv2d）、批标准化（BatchNorm2d）以及激活函数 Si-Lu；C2f 模块将原有 YOLOv5 算法中的 C3 模块进行了替换；SPPF 模块通过使用四种大小的卷积核，对图像进行特征提取。

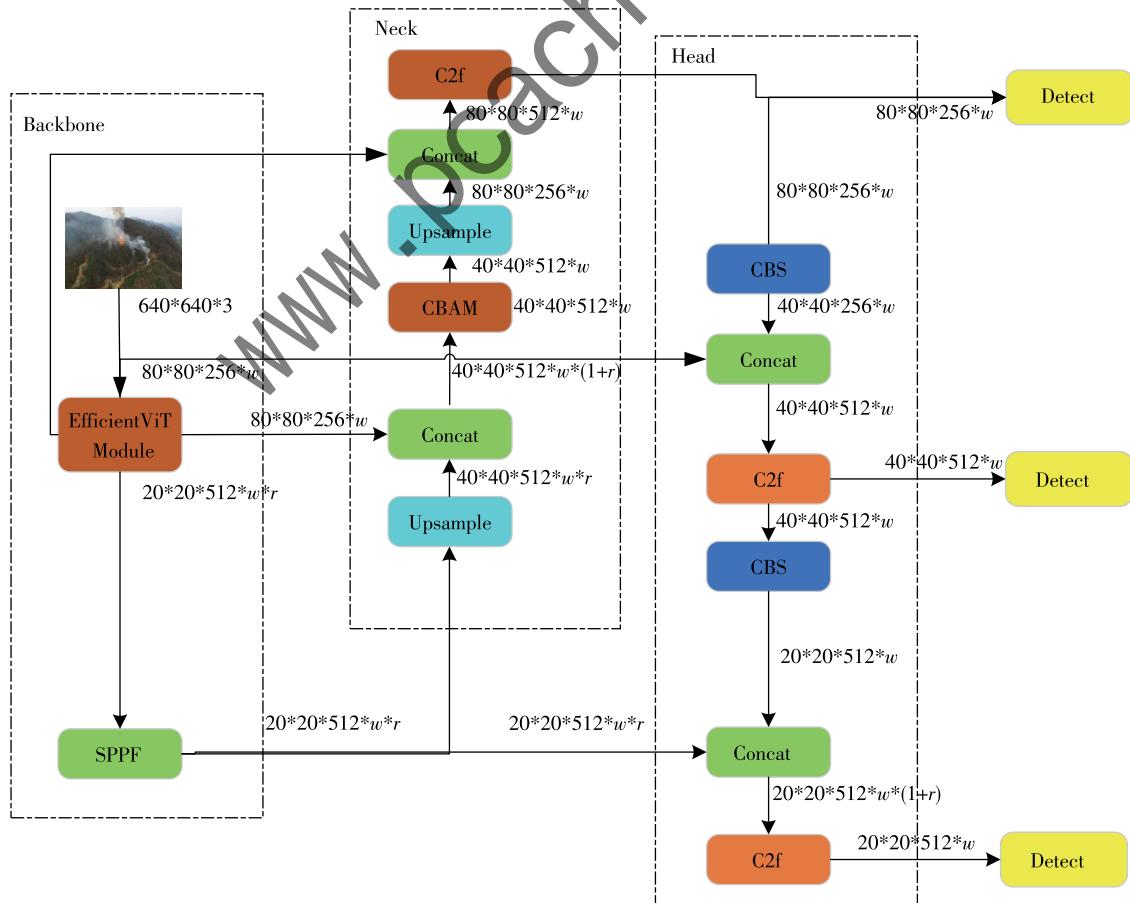
Neck 层由 C2f 模块、Upsample 上采样模块以及 Concat 张量拼接模块<sup>[13]</sup>组成，其位于 Backbone 层和 Head 层之间，对 Backbone 提取的特征进行多尺度特征融合，并把这些特征传递给预测层。

Head 层作为模型的预测部分，其采用了自适应 anchor box<sup>[14]</sup>，从而使模型能够根据不同的训练数据自动学习适配相应的 anchor box。

### 3 改进措施

#### 3.1 整体架构

本文提出的改进架构将 EfficientViT 模块加入骨干网



络中的 P1 到 P4 层，然后将 CBAM 加入到颈部网络中的 P9 层，而头部网络沿用原有的 YOLOv8 架构<sup>[15]</sup>，最后引入 Wise-IoU 损失函数。图 2 所示为改进后的系统架构图。

#### 3.2 EfficientViT 骨干网络

EfficientViT 由深度卷积前馈网络和多尺度线性注意力组成，如图 3 所示，其中，深度卷积前馈网络由深度可分离卷积<sup>[16]</sup>（Depthwise Separable Convolution, DSC）和前馈神经网络<sup>[17]</sup>（Feed-Forward Neural Network, FFN）构成。

多尺度线性注意力首先对输入进行线性变换，得到多个序列的  $Q$ 、 $K$ 、 $V$  矩阵，对每个序列，通过小核卷积生成多尺度特征，然后通过 ReLU 线性注意力对多尺度特征矩阵进行处理，各个序列的输出从前向后进行级联，在进行特征拼接后，通过 Concat 与深度卷积前馈网络进行连接。

深度可分离卷积由逐深度卷积（Depthwise Convolution, DWconv）和逐点卷积（Pointwise Convolution, PWconv）组成，深度卷积用于提取空间特征，首先在特征维度上分组卷积，假设输入的特征图有  $C_{in}$  个通道，则深度卷积的输出也有  $C_{in}$  个通道，其参数量可表示为  $N_{\text{depthwise}} = K_h \times K_w \times C_{in}$ ，其中  $K_h$  和  $K_w$  分别是卷积核的高度和宽度。

图 2 改进后的 YOLOv8 架构图

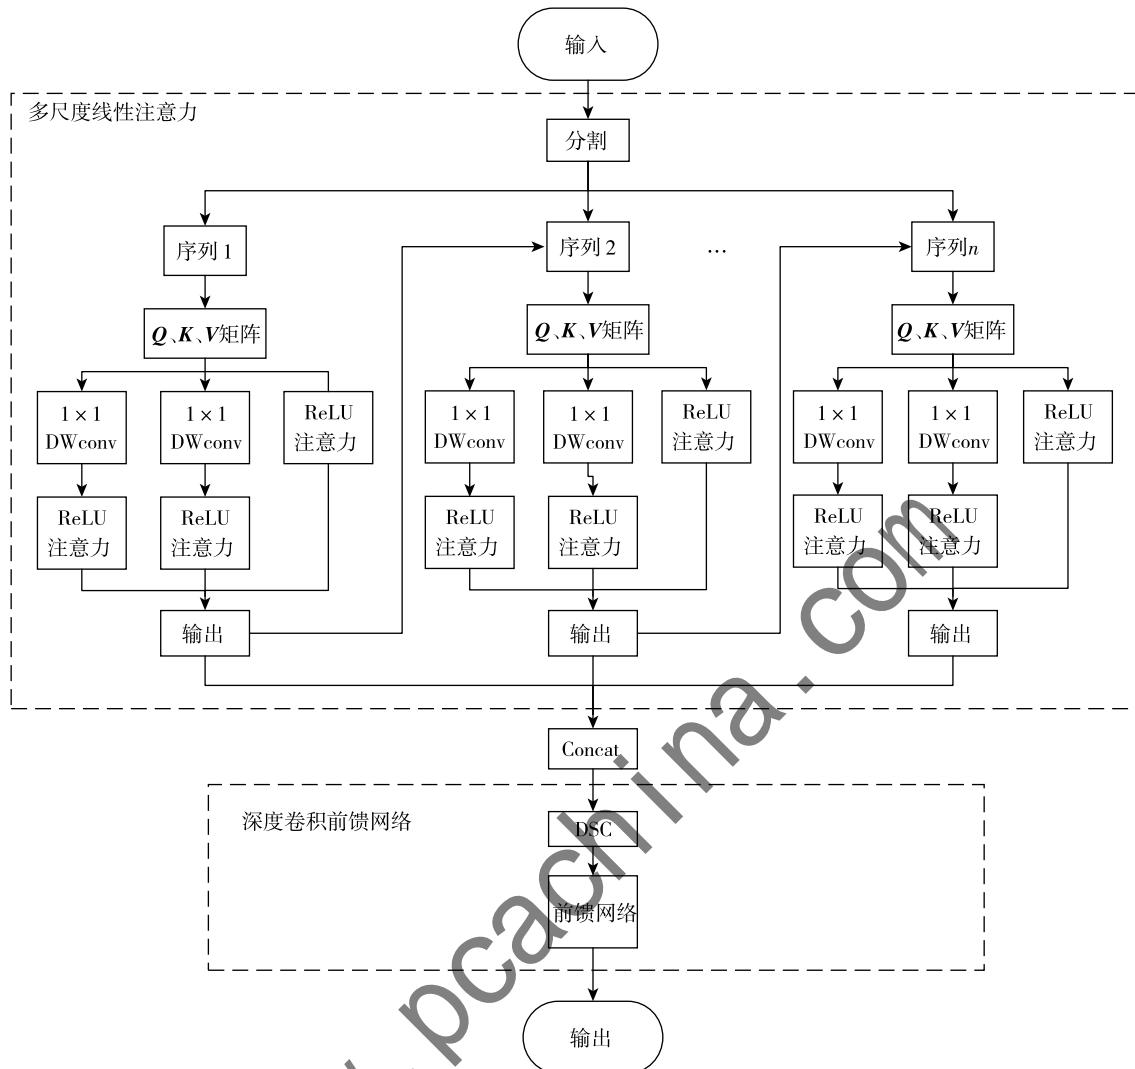


图 3 EfficientViT 网络结构图

逐点卷积使用一个  $1 \times 1$  卷积将深度卷积输出的所有通道进行聚合，假设要将输出通道数增加到  $C_{\text{out}}$ ，则逐点卷积的参数数量可以表示为  $N_{\text{pointwise}} = 1 \times 1 \times C_{\text{in}} \times C_{\text{out}}$ 。

FFN 由两个线性变换组成，这两个线性变换之间有一个 ReLU 激活函数。这种结构增加了模型的非线性，有助于捕获更复杂的模式。FFN 的数学表达式可以表示为：

$$\text{FFN}(x) = \max(0, xW_1 + b_1) W_2 + b_2 \quad (1)$$

其中， $W_1$  和  $W_2$  是权重矩阵， $b_1$  和  $b_2$  是偏置项， $\max(0, xW_1 + b_1)$  是 ReLU 激活函数的应用。

### 3.3 CBAM 注意力机制

注意力机制<sup>[18~20]</sup>是一种帮助网络模型学习输入信息重要度的方法，它通过对输入数据的不同部分赋予不同的权重，从而使模型能够更加关注重要的信息，提高了模型的性能和准确率，同时也有助于避免过拟合的情况发生，提高模型的鲁棒性。注意力机制没有严格的数学定义，传统的局部图像特征提取、滑动窗口方法也可看成注

意力的一种。一般来说在神经网络中，注意力机制是由单独的网络来实现的，可以直接聚合为一个块状结构。

注意力机制可以分为：（1）通道注意力机制，其对通道生成掩码进行打分；（2）空间注意力机制，其对空间生成的掩码进行打分；（3）混合注意力机制，其将通道和空间生成的掩码进行混合打分。

本文采用的是混合注意力机制中的 CBAM 模块，该模块包含两个部分，第一部分为通道注意力模块，第二部分为空间注意力模块，两者串行组成，其网络结构如图 4 所示。

通道注意力模块首先对输入特征图  $F$  分别使用最大值池化操作和平均池化操作聚合空间信息，输出两个  $C$  维池化特征图  $F_{\text{avg}}$  和  $F_{\text{max}}$ 。然后，将  $F_{\text{avg}}$  和  $F_{\text{max}}$  输入包含隐含层的多层感知器（Multilayer Perceptron, MLP）里，得到两个参数为  $1 \times 1 \times C$  的通道注意力图。为减少参数量，隐层神经元需要压缩输入信息，神经元个数为  $C/r$ ，

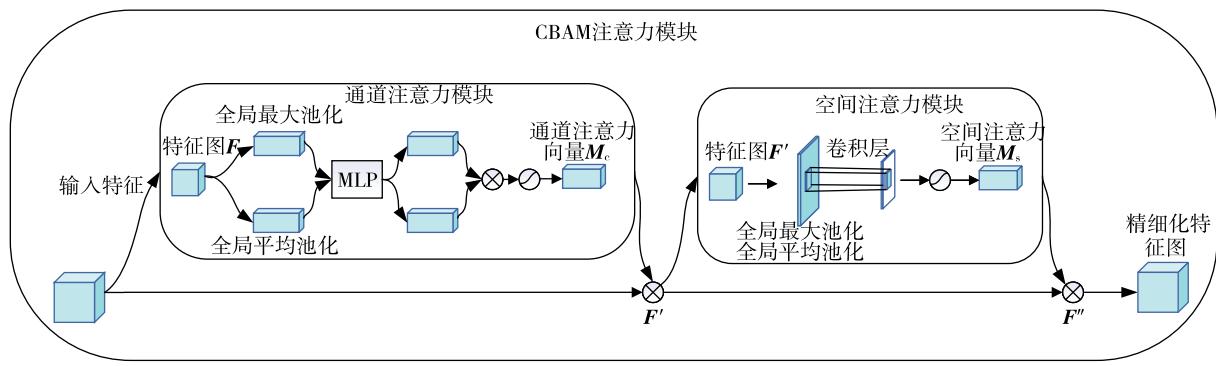


图 4 CBAM 注意力机制结构图

$r$  被称作压缩比，将上一步的输出进行叠加，便可得到通道注意力向量  $\mathbf{M}_c$ ，如式 (2) 所示：

$$\begin{aligned} \mathbf{M}_c(\mathbf{F}) &= \sigma(\text{MLP}(\text{AvgPool}(\mathbf{F})) + \text{MLP}(\text{MaxPool}(\mathbf{F}))) = \sigma(W_1(W_0(\mathbf{F}_{\text{avg}}^c) + W_1(W_0(\mathbf{F}_{\text{max}}^c)))) \end{aligned} \quad (2)$$

空间注意力模块首先输入通道注意力模块输出的特征图，按照通道维度进行平均池化操作和最大池化操作，输出两个特征图  $\mathbf{F}_{\text{avg}}^c$  和  $\mathbf{F}_{\text{max}}^c$ ，输出参数为  $1 \times H \times W$ ，并在通道维度上拼接输出的两个特征图，即可得拼接后的空间特征图。然后将拼接后的特征图使用尺寸为  $7 \times 7$  大小的卷积层进一步生成空间注意力图  $\mathbf{M}_s$ ，如式 (3) 所示：

$$\begin{aligned} \mathbf{M}_s(\mathbf{F}) &= \sigma(f^{7 \times 7}([\text{AvgPool}(\mathbf{F}); \text{MaxPool}(\mathbf{F})])) \\ &= \sigma(f^{7 \times 7}([\mathbf{F}_{\text{avg}}^c; \mathbf{F}_{\text{max}}^c])) \end{aligned} \quad (3)$$

最后，将得到的  $\mathbf{F}'$  与  $\mathbf{M}_s(\mathbf{F}')$  相乘，便可得到精细化特征图  $\mathbf{F}''$ 。

### 3.4 Wise-IoU 损失函数

Wise-IoU<sup>[21~22]</sup> 是一种用于目标检测的创新性损失函数，其机制使用“离群度”替代传统的 IoU (Intersection over Union) 来评估锚框的质量，并引入了明智的梯度增益分配策略。这一策略在降低高质量锚框竞争性的同时，也减小了低质量示例产生的有害梯度，当离群值越小时，锚框的质量就越高。

本文使用 Wise-IoU<sub>3</sub> 来评估锚框质量，设定锚框为  $\vec{\mathbf{B}} = [x, y, w, h]$ ，目标框为  $\vec{\mathbf{B}}_{gt} = [x_{gt}, y_{gt}, w_{gt}, h_{gt}]$ ，重叠度  $L_{\text{IoU}}$  计算公式为：

$$L_{\text{IoU}} = 1 - \text{IoU} = 1 - \frac{W_i H_i}{w h + w_{gt} h_{gt} - W_i H_i} \quad (4)$$

其中， $W_i H_i$  为锚框与目标框重叠部分面积，利用锚框与目标框的方差计算惩罚项因子  $R_{\text{WIoU}}$ ，通过惩罚项因子计算损失  $L_{\text{IoUV3}}$ ，计算公式如 (5) 和 (6) 所示：

$$R_{\text{WIoU}} = \exp \left( \frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*} \right) \quad (5)$$

$$L_{\text{IoUV3}} = R_{\text{WIoU}} L_{\text{IoU}} \quad (6)$$

其中  $L_{\text{IoU}} \in [0, 1]$ ， $R_{\text{WIoU}} \in [1, e]$ ， $W_g$  和  $H_g$  分别表示最小封闭框的宽和高，公式 (5) 中的 \* 表示从计算图中分离最小封闭框的操作。

使用动态非单调聚焦方法来表示锚框的离群度，即  $L_{\text{IoU}}$  与  $\overline{L}_{\text{IoU}}$  的比值，如式 (7) 所示：

$$\beta = \frac{L^*_{\text{IoU}}}{\overline{L}_{\text{IoU}}} \quad (7)$$

其中  $\beta \in [0, \infty]$ ，\* 表示分离最小  $L_{\text{IoU}}$  值的操作。

为离群度  $\beta$  分配一个小的梯度增益，以便将边界框回归聚焦在普通质量的锚框上。此外，将小的梯度增益分配给具有大离群度的锚框将有效地防止来自低质量样本的有害梯度，利用  $\beta$  构造一个非单调聚焦系数  $r$ ，如式 (8) 所示，该系数用于  $L_{\text{WIoUV3}}$  的计算，如式 (9) 所示。本文设定  $\alpha = 1$ ， $\vartheta = 0.5$ 。

$$r = \frac{\beta}{\vartheta \alpha^{\beta - \vartheta}} \quad (8)$$

$$L_{\text{WIoUV3}} = r L_{\text{WIoUV1}} \quad (9)$$

## 4 实验结果

### 4.1 实验环境和评估指标

实验是在操作系统为 Ubuntu22.04、处理器为 AMD EPYC 9754 128-Core、内存大小为 60 GB 的计算机上运行，并配有一张 24 GB 显存的 NVIDIA GeForce RTX4090D 显卡来加速训练，开发工具为 PyCharm，开发语言为 Python 3.8.0，深度学习框架为 PyTorch 2.0，CUDA 版本为 11.8，训练参数见表 1。

表 1 训练参数

参数	参数值
图片大小/像素	$640 \times 640$
初始化学习率	0.01
优化器	SGD
批量大小	4
迭代次数	300
动量	0.937

实验将从以下各方面评价不同模型的性能差异: 每秒帧数 (Frames Per Second, FPS)、平均精度均值 (mean Average Precision, mAP)、查准率 - 查全率曲线 (Precision-Recall 曲线, 简称 PR 曲线) 以及平均绝对误差 (Mean Absolute Error, MAE)。FPS、mAP 的计算分别如式 (10)、式 (11) 所示:

$$\text{FPS} = \frac{\text{Num}}{\text{Time}} \quad (10)$$

$$\text{mAP} = \frac{1}{m} \sum_{i=1}^m \text{AP}_i \quad (11)$$

其中, Num 为一定时间内图像处理的帧数,  $m$  为类别数量, AP 为类别检测的平均正确率。

Precision 和 Recall 的计算如式 (12) 和 (13) 所示:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (12)$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (13)$$

其中, TP 为正确预测为正例的样本数量, FP 为错误预测为正例的样本数量, FN 为错误预测为负例的样本数量。

MAE 的计算如式 (14) 所示:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N (t_i - c_i) \quad (14)$$

其中,  $t_i$  为第  $i$  张图片中烟雾火灾的真实数量 (通过人工计数得到),  $c_i$  为算法预测的第  $i$  张图片中烟雾火灾的数量,  $N$  为待检测烟雾火灾图片的数量。

## 4.2 实验环境和评估指标

实验数据融合了公开的火灾烟雾事件数据集 DF\_Fire 和百度飞桨的 fire-smoke 数据集, 两个数据集混合有大量的负样本数据, 融合后的数据集包含了火灾、烟雾以及无标签的负样本图像共 21 527 张, 无标签的负样本数据为 9 838 张, 火灾烟雾图像共 11 689 张。表 2 为数据集的图像示例。

## 4.3 实验结果分析

为详细评估 YOLOv8 算法中各个改进组件的性能, 以原始的 YOLOv8 基础模型为出发点, 依序融入 EfficientViT 模块、CBAM 注意力机制以及 Wise-IoU 损失函数。在此基础上, 实施了四组针对性的消融实验, 以量化分析每一改进点对算法性能的具体贡献。

由图 5 可以看出, 原始模型 YOLOv8 的 mAP 值低于引入上述模块的模型, 而加入 CBAM 模块后, 模型对检测目标的特征有所关注, 因而模型的 mAP 值略有提升, 而在加入 Wise-IoU 模块后, 在低质量的样本上离群度较大时, 会产生一个较小的梯度增益, 从而提升锚框的准确度, 在加入 EfficientViT 模块后, 模型的 mAP 值未发生明显变化。由图 6 可知, 加入 Wise-IoU 模块后, 算法与原有的 YOLOv8 相比损失值下降较为明显, 而在引入上述所有模块后, 损失值下降到了最低。

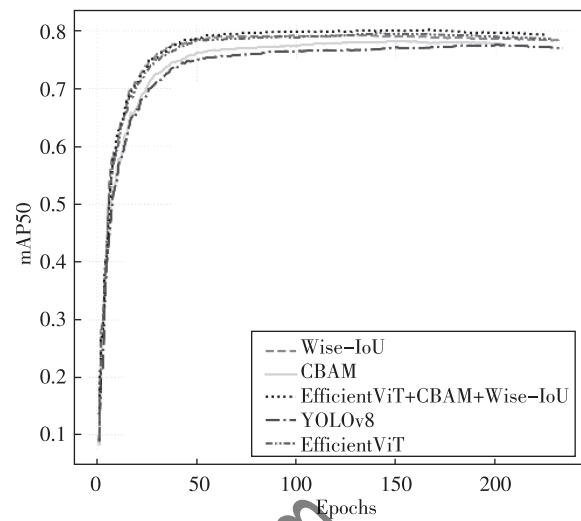


图 5 mAP 对比

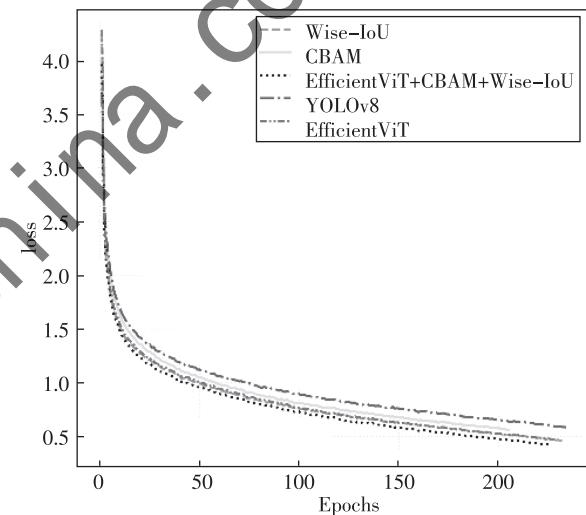


图 6 loss 值对比

由于数据集中存在大量负样本数据, 通过 PR 曲线对模型做进一步分析, 在 PR 曲线上  $\text{Precision} = \text{Recall}$  时称为平衡点, 当平衡点的取值越大时, 表示模型的性能越好, 如表 3 消融实验中的平衡点 mAP 值即为达到平衡点时的精确度, 可以发现, 在加入上述所有模块对模型进行改进后, 其模型性能更好。

最后, 对达到平衡点时的 mAP、FPS 以及权重文件三个指标下的五组消融实验进行总结, 如表 3 所示, 组一相较于组三, 加入 CBAM 后, 替换其关键卷积, 整体 mAP 提高了 0.8%; 组一相较于组二, 加入了 Wise-IoU, 替换了原有的 IoU 损失函数, 使得模型的 mAP 值提升了 2.2%; 组一和组四对比, 可以发现, FPS 值有所下降, 说明了 EfficientViT 模块虽然更加轻量化, 但是检测速度有所降低; 组一和组五对比可知, 上述全部模块加入后 mAP 提高了 2.6%, FPS 值提升 7.1%, 整个权重文件大

表 2 数据集图像及标注示例

火灾		烟雾		无标签	
图像	标签	图像	标签	图像	标签
					—
					—
					—
					—
					—
					—

表 3 消融实验结果

序号	Wise-IoU	CBAM	EfficientViT	平衡点 mAP/%	FPS	权重文件/MB	MAE/%
1				77.5	70	50.9	0.23
2	✓			79.2	70	49.6	0.18
3		✓		78.1	70	49.6	0.14
4	✓		✓	78.7	50	31.8	0.13
5	✓	✓	✓	79.5	75	48	0.12

小减少了 5.7%。实验数据充分表明，本文提出的算法策略在保持实时性的同时，可以提高对火灾和烟雾的检测速度，提升部分检测精度，从而验证了此次改进的合理性与有效性。通过对比 MAE 值，可以发现在引入所有模块后，算法预测的烟雾火灾数量与实际图像中的烟雾火灾数量差值减小，即漏检率有所下降。

为了更加直观地展示改进效果，分别在部分验证集上应用了 YOLOv8 改进前后的模型，并将测试结果呈现在表 4 中。可以看出原始模型下火灾烟雾检测出现了漏检，而在相同检测场景下改进模型能够对火灾和烟雾进行有效检测，证明了加入上述模块后模型的有效性。

## 5 结论

本文针对森林火灾的漏检和误检问题及高精度检测

需求，提出了基于改进 YOLOv8 的森林火灾目标检测算法。该算法以 YOLOv8 网络为基础，引入了 CBAM 注意力机制，更有效地提取图片中小目标的特征信息，同时引入了 EfficientViT 特征提取模块，使得模型更加轻量化。实验结果证明，优化后的模型在保障森林火灾检测实时性的基础上，其检测精确度达到了 79.5%，相较于原网络，精确度提升了 2.6%，显著降低了漏检率。然而，与当前业界主流网络相较，该模型尚存一定的优化潜力。未来研究将在维持模型检测速度的同时，对其结构进行深度优化，以进一步提升检测速度与泛化能力，并降低过拟合风险，确保模型能更加高效、准确地应对复杂场景下的检测任务。

表 4 原始模型和改进模型的效果对比

	图 1	图 2	图 3	图 4
原始模型				
改进模型				

## 参考文献

- [1] 聂明, 李川, 杜洋文. 我国森林火灾的影响及灾后综合治理 [J]. 湖北林业科技, 2023, 52 (6): 77 – 80.
- [2] 王冠博, 杨俊东, 李波, 等. 改进 YOLOv4 的火焰图像实时检测 [J]. 计算机工程与设计, 2022, 43 (5): 1358 – 1365.
- [3] 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.
- [4] 付锦燚, 张自嘉, 孙伟, 等. 改进 YOLOv8 的航拍图像小目标检测算法 [J]. 计算机工程与应用, 2024, 60 (6): 100 – 109.
- [5] 皮骏, 刘宇恒, 李久昊. 基于 YOLOv5s 的轻量化森林火灾检测算法研究 [J]. 图学学报, 2023, 44 (1): 26 – 32.
- [6] 杨武, 余华云, 赵昕宇, 等. 重参数化 YOLOv5s 的森林火灾检测算法 [J]. 无线电工程, 2024, 54 (2): 284 – 293.
- [7] DONG X D, YAN S, DUAN C Q. A lightweight vehicles detection network model based on YOLOv5 [J]. Engineering Applications of Artificial Intelligence: The International Journal of Intelligent Real-Time Automation, 2022, 113: 104914.
- [8] 徐莉, 符祥, 段宾. 基于图像生成和特征融合的复杂背景林火识别 [J]. 计算机仿真, 2022, 39 (4): 465 – 472.
- [9] 李姝, 李思远, 刘国庆. 基于 YOLOv8 无人机航拍图像的小目标检测算法研究 [J]. 小型微型计算机系统, 2024, 45 (9): 2165 – 2174.
- [10] 岳明凯, 权康男, 张骢, 等. 基于改进 YOLOv8 的红外小目标检测算法研究 [J/OL]. 红外技术, 1 – 7 [2024 – 08 – 01 ]. <http://kns.cnki.net/kcms/detail/53.1053.TN.20240826.002.html>.
- [11] 窦智, 高浩然, 刘国奇, 等. 轻量化 YOLOv8 的小样本钢板缺陷检测算法 [J]. 计算机工程与应用, 2024, 60 (9): 90 – 100.
- [12] 罗诗琦, 罗斌, 苏鑫, 等. 利用模拟数据进行遥感图像目标检测模型训练 [J/OL]. 武汉大学学报 (信息科学版), 1 – 12 [2024 – 08 – 01 ]. <https://doi.org/10.13203/j.whgis20230149>.
- [13] DE VENANCIO P V A B, LISBOA A C, BARBOSA A V. An automatic fire detection system based on deep convolutional neural networks for low-power, resource-constrained devices [J]. Neural Computing & Applications, 2022, 34 (18): 15349 – 15368.
- [14] 李嘉新, 侯进, 盛博莹, 等. 基于改进 YOLOv5 的遥感小目标检测网络 [J]. 计算机工程, 2023, 49 (9): 256 – 264.
- [15] 杨明秋, 左小清, 董燕. 基于改进 YOLOv8 的 SAR 图像船舰目标检测方法 [J]. 激光与光电子学进展, 2024, 61 (22). DOI: 10.3788/LOP240813.
- [16] 贵向泉, 刘世清, 李立, 等. 基于改进 YOLOv8 的景区行人检测算法 [J]. 计算机工程, 2024, 50 (7): 342 – 351.
- [17] 张利丰, 田莹. 改进 YOLOv8 的多尺度轻量型车辆目标检测算法 [J]. 计算机工程与应用, 2024, 60 (3): 129 – 137.
- [18] 刘子洋, 徐慧英, 朱信忠, 等. Bi-YOLO: 一种基于 YOLOv8 改进的轻量化目标检测算法 [J]. 计算机工程与科学, 2024, 46 (8): 1444 – 1454.

(下转第 82 页)

- 考 [J]. 东方法学, 2021 (3): 108 - 123.
- [36] OTTO B. The evolution of data spaces [M]. Cham: Springer International Publishing, 2022; 3 - 15.
- (收稿日期: 2024-08-14)

作者简介:

李啸宇 (1999 - ), 通信作者, 男, 硕士, 助理工程师, 主要

研究方向: 数据分析、数据要素。E-mail: zylxy2016@163.com。

夏磊 (1990 - ), 男, 硕士, 工程师, 主要研究方向: 数字政府、数字城市、数字基础设施。

吕东阳 (1994 - ), 男, 硕士, 信息系统项目管理师, 主要研究方向: 数字政府、数据治理、数据要素流通、图像分析、模式识别。

(上接第 56 页)

- [19] RABBI J, RAY N, SCHUBERT M, et al. Small-object detection in remote sensing images with end-to-end edge-enhanced GAN and object detector network [J]. Remote Sensing, 2020, 12 (9): 1432.
- [20] 李忠科, 刘小芳. 基于轻量级 YOLOv8n 网络的 PCB 缺陷检测算法 [J]. 电子测量技术, 2024, 47 (4): 120 - 126.
- [21] DENG L, ZHOU J, LIU Q Y. Improving YOLOv5s algorithm for detecting flame and smoke [J]. IEEE Access, 2024, 12: 126568 - 126576.
- [22] WANG G, CHEN Y F, AN P. UAV-YOLOv8: a small-object-detection model based on improved YOLOv8 for UAV aerial pho-

tography scenarios [J]. Sensors, 2023, 23 (16): 7190.

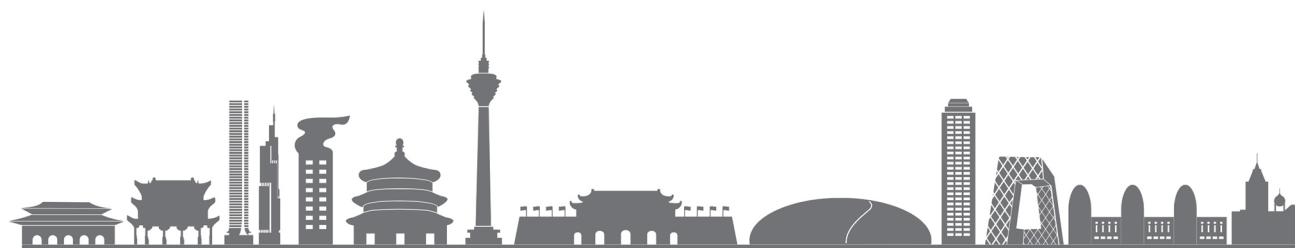
(收稿日期: 2024-08-14)

作者简介:

杜世泽 (1994 - ), 男, 硕士, 工程师, 主要研究方向: 机器视觉与自动化技术。

◆ 银皓 (1990 - ), 女, 硕士, 高级工程师, 主要研究方向: 装备保障信息化。

句海洋 (1990 - ), 通信作者, 男, 博士, 高级工程师, 主要研究方向: 智能装备系统、信号处理、目标探测。E-mail: juhaiyang@ncse.com.cn。



## 版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部