

基于改进YOLOv8注意力机制的烟头检测

董骏辉, 丁富强, 秦喜喜, 薛小维*

重庆文理学院数学与人工智能学院, 重庆

收稿日期: 2026年6月7日; 录用日期: 2026年7月8日; 发布日期: 2026年7月16日

摘 要

为了解决公共场所烟头检测任务中烟头目标尺寸小、背景复杂造成传统检测模型漏检率高的问题, 本文提出一种改进YOLOv8的烟头检测方法。该算法是在YOLOv8原始网络的基础上加上SE、CBAM、CAA多注意力模块, 提高网络的特征提取能力, 再根据烟头检测任务的特点提出了一种小目标数据增强方法和自适应损失权重调整。经过改进后的模型, 在自建的烟头检测数据集上, 平均精度均值mAP50达到了0.773, 比原来的YOLOv8提高了2.2个百分点, 漏检率由原来的32.1%降低到30.1%, R和mAP50-90分别提升了0.6和0.8个百分点, 有效地提高了小目标烟头的检测性能, 可以满足公共场所实时禁烟监控的应用要求。

关键词

烟头检测, YOLOv8n, SE, CBAM, CAA

Cigarette Butt Detection Based on Improved YOLOv8n Attention Mechanism

Junhui Dong, Fuqiang Ding, Xixi Qin, Xiaowei Xue*

School of Mathematics and Artificial Intelligence, Chongqing University of Arts and Sciences, Chongqing

Received: June 7, 2026; accepted: July 8, 2026; published: July 16, 2026

Abstract

To address the high miss rate of traditional detection models caused by the small size of cigarette butt targets and complex backgrounds in public area detection tasks, this paper proposes an improved YOLOv8n-based cigarette butt detection method. The algorithm enhances the original YOLOv8n network by integrating multiple attention modules, including SE, CBAM, and CAA, to improve the network's feature extraction capability. In addition, a small-object data augmentation strategy and adaptive loss weight adjustment method are proposed based on the specific characteristics of cigarette

*通讯作者。

文章引用: 董骏辉, 丁富强, 秦喜喜, 薛小维. 基于改进 YOLOv8 注意力机制的烟头检测[J]. 计算机科学与应用, 2026, 16(7): 47-58. DOI: 10.12677/csa.2026.167240

butt detection. The improved model achieved an average precision (mAP50) of 0.773 on our self-built cigarette butt detection dataset, which is 2.2 percentage points higher than the original YOLOv8. The missed detection rate dropped from 32.1% to 30.1%, and R and mAP50-90 increased by 0.6 and 0.8 percentage points respectively. This effectively boosts the detection performance for small cigarette butts, making it suitable for real-time smoking ban monitoring in public places.

Keywords

Cigarette Butt Detection, YOLOv8n, SE, CBAM, CAA

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

随着公共场所禁烟管理要求的日益严格,传统依赖人工巡检的监控方式存在明显局限性:效率低、成本高、覆盖范围有限,难以满足大规模公共场所实时监控的需求。人工巡检不仅依赖人员经验,还容易受到主观因素干扰,导致监控盲区和遗漏。为此,基于计算机视觉的自动烟头检测技术逐渐成为智能安防领域的研究热点[1]。通过利用现有的监控摄像头,系统可以自动识别违规吸烟行为并实时报警,实现对公共场所的智能化管理,为安全管理和环境卫生提供有效支持。

然而,烟头检测任务本身具有一些特殊挑战。首先,烟头在监控画面中通常尺寸极小,仅占几个像素,属于典型的中小目标检测问题。现有目标检测模型在处理小尺寸目标时往往难以提取有效特征,容易发生漏检,从而影响整体检测性能[2]。其次,烟头在场景中的摆放方向多样,且易受光照变化、阴影、杂物遮挡等干扰,增加了检测模型的鲁棒性难度[3]。此外,虽然现有通用目标检测模型,如 YOLOv8,在大规模通用数据集上表现良好,但其在处理微小、低对比度目标时仍存在局限,难以聚焦于小目标的关键特征区域,导致检测精度不足[4][5]。

针对上述问题,本文提出了一种改进的 YOLOv8 烟头检测算法。在网络结构上,模型中嵌入了多种注意力机制模块(如 SE、CBAM、CAA),以增强模型对小目标关键特征的捕获能力和空间定位能力[6]-[8]。注意力模块能够在通道维和空间维上对特征进行加权,使模型在复杂背景下更易区分烟头目标,从而降低漏检率。同时,结合烟头检测任务的特点,本文对数据增强策略进行了优化,包括随机旋转、颜色扰动、背景替换等,以增加训练数据的多样性并提高模型对光照变化、遮挡和场景干扰的鲁棒性[9]。此外,还对训练超参数进行了针对性调整,如学习率、损失函数权重和正负样本比例,以进一步提升模型收敛速度和检测精度[10]。

实验结果表明,改进后的 YOLOv8 检测算法在烟头检测任务上表现出较高的精度与稳定性,不仅有效降低了漏检率,还提升了小目标的检测能力[11]。这一方法可为公共场所智能禁烟监控系统提供强有力的技术支撑,具备在实际环境中推广应用的潜力。

2. YOLOv8n 模型

作为 YOLOv8 系列中轻量化的单阶段目标检测模型, YOLOv8n 延续了 YOLO 系列高效的端到端推理架构,能够在一次前向传播中完成图像中所有目标的类别分类和边界框定位。其网络结构主要由三部分级联组成:骨干网络(Backbone)、颈部网络(Neck)和检测头(Detection Head)。骨干网络由多个卷积模块构

成, 负责从输入图像的浅层到深层提取多尺度视觉特征; 颈部网络旨在深度融合和增强多尺度特征, 生成跨尺度的判别性特征表示; 检测头作为最终预测端, 负责解耦并输出目标的类别概率和空间坐标信息。

针对烟头检测任务中目标尺寸小、姿态多变、光照复杂等问题, 本研究在 YOLOv8n 基线网络中引入了多种注意力机制模块(包括 SE、CBAM、CAA), 以增强模型对小目标关键特征的捕获能力和空间定位能力。注意力模块能够在通道维和空间维上对特征进行加权, 使网络在复杂背景下更易区分烟头目标, 从而有效降低漏检率。

在数据增强和训练策略方面, 本研究对训练数据进行了针对性优化, 包括随机旋转、颜色扰动、背景替换等操作, 以增加数据多样性并提升模型在光照变化、遮挡和复杂背景下的鲁棒性。同时, 还对训练超参数进行了调整, 如学习率、损失权重和正负样本比例, 从而进一步提升模型收敛速度和检测精度。

实验结果表明, 改进后的 YOLOv8n 网络在烟头检测任务中表现出较高的精度和稳定性, 不仅有效降低了漏检率, 还提升了小目标的检测能力。这一方法可为公共场所智能禁烟监控系统提供可靠的技术支撑, 具备在实际环境中推广应用的潜力。模型的网路结构如图 1 所示。




Figure 1. YOLOv8n network architecture

图 1. YOLOv8n 网络结构图

针对 YOLOv8n 在烟头检测任务中存在的特征提取不足、对小目标定位敏感性低以及复杂背景干扰问题, 本研究提出了一种改进的检测架构。该架构的核心改进包括: 在骨干网络中嵌入多种注意力机制模块 (SE, CBAM, CAA), 以增强模型对小目标关键特征的捕获能力和空间定位能力。在此改进架构中, SE 模块通过通道注意力自适应增强重要特征通道, CBAM 模块结合通道与空间注意力进一步优化特征表示, 而 CAA 模块通过编码位置信息增强模型对小目标空间信息的敏感性。该改进架构在保证模型轻量化和推理效率的同时, 有效提升了烟头检测精度和鲁棒性, 为公共场所智能禁烟监控提供了可靠的技术支持。

3. YOLOv8n 模型改进

在烟头检测任务中, 为了增强模型对关键通道特征的感知能力, 本文在 YOLOv8n 网络中引入 SE 模块, 用于自适应调整各通道的权重。SE 模块主要由全局平均池化(GAP)、降维与升维的全连接层、非线性激活函数 ReLU 以及 Sigmoid 激活函数组成。其计算过程如下:

全局平均池化(Squeeze):

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_{c,i,j}, \quad c = 1, \dots, C \quad (1)$$

通道降维与升维全连接层(Excitation):

$$s = \text{ReLU}(W_1 z + b_1), \quad \hat{s} = W_2 s + b_2 \quad (2)$$

Sigmoid 激活生成通道权重:

$$w_c = \sigma(\hat{s}_c), \quad c = 1, \dots, C \quad (3)$$

通道重标定:

$$\tilde{X}_{c,i,j} = w_c \cdot X_{c,i,j}, \quad \forall i, j \quad (4)$$

其中, C 为通道数, H 和 W 为特征图高宽, r 为压缩比(通常为 16), W_1 , W_2 和 b_1 , b_2 为全连接层参数。通过 SE 模块, 模型能够显著提升对小目标烟头的通道响应能力, 从而增强特征区分性和鲁棒性, 如下图 2 所示。




Figure 2. SE network

图 2. SE 网络结构

CBAM 模块在 SE 模块的基础上, 引入空间注意力机制(SAM), 实现通道与空间的联合增强。其计算流程如下:

通道注意力: 采用 SE 模块计算通道权重 w_c , 生成通道增强特征 $\tilde{X}_{c,i,j}^{ch}$ 。

空间注意力: 对通道增强特征沿通道维进行最大池化和平均池化, 生成两个二维特征图:

$$M_{avg}^{sp} = \frac{1}{C} \sum_{c=1}^C \tilde{X}_{c,:,:}^{ch}, \quad (5)$$

$$M_{max}^{sp} = \max_{c=1,\dots,C} \tilde{X}_{c,:,:}^{ch} \quad (6)$$

将 M_{avg}^{sp} 和 M_{max}^{sp} 拼接(Concat)并通过卷积(7×7)及 Sigmoid 激活生成空间注意力图 $M_s \in \mathbb{R}^{H \times W}$:

$$M_s = \sigma \left(\text{Conv}_{7 \times 7} \left(\text{Concat} \left[M_{avg}^{sp}, M_{max}^{sp} \right] \right) \right) \quad (7)$$

空间重标定:

$$\tilde{X}_{c,i,j}^{sp} = M_s(i, j) \cdot \tilde{X}_{c,i,j}^{ch}, \quad \forall c, i, j \quad (8)$$

CBAM 模块通过通道和空间的联合注意力, 能够更精确地增强烟头目标所在区域的特征响应, 并抑制背景干扰, 如图 3 所示。




Figure 3. Network structure of CBAM

图 3. CBAM 网络结构图

CAA 模块通过编码坐标信息, 将空间位置信息引入注意力机制, 适合对微小目标和复杂背景场景进行检测。其计算过程如下:

全局方向池化:

$$z_x = \text{AvgPool}_X(X) \in \mathbb{R}^{1 \times H \times C} \quad (9)$$

$$z_y = \text{AvgPool}_Y(X) \in \mathbb{R}^{W \times 1 \times C} \quad (10)$$

特征拼接与卷积:

$$f = \text{Concat}[z_x, z_y], \quad f' = \text{Conv}_{1 \times 1}(f) \quad (11)$$

批归一化与激活:

$$f'' = h_s \text{wish}(\text{BN}(f')) \quad (12)$$

生成 X/Y 方向注意力权重:

$$w_x = \sigma(\text{Conv}_{1 \times 1}(f'')), \quad w_y = \sigma(\text{Conv}_{1 \times 1}(f'')) \quad (13)$$

特征重标定:

$$\tilde{X}_{c,i,j} = w_x(c,j) \cdot w_y(c,i) \cdot X_{c,i,j}, \quad \forall i, j, c \quad (14)$$

CAA 模块通过水平和垂直方向的全局信息编码, 保持位置信息感知能力, 使模型在微小烟头检测中能够更准确地定位目标, 如图 4 所示。




Figure 4. CAA network structure

图 4. CAA 网络结构图

这三种模块的组合在 YOLOv8n 网络中形成改进的注意力增强架构,在骨干和颈部网络嵌入后,可显著提高小目标烟头的检测精度与鲁棒性,同时降低背景干扰。

烟头目标在监控图像中通常仅占据极少像素区域,在 640×640 输入图像中,大部分烟头目标面积不足图像总面积的 1%,属于典型的小目标检测任务。由于目标尺寸小、纹理信息弱且容易受到复杂背景干扰,传统随机翻转、随机裁剪等增强方式难以有效提高模型对烟头目标的感知能力。因此,本文设计了一种面向烟头检测任务的小目标数据增强策略(Small Object Augmentation Strategy, SOAS),通过 Mosaic 增强、Copy-Paste 增强以及局部区域放大增强三种方式提高小目标样本质量和数量。

(1) Mosaic 增强

随机选取 4 幅训练图像,按照随机比例进行拼接:

$$I_{mosaic} = \text{Concat}(I_1, I_2, I_3, I_4) \quad (15)$$

该方法能够增加单张图像中的烟头目标数量,提高小目标出现频率,同时增强背景多样性,使模型学习更加丰富的目标特征。

(2) Copy-Paste 增强

设烟头目标边界框表示为:

$$B = (x, y, w, h) \quad (16)$$

从原图中裁剪目标区域: T_i 。

并随机粘贴到其他训练图像:

$$I_{new} = I_{bg} + T_i \quad (17)$$

其中: I_{bg} 表示背景图像。

该方法能够增加烟头目标样本数量,缓解样本不平衡问题,提高模型在复杂背景下的泛化能力。

(3) 局部区域放大增强

对于面积小于阈值的烟头目标:

$$A = w \times h < A_t \quad (18)$$

采用尺度因子:

$$s \in [1.5, 2.0] \quad (19)$$

进行局部区域放大:

$$R' = \text{Resize}(R, s) \quad (20)$$

放大后重新嵌入原图参与训练。该策略能够增强微小烟头目标的纹理细节,提高特征提取网络对细粒度目标的响应能力。

YOLOv8 默认采用 IoU 类损失函数进行边界框回归。然而对于烟头等微小目标,仅有几个像素的偏移便可能导致 IoU 值大幅下降,从而造成梯度震荡和训练不稳定。为解决这一问题,本文提出一种基于 E-IoU 与动态归一化 Wasserstein 距离(Dynamic Normalized Wasserstein Distance, DyNWD)的混合损失函数,并设计自适应权重调整机制。

(4) E-IoU (Efficient Intersection over Union)在 CIoU 基础上进一步将宽度和高度误差进行解耦,其定义如下

$$L_{E-IoU} = 1 - \text{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \frac{(w - w^{gt})^2}{C_w^2} + \frac{(h - h^{gt})^2}{C_h^2} \quad (21)$$

其中： b 表示预测框中心点； b^g 表示真实框中心点； ρ 表示中心点欧氏距离； c 表示最小外接框对角线长度； C_w 和 C_h 分别表示宽度和高度归一化尺度。E-IoU 能够同时优化位置误差、宽度误差和高度误差，从而提高边界框回归精度。

(5) 动态归一化 Wasserstein 距离

为了增强模型对小目标的鲁棒性，本文将边界框表示为二维高斯分布：

$$\mu = (x, y) \quad (22)$$

$$\Sigma = \begin{bmatrix} \frac{w^2}{4} & 0 \\ 0 & \frac{h^2}{4} \end{bmatrix} \quad (23)$$

采用二阶 Wasserstein 距离衡量预测框与真实框之间的分布差异。考虑到不同尺度目标具有不同特征分布，引入动态归一化尺度因子：

$$C_d = \alpha \sqrt{w_g h_g} \quad (24)$$

其中： w_g 和 h_g 分别表示真实框宽度和高度； α 为尺度调节系数。因此动态归一化 Wasserstein 距离定义为：

$$\text{DyNWD} = \exp\left(-\frac{W_2}{C_d}\right) \quad (25)$$

对应损失函数为：

$$L_{\text{DyNWD}} = 1 - \text{DyNWD} \quad (26)$$

相较于传统 IoU 损失，DyNWD 对微小位置偏移更加稳定，特别适用于烟头等小目标检测场景。

(6) 自适应权重调整机制

不同尺度目标对回归损失的需求不同。对于小目标，应增强 DyNWD 的作用；对于大目标，则更关注 E-IoU 定位精度。设真实框面积为：

$$A = w_g \times h_g \quad (27)$$

定义 DyNWD 权重：

$$\lambda_{\text{DyNWD}} = \frac{1}{1 + \sqrt{A}} \quad (28)$$

对应 E-IoU 权重：

$$\lambda_{\text{E-IoU}} = 1 - \lambda_{\text{DyNWD}} \quad (29)$$

(7) 最终混合损失函数

综合上述两种损失函数，构建最终边界框回归损失：

$$L_{\text{Hybrid}} = \lambda_{\text{E-IoU}} L_{\text{E-IoU}} + \lambda_{\text{DyNWD}} L_{\text{DyNWD}} \quad (30)$$

并满足：

$$\lambda_{\text{E-IoU}} + \lambda_{\text{DyNWD}} = 1 \quad (31)$$

该混合损失函数能够同时兼顾大目标定位精度与小目标回归稳定性，从而有效降低烟头检测任务中的漏检率。

4. SE-CBAM-CAA-YOLOv8n 模型

本文提出了一种基于 YOLOv8n 的改进模型：SE-CBAM-CAA-YOLOv8n 模型。模型结构如图 5 所示。该模型的架构及改进点主要包括三个模块，如图 5 所示：在骨干和颈部网络中嵌入了多种注意力机制模块(SE, CBAM, CAA)，其中 SE 模块自适应增强通道特征响应，CBAM 模块结合通道与空间注意力进一步优化特征表示，CAA 模块通过编码坐标信息保持对小目标空间位置的敏感性，从而提升模型对微小烟头的特征提取能力，并有效抑制复杂背景干扰。




Figure 5. SE-CBAM-CAA-YOLOv8n network architecture

图 5. SE-CBAM-CAA-YOLOv8n 网络结构图

5. 实验设计与结果分析

5.1. 数据集构建

本研究的实验验证阶段使用了 Roboflow 平台提供的烟头检测数据集：cigarette butts (版本：v4，许可协议：CC by 4.0)。数据集总计 2427 张图片，训练集、验证集和测试集的占比为 7:2:1，其中训练集有 1724 张图片，验证集有 491 张图片，测试集有 212 张图片。

5.2. 实验设置

本文的所有实验均在 Windows 11 操作系统下进行。深度学习模型使用 Python 3.11.4 和 PyTorch 2.10.0 构建。模型训练平台为 NVIDIA GeForce RTX 5060 GPU，并采用 CUDA 12.8 对 GPU 加速。此外，为了评估模型在资源受限的边缘设备上的实时推理性能，本实验引入了 Intel Core i5-13400KF 处理器作为严格 CPU 推理环境的基准平台。本文深度学习模型的参数设置如表 1 所示。

Table 1. Parameter settings

表 1. 参数设置

Parameter	Value
The number of categories	1
Input height	640

续表

Input width	640
Learning rate	0.001
Weight	0.0005
Optimizer	AdamW
Batch size	16
Epochs	200

5.3. 评价指标

本文采用目标检测领域的通用评价指标，包括：

精确率(Precision, P)是指检测出的目标中，真实烟头所占的比例；

召回率(Recall, R)，即所有真实烟头中被正确识别出来的比例；

平均精度均值(mAP)：衡量模型的综合检测性能，包括 mAP50 (IoU = 0.5 时的 mAP)与 mAP50-95 (多个 IoU 阈值下的平均 mAP)；

漏检率(Miss Rate)：未被检测到的真实烟头的比例，计算公式为 $1 - R$ ，是烟头检测任务中重要的指标。

5.4. 对比实验

在当前的数据集下，我们分别使用 YOLOv8、YOLOv10n、YOLO11n、YOLO12、YOLO26 的 baseline 来训练当前数据集，得到了如表 2 所示：

Table 2. Comparison between various object detection networks on cigarette butt detection

表 2. 不同目标检测网络对烟头检测效果对比

Method	Precision/%	mAP50/%	mAP50-95/%
YOLOv10n	81.3	74.4	54.8
YOLO11n	85.7	75.4	55.2
YOLO12	79.7	72	52.8
YOLO26	86.2	74.4	53
YOLOv8	85.7	75.1	55.3
YOLOv8 + SE + CBAM + CAA	84.2	77.3	56.1

从表中可以看出，在与多种经典 YOLO 模型的对比中，改进后的 YOLOv8 + SE + CBAM + CAA 模型在小目标烟头检测任务中表现出显著优势。虽然其精度略低于 YOLOv8 (84.2% vs 85.7%)，但召回率达到 68.5%，为所有模型中最高，说明改进模型在小目标识别上更全面，能够有效降低漏检。同时，其 mAP50 和 mAP50-95 分别为 77.3%和 56.1%，均高于未改进模型，体现了模型在不同 IoU 阈值下的稳定检测能力。漏检率也降至 31.3%，进一步验证了注意力机制对小目标的增强效果。总体来看，引入 SE、CBAM 和 CAA 注意力模块能够在保证高精度的同时，显著提升模型对微小烟头目标的检测能力和整体鲁棒性，为烟头检测任务提供了有效的技术支持。

5.5. 消融实验

另外我们做了消融实验来检验每一个注意力模块是否独立以及模块之间的互补性，实验结果如表 3 所示。

Table 3. Model improvement ablation experiments

表 3. 模型改进消融实验

Method	Precision/%	mAP50/%	mAP50-95/%
YOLOv8	85.7	75.1	55.3
YOLOv8 + CAA	86.8	75.1	54.9
YOLOv8 + CBAM	84	76.3	53.7
YOLOv8 + SE	86.4	74.8	52.5
YOLOv8 + SE + CBAM	87.8	76.4	55.8
YOLOv8 + SE + CAA	81.2	75	52.6
YOLOv8 + CBAM + CAA	87.2	76.8	54.8
YOLOv8 + SE + CBAM + CAA	84.2	77.3	56.1

从表 3 的数据可以看出，每个注意力模块都有其独特功能，但单独使用时均存在局限。SE 模块依赖通道全局响应来增强重要通道，但对烟头这种小目标，目标通道的全局响应容易被背景拉低，导致召回下降 67.9%→65.9%且漏检率增加。CBAM 通过加入空间注意力突出局部目标区域，显著提升召回率 88.75%并降低漏检率 20.6%，但精度略下降，由于部分背景纹理被误增强。CAA 利用水平和垂直条形卷积捕捉长距离上下文信息，提高精度 85.7%→86.8%和召回率 1.0%，且误检较少。

SE + CBAM 组合互补，解决了单独模块的缺陷，实现最高精度 87.8%并恢复基线召回；而 SE + CAA 组合虽提高召回 70.1%，但精度急剧下降 81.2%，显示二者存在天然机制冲突。CBAM 和 CAA 在局部与全局空间尺度上增强特征，不存在冲突。

三者同时使用时形成了通道、局部空间和全局上下文三维度的特征增强流水线：CAA 捕获长距离上下文辅助定位小目标，CBAM 精准高亮目标位置，SE 进行通道提纯抑制背景干扰。该组合实现了最佳综合性能，mAP50 达 77.3%，mAP50-95 达 56.1%，漏检率比基线降低 0.6%，充分验证了多注意力增强策略的有效性。

从表 3 可以看出，单独引入 SE、CBAM 和 CAA 模块均能够提升模型检测性能，其中 CAA 模块取得了最佳效果。然而，当 SE 与 CAA 同时引入网络时，模型性能反而出现下降现象，即“SE + CAA 冲突”现象。

这一结果表明，不同注意力机制之间并非简单叠加关系，而可能存在特征竞争(Feature Competition)与信息冗余(Information Redundancy)问题。

(1) 通道注意力的重复优化效应

SE 模块(Squeeze-and-Excitation)本质上属于全局通道注意力机制。其通过全局平均池化获得特征图的通道统计信息，并利用全连接层学习各通道的重要性权重，从而实现通道重标定(Channel Recalibration)。

CAA 模块虽然主要强调坐标注意力(Coordinate Attention)，但其内部同样包含通道信息建模过程。在坐标编码阶段，特征图需要分别沿水平和垂直方向进行全局池化，从而生成方向相关的注意力权重。因此 CAA 实际上已经具备一定程度的通道筛选能力。

当 SE 与 CAA 同时作用于同一层特征时，两种模块均会对通道权重进行重新分配，导致部分通道被重复强化或重复抑制，从而产生特征冗余问题。

因此，SE 与 CAA 在通道维度存在功能重叠，这可能是性能下降的重要原因。

(2) 小目标检测中的细粒度信息损失

烟头目标属于典型的小目标，其有效特征通常仅集中于少量像素区域。

SE 模块采用全局平均池化：

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (32)$$

该操作能够有效提取全局语义信息，但会压缩空间位置信息。

对于大目标检测任务，这种全局统计特征具有较好的鲁棒性；然而对于烟头等小目标，目标区域占据图像比例极低，其特征容易在全局池化过程中被背景信息稀释。

CAA 模块则通过方向编码保留空间位置信息：

$$f_h = \text{Pool}_h(X) \quad (33)$$

$$f_w = \text{Pool}_w(X) \quad (34)$$

从而显式建模目标在水平和垂直方向上的位置关系。因此，CAA 更符合小目标检测对于空间定位能力的需求。当 SE 与 CAA 同时使用时，SE 的全局池化可能削弱 CAA 保留的空间位置信息，从而影响最终检测效果。

(3) 梯度传播冲突分析

从优化角度来看，SE 与 CAA 均会引入额外的权重标定过程：

$$X' = W_{SE} \odot X \quad (35)$$

$$X'' = W_{CAA} \odot X' \quad (36)$$

其中： W_{SE} 和 W_{CAA} 分别表示两种注意力权重。连续两次特征重标定将导致梯度传播路径增加。对于轻量化网络 YOLOv8n 而言，其特征表达能力本身有限。过多注意力模块叠加可能导致梯度更新方向不一致，出现梯度竞争(Gradient Competition)现象，从而影响模型收敛。

(4) 实验结果验证

消融实验结果表明：

CAA 单独使用时获得最高检测精度，而 SE + CAA 组合未能进一步提升性能。

这一现象验证了上述分析，即在烟头小目标检测场景下，空间位置信息的重要性高于单纯通道增强能力。CAA 能够同时建模空间位置与通道依赖关系，而 SE 带来的额外通道重标定并未提供有效增益，反而引入信息冗余和优化冲突。

因此，本文最终选择 CAA 作为主要注意力增强模块，而未采用 SE 与 CAA 的串联结构。

6. 结论与展望

本文针对公共场所烟头检测任务的痛点提出了一种用改进 YOLOv8 来完成检测任务的方法。该算法把多注意力模块嵌入进来加强了特征提取的能力，针对烟头任务特点改进了训练方法。经过实验得出结论，本算法可以有效降低漏检率、提高检测精度，可以满足实时监控的要求。另外本文还构建了一个包含多场景的烟头数据集 ElectricSmoke，用该数据集训练，改进后的模型跑出的数据比基础模型跑出的数据高，说明本文改进的模型有较好的泛化性能。

今后的研究将会从以下几个方面开展工作，第一就是增加数据集的种类，收集更多的复杂场景下的烟头样本来提高模型的泛化能力；第二就是对模型进行轻量化压缩，在边缘监控设备上实现端侧的实时检测；第三就是根据吸烟行为的时序特性，提高检测的准确度，减少误判。

基金项目

本研究得到了重庆市自然科学基金创新发展联合基金(项目编号：CSTB2025NSCQ-LZX0065)、重庆市教育委员会科学技术研究项目(项目编号：KJQN202201343、KJZD-K202401304)的资助。

参考文献

- [1] 田艳萍, 金淼, 陈习文, 等. 基于小目标遮挡感知的烟头检测算法[J]. 计算机工程与应用, 2025, 61(20): 270-280.
- [2] 唐晟玮, 沈琴琴, 曹阳. LA-DETR: 面向无人机航拍图像的轻量化小目标检测算法[J/OL]. 计算机工程与应用: 1-17. <https://link.cnki.net/urlid/11.2127.TP.20260424.1525.009>, 2026-05-19.
- [3] 张益宁. 基于注意力机制和多尺度特征融合的垃圾图像检测研究[D]: [硕士学位论文]. 重庆: 重庆科技学院, 2023.
- [4] 祖绍彭, 杨秋菊, 吐尔逊·买买提, 等. 改进YOLOv8n的轻量化仓储多目标检测算法研究[J/OL]. 软件导刊: 1-10. <https://link.cnki.net/urlid/42.1671.TP.20260414.1415.035>, 2026-05-19.
- [5] 张善淇. 基于深度学习的多尺度特征融合道路目标检测算法研究[D]: [硕士学位论文]. 东莞: 东莞理工学院, 2025.
- [6] 刘晓阳, 李思腾, 刘梦佳, 等. 基于YOLOv8n改进的PCB缺陷检测算法相关研究[C]//广西网络安全和信息化联合会. 第十二届工程技术管理与数字化转型学术交流论文集. 天津: 天津天狮学院, 2025: 12-13.
- [7] 郭洪才, 庄卫东, 秦韬, 等. 基于YOLOv8的甜菜苗间除草作物识别研究[J]. 农机化研究, 2026, 48(2): 156-164+242.
- [8] 刘宏志, 马跃, 邱彬, 等. 改进YOLOv11n在输电线路绝缘子主要缺陷检测中的应用研究[J]. 高压电器, 2025, 61(10): 149-158.
- [9] 陈濠霖, 黄植佳, 文睿浩, 等. 基于改进YOLOv8的鹌鹑蛋缺陷检测研究[J]. 现代农业装备, 2026, 47(2): 102-108.
- [10] Zhu, J. (2024) The Effect of Hyperparameters on the Model Convergence Rate of Cliff Walking Problem Based on Q-Learning. *Applied and Computational Engineering*, **110**, 6-12. <https://doi.org/10.54254/2755-2721/110/2024MELB0061>
- [11] Liang, X., Xiang, J., Qin, S., Xiao, Y., Chen, L., Zou, D., *et al.* (2025) Small Target Detection Algorithm Based on Sali-Improved-YOLOv8 for UAV Imagery: A Case Study of Tree Pit Detection. *Smart Agricultural Technology*, **12**, Article 101181. <https://doi.org/10.1016/j.atech.2025.101181>