

基于改进 YOLOv8 的低气压燃气火焰状态识别方法

赛庆毅¹, 赵进¹, 严永辉¹, 毕德贵²

(1. 上海理工大学 能源与动力工程学院, 上海 200093; 2. 上海理工大学 环境与建筑学院, 上海 200093)

摘要: 高原低气压环境下, 燃气火焰检测面临识别精度不足与实时性下降的双重挑战。本研究提出改进的 YOLOv8n 轻量级算法, 通过多维度优化, 实现性能提升。首先, 在 backbone 中构建 GhostConv 模块, 减少模型计算参数; 其次, 重构 C2f 模块为 C2f_RepGhost 结构, 在保持特征表达能力的同时简化推理过程; 最后, 结合卷积块注意力模块 (convolutional block attention module, CBAM) 注意力机制, 强化火焰细粒度特征提取, 并采用 WIoU 损失函数提高定位精度。基于机理实验台数据的实验表明: 改进模型的参数量降低 12.64%, 计算量减少 12.2%, 准确率提升 21.2%, 检测帧率依然保持较高的水平。该方法为低压环境下的火焰状态识别提供了有效的轻量化解决方案。

关键词: 低气压; 火焰检测; 深度学习; YOLOv8; 注意力机制

中图分类号: TP 391.41

文献标志码: A

Improved YOLOv8 for gas flame state recognition under low-pressure conditions

SAI Qingyi¹, ZHAO Jin¹, YAN Yonghui¹, BI Degui²

(1. School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

2. School of Environment and Architecture, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Gas flame detection in high-altitude low-pressure environments faces dual challenges of insufficient recognition accuracy and real-time performance degradation. This study proposes an improved lightweight YOLOv8n algorithm with multi-dimensional optimizations for enhanced performance. First, a GhostConv module was constructed in the backbone to reduce computational parameters. Second, the C2f module was restructured into a C2f_RepGhost configuration that

收稿日期: 2024-03-01

基金项目: 国家重点研发计划资助项目 (2021YFF0600605)

通信作者: 赛庆毅 (1975—), 男, 教授。研究方向: 燃气锅炉燃烧稳定性技术研究。E-mail: saiqingyi@163.com

引文格式: 赛庆毅, 赵进, 严永辉, 等. 基于改进 YOLOv8 的低气压燃气火焰状态识别方法[J]. 上海理工大学学报, 2025, 47(3): 269-277.

Citation: SAI Qingyi, ZHAO Jin, YAN Yonghui, et al. Improved YOLOv8 for gas flame state recognition under low-pressure conditions[J]. Journal of University of Shanghai for Science and Technology, 2025, 47(3): 269-277.

maintained feature representation capability while simplifying inference processes. Finally, the convolutional block attention module (CBAM) attention mechanism was incorporated to strengthen fine-grained flame feature extraction, and the WIoU loss function was adopted to improve localization accuracy. Experimental results based on mechanism testbed data demonstrate that the improved model's parameter count decrease by 12.64%, computational load decrease by 12.2%, and precision increase by 21.2% while maintaining frame rate detection. This method provides an effective lightweight solution for flame state recognition in low-pressure environments.

Keywords: *low-pressure; flame detection; deep learning; YOLOv8; attention mechanism*

以甲烷为主要燃料的燃气炉对燃烧稳定性的要求极高，不稳定燃烧或熄火现象极易触发爆炸事故。高原地区低压、低氧环境会降低甲烷的燃烧效率^[1]，导致火焰形态^[2]和稳定性^[3]等发生变化，进而影响燃烧过程的安全性。因此，精准识别火焰状态对燃烧过程的实时监控与安全预警至关重要，关系到生命与财产安全。

早期的燃气火焰状态检测技术依靠红外摄像机、温度传感器、压力传感器等硬件设备^[4]，易被干扰并且准确率不高。近年来，深度学习技术在图像检测领域取得了很好的应用效果，逐渐成为了主流检测手段。白卫东等^[5]采用支持向量机 (support vector machine, SVM) 对锅炉燃烧火焰图像进行分类识别，实现了准确的燃烧状态监测。Ronquillo-Lomeli 等^[6]运用概率神经网络 (probabilistic neural network, PNN) 算法对锅炉火焰进行分类，准确率达到 90% 以上。Gangopadhyay 等^[7]使用 3D 神经网络和长短期记忆网络，实现了对实验室燃烧火焰的稳定与不稳定状态的识别。Zhao 等^[8]结合 YOLOv8 与 VQ-VAE，提高了实际检测的准确率。Yar 等^[9]改进了 YOLOv5s 模型，减少了模型尺寸和复杂度，并提高了准确率。王冠博等^[10]提出了改进 YOLOv4-tiny 轻量化模型，通过增加感受野并对模型进行剪枝，提升准确率的同时大幅减少了模型参数量以及权重文件。陈露萌等^[11]改进了 YOLOv5s 模型，在特征提取部分添加协同注意力机制，并改进 α -CIoU，提高了模型的收敛速度。

尽管这些研究在平原环境下取得了良好的效果，但在高原环境下，火焰的边缘形状、面积和颜色变化迅速：随着气压降低，火焰边缘形状膨胀变得更加明显；面积也随之扩大；火焰颜色由明黄色变成淡蓝色，加之氧浓度下降会增加烟气

含量，给火焰图像的识别及特征分析增加了难度。网络的加深会不可避免地导致火焰图像信息减少或缺失，准确率提高常以降低检测速度为代价。针对这些问题，本文提出了一种基于改进 YOLOv8 的火焰状态检测算法。该算法通过轻量化设计，优化模型主干，显著提高了检测速度；此外，通过引入注意力机制，增强了模型对火焰细粒度特征的捕捉能力，从而提升检测精度。通过性能分析与实际测试，证明了本文方法的有效性和可行性。

1 YOLOv8 算法简介

YOLO 系列因其在速度与准确性之间的卓越平衡而备受关注。2023 年 1 月，原 YOLOv5 的开发团队推出了最新版本 YOLOv8，提供了 n、s、m、l、x5 种规格。YOLOv8 继承并扩展了前代模型的特性，展现了优异的性能，尤其在火焰图像目标检测方面表现突出。

YOLOv8 由 backbone、neck 和 head 这 3 部分组成，其结构如图 1 所示。backbone 部分包括 Conv、C2f 和 SPPF 模块，旨在扩展网络的深度和感受野，实现局部与全局特征的融合。neck 部分由 C2f、Concat 和 Upsample 模块组成，通过路径聚合网络和 C2f 模块，整合不同尺度的特征图，促进信息的垂直融合。head 部分采用了解耦结构，将分类和定位预测分开处理，有助于解决二者之间的冲突。与之前的版本相比，YOLOv8 在目标检测、跟踪和分割等任务中表现更加出色。

2 改进 YOLOv8 模型

本文基于 YOLOv8 算法模型，提出了一种轻




图1 YOLOv8 结构简图

Fig.1 Structure diagram of YOLOv8

量化的 YOLOv8 火焰类别检测模型。该模型的改进主要体现在 4 个方面: a. 为了解决模型参数量过大的问题, 引进了 GhostNet^[12] 网络中的 GhostConv 模块替换网络中 backbone 层里的 Conv 模块; b. 改进 C2f 模块为 C2f_RepGhost, GhostConv 和 C2f_RepGhost 都采用了重参数技术, 可以有效降低模型的计算量; c. 为确保模型的检测精度, 在 neck 和 head 部分添加卷积块注意力模块 (convolutional block attention module, CBAM)^[13] 注意力机制; d. 为了提高模型的回归性能, 采用 WIoU (wise intersection over union) 替代原始的 CIoU (complete intersection over union), 提高模型的收敛能力。改进后的结构如图 2 所示。

2.1 GhostConv 模块

GhostNet 是华为诺亚方舟实验室设计的一种轻量级网络, 它可以使原有卷积输出特征图的尺寸以及通道的大小保持不变, 同时还能降低模型的计算量和参数量。在实际的操作中, 输入图像数据 $X \in R^{h \times w \times c}$, 其中 c 为输入通道数, h 、 w 分别为图片的高度和宽度; 输出图像数据 $Y \in R^{h' \times w' \times n}$, n 为输出通道数, h' 和 w' 为图片的高度和宽度; 卷积核大小为 $k \times k$; 线性操作的核大小为 $d \times d$ 。将输

入图像数据分为 s 份, 则:

传统卷积层的参数量为

$$nckk \quad (1)$$

Ghost 模块的参数量为

$$\frac{n}{s}ckk + (s-1)\frac{n}{s}dd \quad (2)$$

此时压缩比为

$$r_c = \frac{nckk}{\frac{n}{s}ckk + (s-1)\frac{n}{s}dd} \approx s \quad (3)$$

用 Ghost 模块升级普通卷积的理论加速比为

$$r_s = \frac{nh'w'ckk}{\frac{n}{s}h'w'ckk + (s-1)\frac{n}{s}h'w'dd} = \frac{ckk}{\frac{1}{s}ckk + \frac{s-1}{s}dd} \approx s \quad (4)$$

因此, GhostConv 作为 GhostNet 网络中的一个卷积模块, 与普通的卷积相比, 有效地提高了模型的效率和性能。

2.2 C2f 模块轻量化

RepGhost 模块是一种轻量级的网络结构, 能够在减少计算资源消耗的同时保持模型性能^[14]。




图 2 改进 YOLOv8 结构简图

Fig.2 Structure diagram of the improved Yolov8

YOLOv8 网络中使用的 C2f 模块能够将低级和高级特征图融合，从而提升检测的准确性和鲁棒性。然而，这一特性也增加了模型的计算复杂度，导致训练和推理时间延长。为了解决这一问题并提高模型效率，将 C2f 模块与 RepGhost 模块集成，形成了 C2f_RepGhost 混合模块。该模块在保留火焰图像多尺度特征融合的同时，显著降低了计算负载，通过引入 RepGhost 模块，C2f_RepGhost 模块有效提升了推理和检测速度。

2.3 CBAM 注意力机制

火焰状态识别属于细粒度识别问题^[15]，通过添加注意力机制，可以让模型更快地找到火焰图像中重要的区域，提高图像分类速度。注意力机制旨在模仿人类视觉感知^[16]，专注于关键特征同时抑制非必要特征。CBAM 代表一种轻量级的卷积注意力模块，将其整合到卷积神经网络中，可以显著提升模型性能。CBAM 引入的额外参数和计算需求极小，使其适合嵌入到大多数卷积网络中。

火焰图像特征图在不同维度上携带不同信息：通道维度提供了火焰的颜色信息、热辐射等，而空间维度则提供了火焰的形状轮廓、尺寸

面积、纹理特征等。CBAM 整合了通道注意力模块 (channel attention module, CAM) 和空间注意力模块 (spatial attention module, SAM)，这两个子模块以串行方式组合，依次在通道维度和空间维度上生成注意力特征图。CBAM 利用通道间的特征关系来创建通道注意图，然后与空间注意力相连，产生最具信息量的特征图。

2.4 损失函数

在 YOLOv8 中，传统的边界框回归损失函数被 CIOU loss 替代，以解决无法有效区分不同回归情况的问题。CIOU loss 是一种先进的损失函数，它不仅考虑边界框之间的重叠区域 (即交并比)，还包括边界框中心的距离和长宽比的匹配程度^[17]。

然而，CIOU loss 仍有局限性，它在处理高度重叠或相交的边界框时效果不佳，且在优化过程中对边界框的尺寸和形状变化敏感。为此，本文采用了 WIou 损失函数，其核心理念是在计算交并比时引入加权机制，以更好地反映边界框之间的相对位置、尺寸和形状差异^[18]。这种方法的基本原则是，通过对边界框的不同区域和特征赋予不同的权重，提高回归损失的敏感性和准确性。

WIoU 回归损失函数根据离群度动态调整锚框的梯度增益，旨在训练过程中最大化锚框的梯度增益。通过使用 WIoU，降低了高质量锚框的竞争性，同时也减少了由低质量示例产生的有害梯度。这种对平均质量锚框的关注转移提高了检测器的整体性能。

3 实验设计与结果分析

3.1 数据集建立

实验的图片数据均来自上海理工大学低气压

燃气燃烧机理实验台。以最典型的高原城市拉萨为例，海拔 3 650 m，大气压约为 65 kPa。为模拟其低气压环境，用真空泵和变频器将低压燃烧室的气压抽到并维持在 65 kPa 左右，实验装置和实验系统示意图如图 3 所示。将氧气、氮气先通到混气罐中混合均匀，再将混合后的气体同甲烷按照不同的当量比送进燃烧室，使用电子点火装置点火，并用工业 CCD 相机采集不同当量比的燃气火焰在低气压状态下的图像，包括预混稳定火焰、扩散稳定火焰、预混不稳定火焰和扩散不稳定火焰这 4 种状态。




图 3 实验系统示意图

Fig.3 Schematic diagram of experimental system

将采集到的视频转换成 png 图片。为了增加数据集的多样性和提高模型的泛化能力，对图片进行数据增强操作，包括随机调整图片的亮度和饱和度、进行图片镜像以及添加随机的高斯噪声。最后得到共 8 140 张图片数据，对图片进行数据标注，并按照训练集：测试集为 8 : 2 进行分配，其中训练集共 6 512 张，测试集共 1 628 张。

3.2 实验环境及参数配置

本次实验基于 64 位 Windows11 操作系统，采用 PyTorch2.0.0，CUDA11.7，Python3.9.16 作为实验环境。所用计算机硬件参数：CPU 为 Intel(R) Core(TM) i5-12490F；内存为 32 G；GPU 为 NVIDIA GeForce RTX2080Ti；显存为 22 G。epoch 为 200 轮，有助于模型更好地拟合数据；批大小为 16；优化器选择经典的 SGD；初始和最终学习率分别设置为 0.001 和 0.01，以提高收敛过程的稳定性；Mixup 设置为 0.2；Degrees 设置为 5，以增加数据的多样性，提高模型的泛化能力及鲁棒性。

3.3 评价指标

为了直观地体现模型改进后性能的提升效

果，本文采用以下指标对模型进行整体性能评价：准确率 P 用来评估预测的准确度；召回率 R 用来评估找到正确样本的能力；平均精度均值 (mean average precision, mAP) M_{AP} 是所有类别预测精准度的平均值；模型参数量 p 指模型中参数的数量；总浮点运算量 q 用来衡量模型的复杂度；帧率 v 指模型每秒钟能处理的图像数量；准确率和召回率的调和平均数用 F_1 表示。 P 、 R 及 F_1 的计算公式为

$$P = \frac{T_P}{T_P + F_P} \tag{5}$$

$$R = \frac{T_P}{T_P + F_N} \tag{6}$$

$$F_1 = \frac{2PR}{P + R} \tag{7}$$

式中： T_P 为预测正确的正样本个数； F_P 为错误地将负样本预测为正样本的样本个数； F_N 为错误地将正样本预测为负样本的样本个数。

通过 P - R (precision-recall) 曲线做积分得到平均精度 A ，再对所有的 A 求平均得到 M_{AP} ，其值越高

说明模型检测效果越好，公式如下：

$$A = \int_0^1 P(R) dR$$

(8)

$$M_{AP} = \frac{1}{m} \sum_{i=1}^m A_i$$

(9)

式中， m 为所有类别数。

本实验通过分析平均精度均值、模型参数量、总浮点运算量、模型大小以及检测视频中火焰目标的检测速度，说明改进模型的效果。

3.4 实验结果

3.4.1 对比实验

在对本文改进模型与 YOLOv8n 模型进行训练时，两者的超参数设置保持一致。对两模型的迭代过程中 F_1 进行了比较，图 4 为两种模型在 200 轮训练中 F_1 的变化折线图。由于本文改进模型缺少预训练权重，在最初的 30 轮训练中，其 F_1 与 YOLOv8n 的相当。在 30~50 轮训练期间，两模型的 F_1 波动明显，本文改进模型的 F_1 高于 YOLOv8n 的。经过 50 轮后，模型趋于稳定，本文改进模型的 F_1 持续超过 YOLOv8n 的。




图 4 模型训练过程中 F_1 对比
Fig.4 Comparison of F_1 in model training process

表 1 为本文改进模型与 YOLOv8n 在准确率、召回率及其他参数上的比较。从中可看出，本文改进模型比 YOLOv8n 模型的准确率提高了 21.2%，召回率提高了 7.4%， $M_{AP}@50$ 提高了 0.5%。 $M_{AP}@50$ 是在交并比阈值为 0.5 时，计算得出的 M_{AP} 。具体而言，当预测边界框与真实边界框的交并比 $I \geq 0.5$ 时，视为有效预测。依此标准计算出各类别的 A 后，取其平均值得到 $M_{AP}@50$ 。这些比较结果证明，本文改进模型在检测准确性上优于 YOLOv8n。此外，经过轻量化改进后，本文改进模型的参数量显著减少，总浮点运算量减少了

12.2%，模型参数量减少了 12.64%，因此，本文改进模型的轻量化效果显著。

表 1 新旧模型参数对比
Tab.1 Comparison of old and new model parameters

模型	p/M	q/G	$P/\%$	$R/\%$	$F_1/\%$	$M_{AP}@0.5/\%$	$v/(f \cdot s^{-1})$
YOLOv8n	11.47	8.2	75.6	88.5	81.7	89.4	91
本文	10.02	7.2	96.8	81.1	88.3	89.9	87

为了进一步评估改进模型的性能，采用 Grad-CAM^[19] 技术对比分析了 YOLOv8n 与本文模型的注意力机制，结果如图 5 所示。图中红色区域为模型在检测过程中的注意力集中情况。通过对比原始 YOLOv8 模型与添加了 CBAM 注意力机制模型的热力图，明显可以看出，添加 CBAM 注意力机制后，模型的注意力集中区域更接近于火焰的轮廓，捕捉火焰特征更加准确，热力区域更加集中和清晰。结果表明，添加 CBAM 注意力机制能够显著提升模型在低气压条件下的火焰检测表现。




图 5 Grad-CAM 热力图可视化
Fig.5 Visualization of Grad-CAM heat map

采用测试集火焰数据进行预测，预测结果表明改进模型表现出色：能够准确识别和分类火焰，同时还具有较高的置信度和精确的定位能力。部分预测结果如图 6 所示。

为了验证文本改进模块的有效性，在确保各超参数设置相同的情况下，进行了与其他 YOLO 模型的对比实验，结果如表 2 所示。与 YOLOv5m、




图 6 模型预测结果

Fig.6 Model prediction results

表 2 YOLO 系列模型实验结果对比

Tab.2 Experimental results comparison of the YOLO series models

模型	p/M	q/G	$P/\%$	$R/\%$	$F_1/\%$	$M_{AP}@0.5/\%$	$v/(f \cdot s^{-1})$
YOLOv5m	79.59	47.9	93.0	76.9	89.15	85.6	42
YOLOv5l	175.95	107.7	88.3	70.7	78.50	85.3	75
YOLOv7	141.96	105.2	88.4	90.0	89.19	95.5	31
YOLOv7-tiny	22.98	13.2	86.3	90.6	88.40	95.1	43
YOLOv8s	11.83	8.2	87.7	91.2	89.40	88.8	70
本文	10.02	7.2	96.8	81.1	88.30	89.9	87

YOLOv5l、YOLOv7 模型相比，在轻量化方面有很大的优势，并且在检测准确率上分别提高了 3.8%、8.5% 和 8.4%、在检测速度上分别提升了 45、12 和 56 f/s；与 YOLOv7-tiny 和 YOLOv8s 模型相比，模型参数量分别下降了 56.4% 和 15.3%，总浮点运算量分别降低了 45.5% 和 12.2%，在检测准确率方面分别提高了 10.5% 和 9.1%，检测帧率分别提高了 47 f/s 和 17 f/s，但是 R 、 F_1 和 M_{AP} 有一定的降低。从总体效果来看，相比于其他模型，本文提出的改进模型在轻量化和检测速率上有明显的提升，在不降低检测精度的同时减少了一定的参数量和计算量，降低了对内存资源的消耗。

3.4.2 消融实验

为证明本文添加的模块对模型性能的提升，设计并开展了消融实验。用 M1 表示 GhostConv 模块、M2 表示 GhostConv+C2f_RepGhost 模块、M3 表示 GhostConv+C2f_RepGhost+CBAM 模块、M4 表示 GhostConv+C2f_RepGhost+CBAM+WIoU 模块；实验结果如表 3 所示。

表 3 消融实验结果对比

Tab.3 Ablation study results comparison

模型	p/M	q/G	$P/\%$	$R/\%$	$F_1/\%$	$M_{AP}@0.5/\%$	$v/(f \cdot s^{-1})$
YOLOv8n	11.47	8.2	75.6	88.5	81.70	89.40	91
+M1	11.43	8.0	95.7	81.2	87.90	89.10	85
+M2	10.15	7.2	74.4	91.4	82.80	82.03	81
+M3	10.10	7.2	86.3	81.9	84.03	84.60	78
+M4	10.02	7.2	96.8	81.1	88.30	89.90	87

增加 GhostConv 模块后，模型的准确率提升了 20.1%， F_1 提升了 6.2%，同时模型的总浮点运算量下降了 2.43%，说明该操作对模型轻量化起到了一定的作用；召回率下降了 7.3%，平均精度均值下降了 0.3%，这说明了 GhostConv 虽然减少了运算量，但是会导致模型捕捉到的特征信息减少，使模型错过一些正样本，从而使模型的召回率和平均精度均值有所下降。增加 C2f_RepGhost 后，模型的召回率提升了 2.9%，但准确率比原模型下降了 1.2%，平均精度均值下降了 7.37%，模型参数量下降了 11.5%，总浮点运算量下降了 12.2%，这说明了该模块对降低模型总浮点运算量有很大的帮助，但是却丢失了对火焰细粒度特征的捕捉能力，导致模型检测性能的下降。添加 CBAM 注意力机制后，模型的准确率相比添加 C2f_RepGhost 模块提升了 21.1%，同时 F_1 和平均精度均值分别提升了 3.1% 和 8.27%，说明添加了 CBAM 模块后，模型关注到了火焰图像的细粒度特征，并成功将这些特征进行了提取。更换损失函数为 WIoU 后，整体准确率提高了 10.5%，平均精度提高了 5.3%，说明 WIoU 有助于提高模型的检测精度。

图 7 和图 8 给出了不同损失函数的平均精度均值和评估指标。从图 7 和图 8 可知，与其他损失函数^[20-22]相比，WIoU 在准确率、平均精度均值和 F1 上均占优势。




图 7 不同损失函数的平均精度均值

Fig.7 Mean average precision of different loss functions




图 8 评估指标对比

Fig.8 Comparison of evaluation indicators

4 结 论

本文提出了一种改进的 YOLOv8n 火焰状态检测方法，针对高原环境下的低气压燃气火焰进行优化。通过将原模型的 backbone 部分中的 Conv 模块和 C2f 模块分别替换为 GhostConv 和 C2f_RepGhost 模块，我们实现了模型的显著轻量化。此外，引入 CBAM 注意力机制进一步提升了模型对火焰细粒度特征的捕捉能力，使其在识别火焰特征时更加高效。改进的损失函数通过引入 WIoU，使模型能够更加关注关键火焰特征，显著提高了对火焰与背景的区分能力，从而提升了模型的鲁棒性和准确性。

实验结果表明，改进后的 YOLOv8n 模型在轻量化和准确率提升方面表现优异。具体而言，总浮点运算量减少了 12.2%，模型参数量减少了 12.64%，准确率提升了 21.2%，召回率提升了 7.4%。这些改进使得模型能够有效减少在高原环境、低气压条件下计算资源的消耗，同时提供了一种燃气火焰状态识别的智能检测解决方案，可

确保对燃气燃烧过程的安全监控。

然而，本研究也存在一定的局限性。首先，改进模型主要在特定的低气压火焰检测任务中进行了验证，其在其他环境条件下的表现仍需进一步评估。其次，虽然模型在准确率和鲁棒性上有所提升，但对于极端火焰特征的检测能力仍需进一步优化。未来的研究可以考虑扩展模型在不同环境条件下的适用性，探索更多有效的特征提取技术，并结合实时处理需求，以进一步提升火焰检测系统的整体性能和适应性。

参考文献：

[1] ZHOU Y, HUANG X M, PENG S N, et al. Comparative study on the combustion characteristics of an atmospheric induction stove in the plateau and plain regions of China[J]. *Applied Thermal Engineering*, 2017, 111: 301–307.

[2] XIE K, CUI Y J, QIU X Q, et al. Combustion characteristics of horizontal diesel spray burner in low-pressure chamber based on multivariate correlation analysis[J]. *Complexity*, 2019, 2019(1): 9421986.

[3] XIE K, CUI Y J, QIU X Q, et al. Experimental investigation on horizontal jet spray flame characteristics with a constant air-fuel ratio in different sub-atmospheric pressures[J]. *Applied Thermal Engineering*, 2020, 165: 114555.

[4] 徐伟勇, 余岳峰, 张银桥, 等. 采用传像光纤和数字图像处理技术检测燃烧火焰 [J]. *动力工程*, 1999, 19(1): 45–48, 79.

[5] 白卫东, 严建华, 马增益, 等. 基于支持向量机的火焰状态识别方法 [J]. *动力工程*, 2004, 24(4): 548–551.

[6] RONQUILLO-LOMELI G, GARCÍA-MORENO A I. A machine learning-based approach for flames classification in industrial Heavy Oil-Fire Boilers[J]. *Expert Systems with Applications*, 2024, 238: 122188.

[7] GANGOPADHYAY T, TAN S Y, LOCURTO A, et al. Interpretable deep learning for monitoring combustion instability[J]. *IFAC-PapersOnLine*, 2020, 53(2): 832–837.

[8] ZHAO H Y, JIN J, LIU Y, et al. FSDF: a high-performance fire detection framework[J]. *Expert Systems with Applications*, 2024, 238: 121665.

[9] YAR H, KHAN Z A, ULLAH F U M, et al. A modified YOLOv5 architecture for efficient fire detection in smart cities[J]. *Expert Systems with Applications*, 2023, 231: 120465.

[10] 王冠博, 赵一帆, 李波, 等. 改进 YOLOv4-tiny 的火焰实时检测 [J]. *计算机工程与科学*, 2022, 44(12): 2196–2205.

[11] 陈露萌, 曹彦彦, 黄民, 等. 基于改进 YOLOv5 的火焰检

- 测方法[J]. 计算机工程, 2023, 49(8): 291–301, 309.
- [12] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 1580–1589.
- [13] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018: 3–19.
- [14] CHEN C P, GUO Z C, ZENG H E, et al. RepGhost: a hardware-efficient ghost module via re-parameterization[EB/OL]. [2024-07-31]. <https://doi.org/10.48550/arXiv.2211.06088>.
- [15] WEI X S, SONG Y Z, MAC AODHA O, et al. Fine-grained image analysis with deep learning: a survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(12): 8927–8948.
- [16] 胡丹丹, 张忠婷, 牛国臣. 融合 CBAM 注意力机制与可变形卷积的车道线检测[J]. 北京航空航天大学学报, 2024, 50(7): 2150–2160.
- [17] ZHENG Z H, WANG P, REN D W, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. *IEEE Transactions on Cybernetics*, 2022, 52(8): 8574–8586.
- [18] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[EB/OL]. [2023-08-08]. <https://doi.org/10.48550/arXiv.2301.10051>.
- [19] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 618–626.
- [20] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. *Neurocomputing*, 2022, 506: 146–157.
- [21] GEVORGYAN Z. SIoU loss: more powerful learning for bounding box regression[EB/OL]. [2022-05-25]. <https://doi.org/10.48550/arXiv.2205.12740>.
- [22] MA S L, XU Y. MPDIoU: a loss for efficient and accurate bounding box regression[EB/OL]. [2023-07-14]. <https://doi.org/10.48550/arXiv.2307.07662>.

(编辑: 董 伟)