

基于 YOLO11-AM 的烟垢小目标检测与在线监测^①



高春芳, 韦干付, 郝晋飞, 陆有超

(广西中烟工业有限责任公司 南宁卷烟厂, 南宁 530001)
通信作者: 陆有超, E-mail: 523885740@qq.com

摘要: 卷烟加工过程对生产线上混合物料状态的感知能力, 直接影响产品质量与运行效率. 但当前监测方法主要聚焦原料属性, 难以全面揭示生产线运行状态. 为此, 提出一种以烟垢为切入点的生产线异常检测新方法, 通过引入自适应特征增强模块 (adaptive feature enhancement, AFE) 和多尺度卷积注意力机制 (multi-scale convolutional attention mechanism, MSCAM), 提升模型在复杂背景下的微小目标烟垢检测精度和实时性, 构建出高效率的烟垢检测 YOLO11-AM 网络. 对标准取样得到的烟草混合物料, 在正交优化后的环境参数下进行消融实验, 结果表明 YOLO11-AM 模型的平均精度达到 97.8%. 同时, 推理速度较基础模型提升了 24.6%, 达到 2.16 ms/张. 进一步的工业部署显示, 模型预测烟垢质量的误差控制在 $\pm 5\%$ 以内, 满足卷烟厂对在线监测系统的性能要求. 本研究为烟草行业的智能化质量控制提供了高效技术支持, 具有显著的理论 and 实践价值.

关键词: 目标检测; 模型改进; 特征增强; 多尺度卷积

引用格式: 高春芳, 韦干付, 郝晋飞, 陆有超. 基于 YOLO11-AM 的烟垢小目标检测与在线监测. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10118.html>

Small-object Tobacco Tar Residue Detection and Online Monitoring Based on YOLO11-AM

GAO Chun-Fang, WEI Gan-Fu, HAO Jin-Fei, LU You-Chao

(Nanning Cigarette Factory, China Tobacco Guangxi Industry Co. Ltd., Nanning 530001, China)

Abstract: The perception of mixed material conditions on cigarette production lines directly affects product quality and operational efficiency. However, current monitoring methods mainly focus on raw material attributes and are difficult to comprehensively reflect production line status. To address this limitation, a novel anomaly detection method using tobacco tar residue as a key indicator is proposed. By integrating an adaptive feature enhancement (AFE) module and a multi-scale convolutional attention mechanism (MSCAM), detection precision and real-time performance for small tobacco tar residues in complex backgrounds are improved, resulting in the development of an efficient YOLO11-AM detection network. Ablation experiments conducted on standard-sampled tobacco mixtures under orthogonally optimized environmental parameters show that the proposed YOLO11-AM model achieves a mean average precision (mAP) of 97.8%, while the inference speed is improved by 24.6% compared to the baseline model, reaching 2.16 ms per image. Further industrial deployment demonstrates that the prediction error for tobacco tar residue mass is controlled within $\pm 5\%$, meeting the performance requirements of online monitoring systems in cigarette factories. This study provides efficient technical support for intelligent quality control in the tobacco industry and holds significant theoretical and practical value.

Key words: object detection; model improvement; feature enhancement; multi-scale convolution

① 收稿时间: 2025-09-22; 修改时间: 2025-10-14; 采用时间: 2025-11-07; csa 在线出版时间: 2026-02-06

在烟草行业中,卷烟加工工序作为香烟生产的核心步骤之一,目的是将卷烟原料中的烟丝和烟梗分离并制成成品香烟.其中,烟丝和烟梗的分离程度是确保产品质量和生产效率的关键,检测并反馈卷烟原料中烟丝和烟梗的比例直接影响生产线调控和卷烟加工工序.近年来,光谱分析和计算机视觉检测在针对烟丝、烟梗等原料及产品的检测任务中取得显著作用.一方面,光谱检测技术因其非破坏性和高分辨率得到广泛应用,如刘涛等^[1]基于太赫兹光谱检测烟丝掺配比例,分类精度达 92.27%;杨天卓等^[2]和张宇帆等^[3]利用高光谱成像技术分别实现烟丝掺配比例的快速检测和烟蒂物证高效检测.另一方面,深度学习作为计算机视觉检测的核心技术,依托卷积神经网络(convolutional neural network, CNN)^[4]驱动图像分割和目标检测,构建出 YOLO (you only look once) 系列^[5]、残差网络(residual network, ResNet)^[6]和掩膜区域卷积神经网络(mask region-based convolutional neural network, Mask R-CNN)^[7]等在烟草加工领域表现突出的检测模块.如洪金华等^[8]利用 YOLOv3 模型开发出烟虫检测系统,实现高精度的目标检测;赵杰峰等^[9]通过改进 YOLOv4 模型提升模型推理速度,实现烟丝宽度实时检测;胡东辉等^[10]基于改进的 YOLOv5s 模型优化异常烟丝的视觉检测,识别平均精确率达到 96.4%;Xue 等^[11]改进 YOLOv7 的少样本学习方法优化小目标检测性能,实现烟梗中杂质高效检测;费致根等^[12]提出基于改进 ResNet 网络的烟丝输送带洁净度分类模型,引入通道注意力机制(squeeze-and-excitation, SE)^[13]和卷积块注意力模块(convolutional block attention module, CBAM)^[14]去提升对烟垢等细微特征物体的检测能力;张伟伟等^[15]提出 Mask R-CNN 的粘连烟丝识别方法,结合边缘、分形及注意力机制特征融合,提高烟丝分割的准确性;王小明等^[16]利用自适应提升算法(adaptive boosting, AdaBoost),构建烟丝成分识别框架,其精度达 95%;王莉等^[17]改进 MobileNetV2 实现烟丝种类识别方法,烟丝识别准确率为 95.37%.然而,这些方法主要聚焦于识别烟丝和烟梗这些卷烟原料信息,不能全面反映生产线状态.

烟垢是烟叶加工过程中由烟叶和焦油在高温下碳化形成的副产物,其生成量和分布特性与设备的清洁度和运行效率密切相关,且在卷烟原料中具有相对稳定的比例.因此,通过对烟垢的定量检测,可以及时判

断生产线的状态,确保产品质量和生产效率的稳定性.为此,提出一种以烟垢为切入点的生产线异常检测方法.为应对烟垢检测中复杂背景、小目标识别及设备状态监测的挑战,提出一种改进的 YOLO11-AM 网络,该网络引入自适应特征增强模块(adaptive feature enhancement, AFE)和多尺度卷积注意力机制(multi-scale convolutional attention mechanism, MSCAM),实现多阶段融合空间上下文和特征精炼信息,优化烟垢分割的计算效率并验证所搭建的烟垢视觉检测框架.

1 模型改进

1.1 自适应特征增强模块

烟垢在卷烟加工生产线图像中表现为小目标且背景复杂,传统目标检测与定位算法模型的特征提取能力不足以满足高精度检测需求.为此,引入自适应特征增强模块 AFE 以提升烟垢特征表达能力. AFE 的结构(图 1)包括 4 个核心组件:卷积嵌入(convolutional embedding, CE)、空间上下文模块(spatial context module, SCM)、特征精炼模块(feature refinement module, FRM)和卷积多层感知器(convolutional multi-layer perceptron, ConvMLP).

这些组件通过多尺度特征融合和注意力机制协同优化,增强烟垢在复杂背景下的特征表达能力. AFE 模块的处理流程如下.

(1) 卷积嵌入(CE):输入特征 F 通过层归一化(layer normalization, $LayerNorm$)和卷积嵌入层处理,生成初始特征:

$$F_{CE} = Conv_{5 \times 5}(LayerNorm(F), stride = 4) \quad (1)$$

其中,卷积核大小为 5×5 ,步幅为 4, $LayerNorm$ 稳定输入特征的分布,缓解训练过程中的梯度消失问题.随后,通过 1×1 卷积将通道数压缩至一半,降低计算开销并促进特征混合:

$$F_{squeeze} = Conv_{1 \times 1}(F_{CE}) \quad (2)$$

(2) 空间上下文模块(SCM):采用分组卷积(核大小 7×7)扩大感受野,捕获多尺度空间上下文信息:

$$F_{SCM} = GroupConv_{7 \times 7}(F_{squeeze}) \quad (3)$$

(3) 特征精炼模块(FRM):通过深度卷积和上采样操作,分别提取高频和低频特征,具体步骤如下:

首先,输入特征 $F_{squeeze}$ 通过深度卷积(depthwise

convolution, $DWConv$) 生成下采样特征图 P :

$$P = DWConv_{3 \times 3}(F_{squeeze}, stride = 2) \quad (4)$$

其次, 将 P 上采样至原始分辨率, 得到平滑特征 Q :

$$Q = Upsample(P) \quad (5)$$

接着, 通过特征差值突出烟垢的边缘细节:

$$R = F_{squeeze} - Q \quad (6)$$

然后, 通过元素级乘法强调低频区域, 突出烟垢的斑块区域:

$$S = F_{squeeze} \cdot Q \quad (7)$$

最后, 将高频和低频特征通过深度卷积进行特征聚合, 并通过投影层生成最终特征:

$$F_{FRM} = DWConv_{3 \times 3}(R + S) \quad (8)$$

(4) 卷积多层感知器 (ConvMLP): 将 SCM 和 FRM 的输出通过 1×1 卷积融合, 并通过 ConvMLP 进一步增强特征:

$$F_{out} = F_{ConvMLP}(Conv_{1 \times 1}(F_{SCM} + F_{FRM})) \quad (9)$$

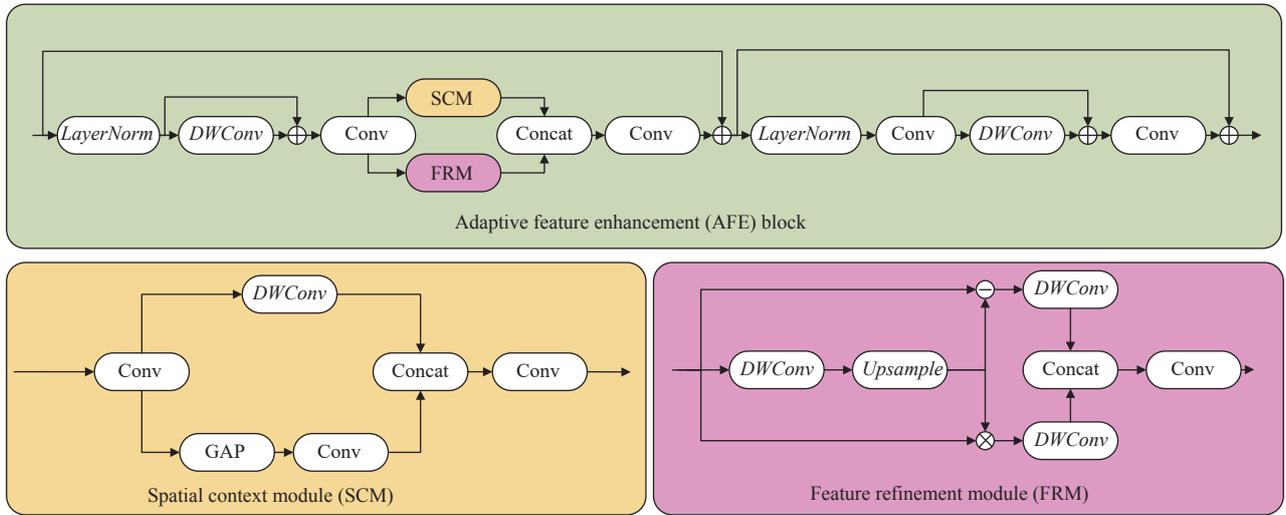


图1 自适应特征增强模块

1.2 多尺度卷积注意力机制

为提升模型对不同尺寸烟垢的感知能力和计算效率, 引入多尺度卷积注意力机制 (MSCAM). MSCAM (图2) 通过通道注意力模块 (channel attention block, CAB)、空间注意力模块 (spatial attention block, SAB) 和多尺度卷积模块 (multi-scale convolution block, MSCB) 实现高效特征提取. MSCAM 的处理流程如下.

(1) 通道注意力模块 (CAB). 首先, 输入特征 F , 通过自适应最大池化 (adaptive max pooling, P_m) 和自适应平均池化 (adaptive average pooling, P_a) 提取通道特征. 其次, 使用逐点卷积 (pointwise convolution, PWC) 和 $ReLU$ (rectified linear unit) 激活函数生成注意力权重, 并通过逐元素乘积加权输出特征:

$$\begin{cases} F_a = PWC_2(ReLU(PWC_1(P_a(F)))) \\ F_m = PWC_2(ReLU(PWC_1(P_m(F)))) \\ F_{CAB} = \sigma(F_a + F_m) \odot F \end{cases} \quad (10)$$

(2) 空间注意力模块 (SAB). 输入特征 F_{CAB} , 通过沿通道维度的最大池化 (channel-wise max pooling, Ch_{max}) 和平均池化 (channel-wise average pooling, Ch_{avg}) 提取局部特征, 再使用大核卷积 (large kernel convolution, LKC) 增强上下文关系并通过 Sigmoid 激活生成注意力权重:

$$F_{SAB} = \sigma(LKC([Ch_{max}(F_{CAB}), Ch_{avg}(F_{CAB})])) \odot F_{CAB} \quad (11)$$

(3) 多尺度卷积模块 (MSCB). 以输入特征 F_{SAB} 为基础, 首先通过逐点卷积 (PWC_1) 扩展通道数, 随后利用多尺度深度卷积 (multi-scale depthwise convolution, $MSDC$) 捕获多分辨率上下文, 接着通过逐点卷积 (PWC_2) 恢复通道数, 并在各卷积操作后引入批归一化 (batch normalization, BN) 提升模块的稳定性与非线性表达能力:

$$\begin{cases} F_{MSDC} = MSDC(ReLU(BN(PWC_1(F_{SAB})))) \\ F_{out} = BN(PWC_2(F_{MSDC})) \end{cases} \quad (12)$$

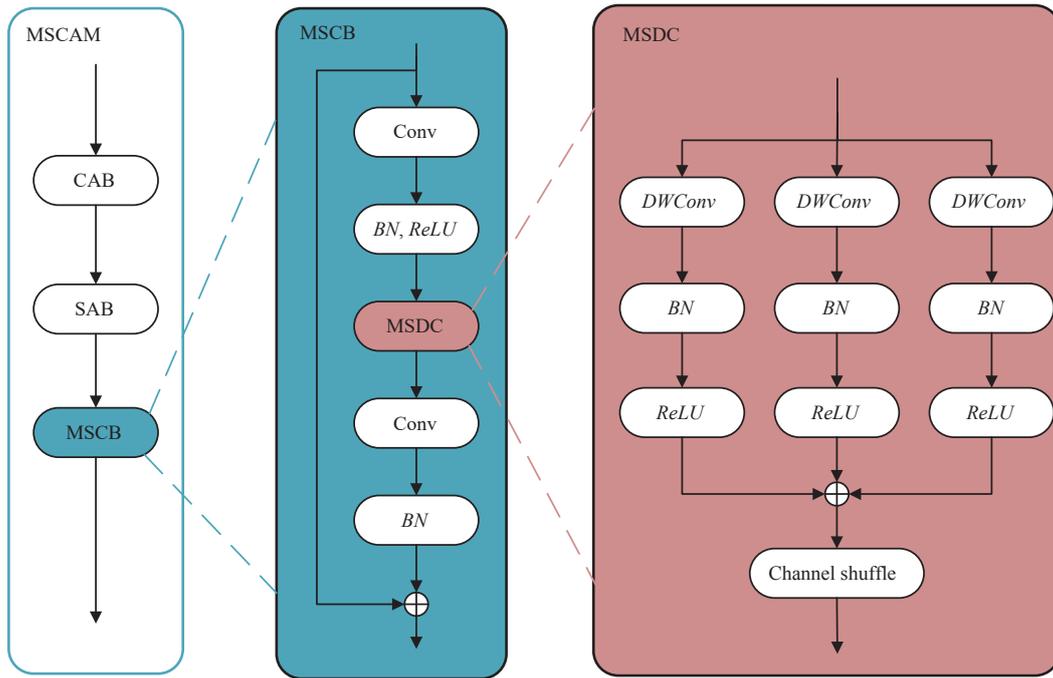


图2 多尺度卷积注意力机制

1.3 YOLO11-AM 网络

为提升模型在复杂背景下烟垢识别的泛化性,基于 YOLO11 基准模型并集成 AFE 和 MSCAM 模块,对骨干网络 (Backbone) 和特征融合路径 (Neck) 进行以下两点改进,搭建出高效的烟垢检测 YOLO11-AM 网络 (图 3)。

改进点 1: 当参数 $c3k=True$ 时,对 C3k2 模块中的 C3k 模块进行修改,具体为在 C3k 网络中,连续 Bottleneck 处理后添加 AFE 处理模块,适配复杂背景下的烟垢检测;当 $c3k=False$ 时,直接对 C3k2 模块进行修改,具体为直接在 C3k2 中连续 Bottleneck 处理后添加 AFE 处理模块,增强复杂背景下的烟垢识别。

改进点 2: 将 YOLO11 的空间金字塔池化 (spatial pyramid pooling, SPPF) 模块替换为 MSCAM 模块,提升对不同尺寸烟垢的检测能力。

采用 YOLO11-AM 检测烟垢的处理流程如下。

- (1) 输入的烟垢图像 F 通过初始卷积 (3×3 , 步幅 2, 64 通道) 生成 P1/2 特征。
- (2) 后续卷积 (3×3 , 步幅 2, 128 通道) 生成 P2/4 特征。
- (3) 特征通过 C3k2_AFE 模块 (256 通道, $c3k=$

False, 重复 2 次; 512 通道, $c3k=False$, 重复 2 次; 512 通道, $c3k=True$, 重复 2 次; 1024 通道, $c3k=True$, 重复 2 次), 结合下采样卷积 (3×3 , 步幅 2), 生成多尺度特征 P3/8、P4/16、P5/32。

(4) P5/32 特征通过 MSCAM (1024 通道) 和 C2-PSA 模块 (1024 通道, 重复 2 次) 进一步增强, 生成 S4。

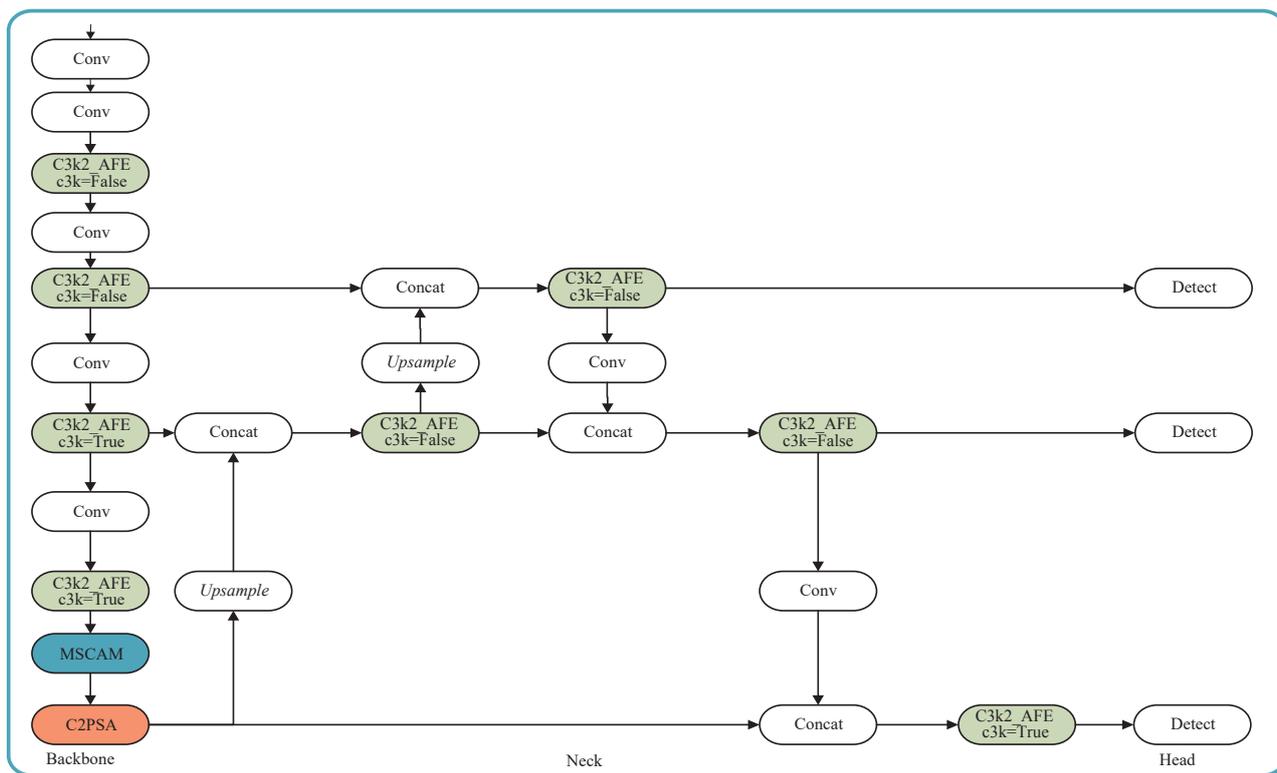
(5) 深层特征 S4 (P5/32, 1024 通道) 通过上采样 (2 倍, 最近邻插值) 与 P4/16 (512 通道) 拼接, 通过 C3k2_AFE (512 通道, $c3k=False$, 重复 2 次) 生成 F3。

(6) F3 上采样后与 P3/8 (256 通道) 拼接, 通过 C3k2_AFE (256 通道, $c3k=False$, 重复 2 次) 生成 F2 (P3/8-small)。

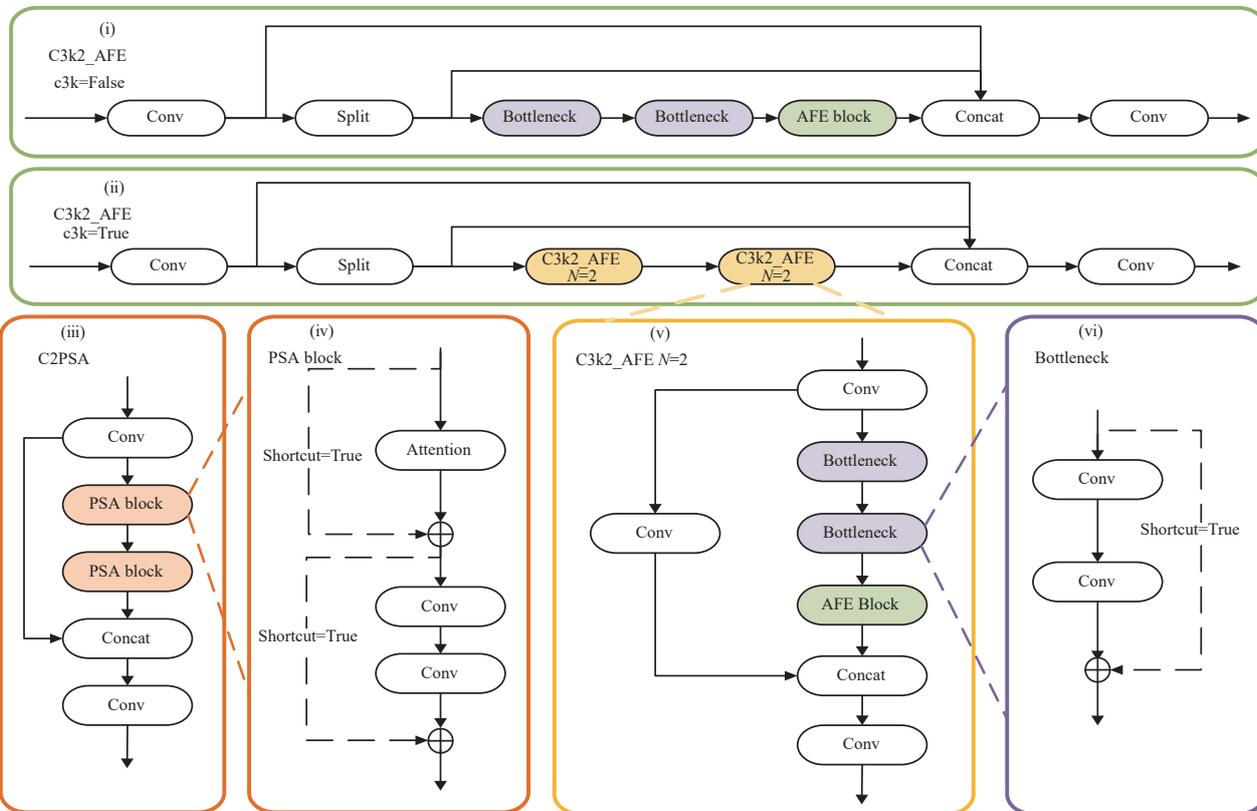
(7) F2 通过卷积 (3×3 , 步幅 2, 256 通道) 与 FAFE3 拼接, 通过 C3k2_AFE (512 通道, $c3k=False$, 重复 2 次) 生成 F3 (P4/16-medium)。

(8) F3 通过卷积 (3×3 , 步幅 2, 512 通道) 与 S4 拼接, 通过 C3k2_AFE (1024 通道, $c3k=True$, 重复 2 次) 生成 F4 (P5/32-large)。

(9) Segment 检测头融合多尺度特征 {F2, F3, F4}, 生成 3 路分割掩码 (P3/8-small、P4/16-medium、P5/32-large), 适配不同尺度的烟垢检测。



(a) 整体模块



(b) 6个子模块

图3 YOLO11-AM网络

2 实验与结果分析

为全面验证 YOLO11-AM 在复杂工业场景下的检测精度、推理速度及其实用性,设计了一系列科学实验,包括烟垢质量分布实验、模型消融实验和实际部署.首先,在卷烟生产线上进行了烟垢的标准采样并讨论了烟垢的质量分布.接着,在正交优化的拍摄参数下进行 YOLO11-AM 网络的消融实验,最后,在烟厂实际卷烟生产线上进行了模型部署.

2.1 实验配置

实验平台(图4)由图像采集系统、照明控制系统和运动模拟系统组成,旨在模拟卷烟加工生产线的真实工作环境.图像采集系统采用 MV-CB060-10GM-C 工业相机,分辨率为 3072×2048 (600 万像素),配备 MVL-LF3528M-F 定焦 FA 镜头(焦距 35 mm,像圈直径 43.2 mm),确保图像的高清晰度和几何保真度.照明系统采用 ZM-R18000-RGB 三色环形光源,光照强度可调范围为 0-1 000 lux,能够适应多种光照条件.运动模拟系统通过精密控制的传送带实现物料动态输送,传送带速度可调(0.1-1 m/s),精确模拟生产线上的物料运动状态.



图4 生产线实验平台

硬件配置包括 NVIDIA RTX3090 GPU (24 GB 显存)、Intel Xeon Silver 4210 CPU (10 核, 2.2 GHz)、64 GB 内存和 1 TB NVMe SSD, 确保高效的模型训练与推理.软件环境基于 PyTorch 2.0、Python 3.8、CUDA 11.8、CuDNN 8.6 和 Ubuntu 20.04 操作系统, 提供稳定的开发与测试平台.

2.2 烟垢生成机理与特性表征

烟垢是制丝过程中烟叶中可挥发与焦油类组分在

高温作用下发生热解-缩合-炭化所形成的固体副产物,常附着于设备表面或混杂于物料之中.其主要成分包括碳质残留物、焦油聚合物、糖类衍生物及微量金属离子,整体呈脆性特征,表面易黏附细碎烟丝,体现出与基质不同的物理性质与力学响应.正常生产条件下,烟垢含量相对稳定,其生成量与空间分布受设备清洁度、运行效率及工艺条件(如温度、含水率、输送速度、表面形貌与静电等)耦合影响.

从形成过程看,烟叶经刀辊切削后在导丝条刀刃-导丝面区域经历高频接触与局部升温,烟油/焦油等黏性组分首先在刃口处初始黏附并聚集,随后随物料流在导丝面上迁移与二次黏附;随着运行时间增加,黏附体逐步失水、硬化并碳化,演化为条状或片状沉积物.当沉积达到一定厚度后,受剪切与振动作用易发生分段或整体脱落,混入烟丝,进而对外观与质量产生不利影响.

在光学特征上,烟垢(图5)表面多呈深棕至黑色,与黄褐色的烟草混合物料形成显著亮度与色彩对比,为基于计算机视觉的小目标检测提供了清晰的判别线索.基于此,本文将研究对象设置为卷烟加工生产线上烟草混合物料中的烟垢,并通过定量检测表征其生成与波动特性:一方面可反映生产线运行状态与设备洁净度,另一方面为维护策略与质量控制提供依据,从而支撑在线监测与智能化生产的实施.



图5 标准取样得到的烟垢

2.3 质量测量实验与结果分析

为定量分析卷烟生产线上的烟垢分布特性及其与设备运行状态的关联, 本实验设计了系统的质量测量流程, 旨在为 YOLO11-AM 模型的检测提供数据支持, 并验证烟垢检测的工业应用价值. 实验通过在南宁卷烟厂卷烟生产线上定期取样、人工筛选和精准称重, 获取烟垢的质量分布数据, 为后续模型部署中的区域划分和检测策略优化提供依据.

实验流程如下.

(1) 取样设计: 在南宁卷烟厂实验平台的正常卷烟生产线中, 每隔 30 min 从传送带上随机抽取 30 g 烟草混合物料样本, 共采集 280 组样本. 为确保样本代表性, 取样点覆盖生产线不同区域 (包括进料口、加工段和出料口), 并在不同运行时间段 (早班、中班、晚班) 进行采集, 以反映烟垢在生产过程中的动态分布特性.

(2) 质量测量: 使用高精度电子秤 (精度为 0.001 g) 对分离出的烟垢样本进行称重, 记录每个样本的质量. 实验共分离 1064 个烟垢样本, 质量范围为 0.022–0.27 g. 测量环境控制在恒温恒湿条件下 (温度 24 °C, 湿度 12%), 以避免环境因素对称重结果的干扰.

(3) 数据分析: 对 1064 个烟垢样本的质量数据进行统计分析, 计算平均质量和分布特性 (图 6). 结果显示, 烟垢平均质量为 0.079 g, 95% 分布区间为 0.03–0.18 g; 分区域统计显示, 加工段占比 41.2%, 进料口 33.5%, 出料口 25.3%. 跨班次统计的均值波动在 ± 0.010 – ± 0.012 g 之间 (早班 0.078 ± 0.011 g, 中班 0.079 ± 0.010 g, 晚班 0.080 ± 0.012 g), 整体分布稳定, 进一步验证了烟垢量作为设备状态监测指标的可行性与稳定性.

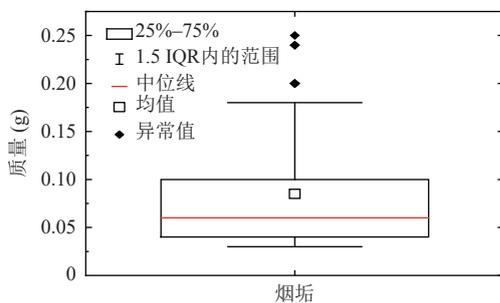


图 6 烟垢质量分布

2.4 多光源多照度条件下的鲁棒性评估

为评估所提模型在不同光照条件、背景复杂度与干扰因素下的泛化能力, 构建所示的验证平台 (图 7). 采用白/红/绿/蓝这 4 种环形光源, 照度设为 200/500/800

lux 这 3 档, 并使用标准照度计在成像平面中心实测与校准; 相机安装高度、焦距与白平衡在全程锁定一致, 以排除非光谱因素干扰. 在每一“光源×照度”条件下采集 400 张图像, 覆盖皮带磨损、混入纤维碎屑、局部高光与轻微遮挡等常见扰动. 各条件进行 3 次独立重复推理, 报告 mAP@0.5 的均值±标准差, 阈值与后处理参数统一固定以保证可比性.

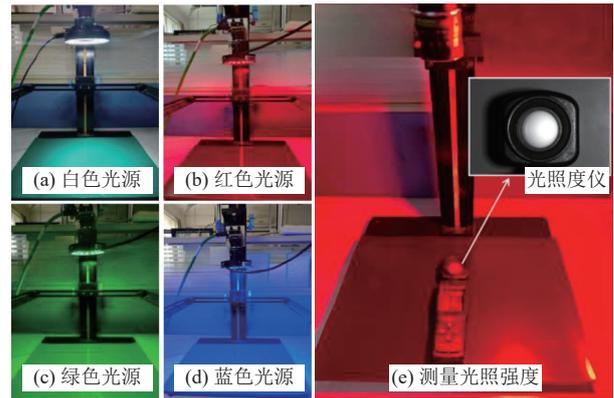


图 7 鲁棒性验证实验平台

结果表明 (表 1), 在全部“光源×照度”组合下模型均保持 mAP@0.5 $\geq 96.3\%$ 的高水平, 体现出良好的鲁棒性. 总体性能排序为红色 > 白色 > 绿色 > 蓝色, 其中红色 500 lux 获得全局最优 (98.7%). 其原因在于红光能增强深色烟垢与黄褐色基质之间的亮度对比, 同时对镜面高光更不敏感; 白光在 500 lux 次优且具备较好的色彩还原性; 绿色整体略低于白光; 蓝色受近色背景与高光斑影响更明显. 照度从 200 提升至 500 lux 可显著改善传感器信噪比与有效动态范围, 使 mAP@0.5 稳定提升; 进一步提升至 800 lux 时, 由于局部接近饱和与高光反射, mAP@0.5 出现轻微回落 (典型幅度 ≤ 0.5 – 0.7 个百分点). 综合考虑精度与可实施性, 建议在线部署采用红色环形光 500 lux 作为默认参数; 当红光受限时, 可优先选择白光 500 lux 作为备选, 并在运行中设置照度健康阈值 (如偏离 500 lux 超过 $\pm 10\%$ 触发自检/校准), 以保障长期稳定监测.

2.5 消融实验与结果分析

为验证所提模块的有效性并优化模型性能, 本研究在最优环境参数 (红色光源、25 cm 相机高度、500 lux 光强) 下进行系统性消融实验. 首先, 构建本地烟垢数据集 (共 5000 张图像, 含训练集 3500 张、验证集 1000 张、测试集 500 张). 设置训练参数: 批量大小 16, 初始学习率 0.001 (Adam 优化器), 200 epoch 训练周期, 基

于 YOLO11n 预训练模型, 结合余弦退火学习率调度和 0.0005 权重衰减. 通过对比不同模块组合的性能表现 (验证集 mAP@0.5 与测试集推理速度), 定量分析各模块贡献.

表 1 不同条件下 YOLO11-AM 的鲁棒性结果

光源颜色	照度 (lux)	mAP@0.5 (%)
白	200	97.1±0.3
	500	98.0±0.2
	800	97.5±0.3
红	200	98.1±0.2
	500	98.7±0.2
	800	98.3±0.2
绿	200	97.0±0.3
	500	97.6±0.3
	800	97.2±0.3
蓝	200	96.3±0.4
	500	97.0±0.3
	800	96.6±0.3

实验结果 (表 2) 表明: 单独引入 AFE 模块时, 推理速度提升 9.1%, 但 mAP@0.5 轻微下降 1.3%, 说明特征增强可能引入少量噪声; 单独采用 MSCAM 模块

时, mAP@0.5 提升 0.8% 至 0.9856, 验证多尺度注意力机制对检测精度的促进作用; 完整模型 YOLO11-AM (同时集成 MSCAM 与 AFE) 在保持基础模型精度水平 (mAP@0.5=0.9775) 的同时, 推理速度显著提升 24.6% (2.865→2.16 ms/张), 实现精度与效率的协同优化, 充分满足卷烟生产场景对高精度 (误差<±5%) 与实时性的双重要求.

表 2 消融实验结果

模型	mAP@0.5 (%)	推理速度 (ms/张)
YOLO11	97.82	2.865
+AFE	96.48	2.605
+MSCAM	98.56	2.825
YOLO11-AM	97.75	2.160

2.6 工业部署验证

基于消融实验结果, 选择 YOLO11-AM 模型部署至卷烟生产线, 部署流程包括以下步骤.

(1) 图像采集: 工业相机实时采集生产线上的混合物料图像 (图 8), 图像经预处理后输入 YOLO11-AM 模型.

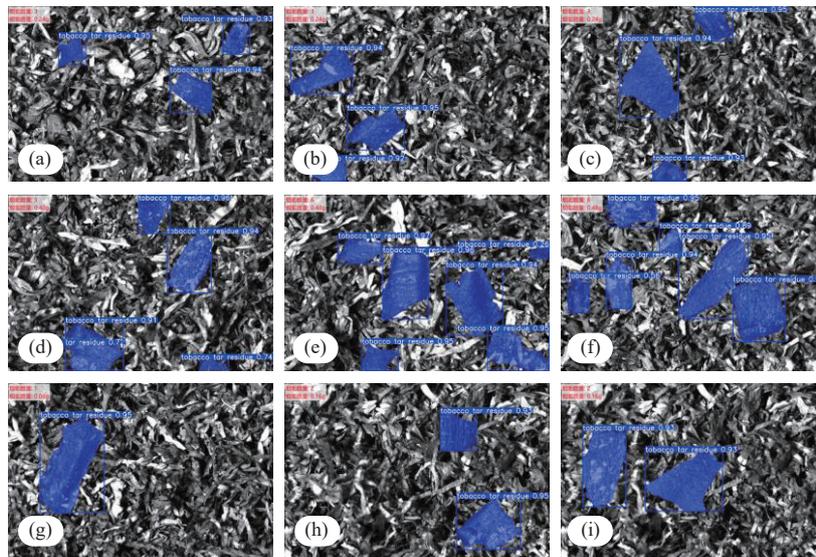


图 8 YOLO11-AM 模型推理结果

(2) 模型推理: 在 Jetson AGX Orin 平台上运行优化后的 YOLO11-AM 模型, 输出检测的烟垢区域信息.

(3) 结果输出: 通过烟垢区域检测数量与预设平均质量参数, 自动计算总烟垢质量.

结果显示, 部署模型能准确识别不同光照条件下的烟垢区域 (检测框置信度>95%), 且推理延迟稳定在 4.5±0.3 ms, 输出结果与实际人工测量误差保持在

±5% 范围内, 验证了该方法在复杂工业环境中的鲁棒性与实用性.

3 结论与展望

面向卷烟生产线中影响生产效率和产品质量的制丝副产物——烟垢, 提出基于改进 YOLO11-AM 网络的检测方法. 通过引入自适应特征增强模块 (AFE) 与

多尺度卷积注意力机制 (MSCAM), 提升模型对小尺度目标的感知能力和特征表达能力. 在标准实验平台和正交优化拍摄条件下, YOLO11-AM 模型实现了 97.8% 的检测精度和 2.16 ms/张的推理速度, 相较于原始 YOLO11 模型实现 24.6% 的速度提升, 验证了改进策略的有效性. 消融实验表明, AFE 有助于增强细粒度特征, MSCAM 则显著提升检测精度, 二者的协同作用为模型带来了优异的整体性能表现. 在工业实际部署中, YOLO11-AM 模型能够稳定适应不同光照和背景条件, 快速定位烟垢区域, 其检测结果与人工测量数据误差控制在 $\pm 5\%$ 以内, 具备良好的鲁棒性和实用性. 该方法不仅丰富了烟草行业视觉检测技术的应用场景, 也为实现生产过程中的在线监测和智能决策提供了有力支撑. 未来的工作将围绕以下方向展开: 一是引入更轻量化的模型结构以适配边缘计算场景; 二是结合多模态数据 (如温度、振动) 进一步提升设备状态感知能力; 三是拓展模型在其他污染源检测或清洁度评估任务中的通用性与可迁移性.

参考文献

- 1 刘涛, 丁美宙, 张二强, 等. 基于太赫兹光谱检测技术的烟丝掺配比例识别模型. 烟草科技, 2024, 57(12): 74–83. [doi: 10.16135/j.issn1002-0861.2024.0151]
- 2 杨天卓, 何晋, 吴恋恋, 等. 基于高光谱成像的烟丝掺配比例检测研究. 轻工学报, 2025, 40(3): 115–126.
- 3 张宇帆, 高树辉. 基于高光谱成像技术的烟蒂物证检测. 应用化工, 2025, 54(3): 667–675. [doi: 10.3969/j.issn.1671-3206.2025.03.021]
- 4 Li ZW, Liu F, Yang WJ, *et al.* A survey of convolutional neural networks: Analysis, applications, and prospects. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(12): 6999–7019.
- 5 Redmon J, Divvala S, Girshick R, *et al.* You only look once: Unified, real-time object detection. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 779–788.
- 6 Targ S, Almeida D, Lyman K. Resnet in resnet: Generalizing residual architectures. arXiv:1603.08029, 2016.
- 7 He KM, Gkioxari G, Dollár P, *et al.* Mask R-CNN. Proceedings of the 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017. 2980–2988.
- 8 洪金华, 忻惠琴, 陆海华, 等. 基于 YOLOV3 模型的卷烟厂烟虫识别方法. 烟草科技, 2020, 53(9): 77–84. [doi: 10.16135/j.issn1002-0861.2019.0280]
- 9 赵杰峰, 胡艳华. 基于改进 YOLOv4 算法的烟丝宽度检测方法. 计算机应用与软件, 2025, 42(4): 63–67. [doi: 10.3969/j.issn.1000-386x.2025.04.011]
- 10 胡东辉, 刘振宇, 林苗俏, 等. 基于改进 YOLOv5s 的异常烟丝识别检测轻量化算法. 中国烟草学报, 2025, 31(3): 78–87. [doi: 10.16472/j.chinatobacco.2024.T0192]
- 11 Xue S, Li ZY, Wu R, *et al.* Few-shot learning for small impurities in tobacco stems with improved YOLOv7. IEEE Access, 2023, 11: 48136–48144.
- 12 费致根, 鲁豪, 宋晓晓, 等. 基于改进 ResNet 网络的烟丝输送带洁净度分类模型. 轻工学报, 2024, 39(5): 71–77.
- 13 Hu J, Shen L, Sun G. Squeeze-and-excitation networks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 7132–7141.
- 14 Woo S, Park J, Lee JY, *et al.* CBAM: Convolutional block attention module. Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018. 3–19.
- 15 张伟伟, 姬远鹏, 元春波, 等. 基于改进 Mask R-CNN 模型的粘连烟丝识别方法. 轻工学报, 2024, 39(5): 78–85.
- 16 王小明, 魏甲欣, 马飞, 等. 基于 AdaBoost 集成学习的烟丝组分识别. 食品与机械, 2022, 38(3): 205–211. [doi: 10.13652/j.spjx.1003.5788.2022.90008]
- 17 王莉, 朱雯路, 范磊, 等. 基于改进 MobileNetV2 的烟丝种类识别. 中国农机化学报, 2025, 46(8): 58–65. [doi: 10.13733/j.jcam.issn.2095-5553.2025.08.009]

(校对责编: 李慧鑫)