

李峰.融合注意力机制的铝型材缺陷检测研究[J].辽宁工程技术大学学报(自然科学版),2026,45(2):249-256.DOI:10.11956/j.issn.1008-0562.20250459

LI Feng. Defect detection of aluminum profiles with attention mechanism incorporation[J]. Journal of Liaoning Technical University (Natural Science), 2026, 45(2): 249-256. DOI: 10.11956/j.issn.1008-0562.20250459

融合注意力机制的铝型材缺陷检测研究

李 峰

(中国飞行试验研究院 中飞测试, 陕西 西安 710089)

摘 要: 针对现有检测模型在小目标缺陷识别中存在漏检、误检等问题, 提出一种基于YOLOv8n-SE模型的铝型材表面缺陷检测方法。通过在YOLOv8n模型的颈部网络中嵌入SE注意力机制, 增强特征提取能力, 提高对缺陷区域的定位精度与检测敏感度。基于铝型材工件缺陷数据集开展对比试验, 将改进模型与Faster R-CNN、YOLOv5n等轻量级模型及不同注意力机制的方案进行性能评估。研究结果表明, 改进后模型的平均精确度(mAP)达到75.0%, 相较于原始YOLOv8n模型提升4.2%, 参数量基本保持不变, 推理速度仅下降0.3%。嵌入SE注意力机制的YOLOv8n模型能有效提升铝型材表面缺陷识别效果, 缓解小目标的漏检与误检问题, 同时保持轻量级模型的高效推理优势, 适用于工业场景下的铝型材缺陷检测需求。研究结论为同类工业缺陷检测任务的模型选择与优化提供参考。

关键词: 缺陷检测; 铝型材; YOLOv8模型; SE注意力机制; 小目标检测

中图分类号: TP391.4

文献标志码: A

文章编号: 1008-0562(2026)02-0249-08

Defect detection of aluminum profiles with attention mechanism incorporation

LI Feng

(Chinese Flight Test, China Flight Test Research Institute, Xi'an 710089, China)

Abstract: In the field of industrial material production and management, traditional detection methods are difficult to meet the diverse detection requirements for surface coating cracks and other defects of aluminum profiles. Moreover, existing detection models have problems of missed detection and false detection of small targets. This paper proposes a surface defect detection method for aluminum profiles based on YOLOv8n-SE. By embedding the SE attention mechanism in the neck network of the YOLOv8n model, the feature extraction ability is enhanced, improving the positioning accuracy and defect sensitivity of the defect area. Experiments were conducted using an aluminum profile defect dataset, and the proposed method was compared with lightweight models such as Faster R-CNN and YOLOv5n combined with different attention mechanisms. The research results show that the average precision (mAP) of the improved model reaches 75.0%, a 4.2% higher than the original YOLOv8n model, with the number of parameters remaining basically unchanged and the inference speed only decreasing by 0.3%. The improved YOLOv8n model with the embedded SE attention mechanism can effectively improve the recognition effect of surface defects of aluminum profiles, solve the problem of missed detection and false detection of small targets, and maintain the efficient inference advantage of lightweight models, making it suitable for the defect detection requirements of aluminum profiles in industrial scenarios.

Keywords: defect detection; aluminum profiles; YOLOv8 model; SE attention mechanism; small target detection

0 引言

在工业4.0与智能制造深度融合的背景下, 铝

型材工件表面缺陷检测技术面临着新的要求与挑战。传统人工检测方法在精度与效率上难以满足工业场景的实际需求, 尤其在识别凹陷、涂层开

收稿日期: 2025-10-29

修回日期: 2025-12-24

接受日期: 2026-01-07

责任编辑: 朱含露

基金项目: 陕西省重点研发计划项目(2023JBG5-23)

作者简介: 李 峰 (1981-), 男, 陕西 咸阳人, 硕士, 高级工程师, 主要从事飞机机载测试技术方面的研究。E-mail: 104604544@qq.com

裂、桔皮、起坑、凸粉等复杂表面缺陷时表现欠佳。随着深度学习技术^[1]的发展,基于卷积神经网络的目标检测算法为该领域提供了新的解决路径。其中,YOLO系列算法因其同时具备较高的检测精度与良好的实时性,已被广泛应用于各类工业缺陷检测任务^[2-3]。

近年来,YOLOv8系列算法凭借其出色的实时性与检测精度,已成为工业缺陷检测领域的研究热点。其中,轻量级YOLOv8n模型依托高效的特征提取与多尺度检测能力,在维持较快推理速度的同时,能有效识别铝型材工件表面的多种缺陷,展现出良好的应用潜力。然而,该模型在处理反光曲面上的微小缺陷时,仍存在漏检率高等问题。在缺陷检测模型优化方面,陈万志等^[4]提出融合Swin Transformer和坐标注意力(coordinate attention, CA)模块的改进YOLOv5方法,增强对缺陷方向与位置信息的敏感性,提升了平均精度均值(mean average precision, mAP);彭继慎等^[5]针对电力设备小目标检测任务,设计了多尺度特征融合增强检测模型(multi-scale feature fusion enhanced YOLO, MFFE-YOLO),改善了小目标缺陷的识别效果。王明涛^[6]在YOLOv8模型中引入感受野通道注意力机制(receptive field channel attention, RFCA)并增设小尺度检测头,加强了对小型目标的检测关注度。针对铝型材缺陷检测,孙铁强等^[7]提出基于改进YOLOv8n的表面小目标缺陷检测方法,通过优化模型结构提升了小目标检测能力,但未对复杂光照下的特征混淆问题进行优化。YIN等^[8]提出了边界框加权(bounding box weighted, BBW)YOLO网络算法,在常规场景下表现良好,但在逆光条件下稳定性欠佳。景会成等^[9]基于改进YOLOv12开展研究,虽提升了检测精度,但轻量化程度仍显不足。SE注意力机制(squeeze and excitation module)通过建模通道间的依赖关系,能够自适应地强化关键特征通道、抑制冗余信息,因其结构轻量、易于嵌入的优势,已成为缺陷检测模型优化中的常用手段。例如,闵芮等^[10]将其与Ghost Bottleneck模块结合,重构了YOLOv8n的主干网络,在降低模型复杂度的同时,提升了钢材缺陷的检测精度。GUNUKULA等^[11]将SE与ResNet结合,应用于AI生成图像检测任务,通过通道特征校准增强了模型鲁棒性。WANG等^[12]在双骨干网络中引入SE模块,优化了钢材缺陷检测效果,验证了SE在特征筛选方面的有效性。

然而,现有研究中将SE注意力机制应用于铝

型材反光表面缺陷检测的工作相对较少,且多数研究未能充分考虑铝型材缺陷的特殊性,导致SE模块的优化潜力尚未充分发挥。此外,在SE与YOLO系列模型的融合研究中,存在模块嵌入位置不合理、与多尺度特征融合适配不足等问题,制约了检测性能的进一步提升。因此,作者提出一种改进的YOLOv8n模型。该模型在YOLOv8n的颈部网络中嵌入SE注意力机制^[13],以增强关键特征的提取能力,并结合多尺度特征融合策略,发挥YOLOv8n的多尺度检测优势^[14],进一步提升对不同尺寸缺陷的识别效果。同时,通过对比不同YOLO模型与SE、卷积块注意力模块(convolutional block attention module, CBAM)等注意力机制在特定缺陷类型上的检测结果,探究不同注意力模块的优化侧重点。

1 YOLOv8n 模型

YOLOv8n 算法结构见图 1,主要包括 Backbone(骨干网络)、Neck(颈部网络)以及 Head(检测头)三部分。




图1 YOLOv8n模型架构

Fig.1 YOLOv8n model architecture

Backbone负责提取图像特征,在逐步降低分辨率的同时增加通道数,包括用于输入原始图像预处理的Input模块、初步提取低阶特征的Conv卷积模块、通过多个Bottleneck分支进行深度特征提取的C2f模块,以及在不改变分辨率的前提下扩展感受野、提升特征表达能力的SPPF模块。Neck部分负责多尺度特征融合,通过Upsample模块上采样、Concat操作整合特征,再经下采样输出,并由C2f模块进一步对融合后的特征进行增强和细

化。Head部分执行目标检测任务,基于Neck输出的多尺度特征完成分类与位置回归预测。其中,Conv卷积模块用于调整特征通道数至检测头所需的预测维度,最终由Detect模块生成检测结果。

该模型的关键优势在于其轻量化设计:通过控制Depth(Bottleneck数量)和Width(通道数缩放)调整模型规模,并利用80×80像素(小目标)、40×40像素和20×20像素(大目标)3组特征图进行多尺度检测^[15-18],以增强对不同尺寸缺陷的识别能力。同时引入解耦检测头,进一步提升检测精度。

试验选用YOLOv8n模型作为缺陷检测模型,兼顾检测精度与实时性,具体参数见表1。其中,Depth为全局控制参数,通过缩放模型重复模块的层数来平衡模型复杂度与推理效率;Width同样是全局参数,通过调节各层特征图的通道数来权衡特征表达能力与计算量;Max_channels用于限制各层通道数的上限,避免因局部通道过度扩张而产生冗余。此外,T_Depth以元组形式局部控制关键子模块(如Neck层的多尺度融合分支或Head层的解耦分支)的重复层数,从而针对性优化多尺度缺陷检测性能;T_width同样以元组形式对相应子模块的特征图通道数进行局部调节,确保多尺度特征具备良好的兼容性与可学习性。

表1 YOLOv8n模型参数
Tab.1 YOLOv8n model parameters

参数	取值
深度因子(Depth)	0.33
宽度因子(Width)	0.25
最大通道数(Max_channels)	1 024
子模块深度(T_Depth)	(1,2,2,1)
子模块宽度(T_width)	(64,128,256)

2 改进的YOLOv8n算法

2.1 SE注意力机制

SE注意力机制是一种通过建模通道间依赖关系来增强模型特征表达能力的经典方法,其主要作用是强化模型对关键特征通道的关注,其结构见图2。该机制首先对输入特征图进行全局平均池化,随后经过降维全连接层(fully connected layer, FC)、ReLU激活函数、升维全连接层以及对通道权重的归一化处理,最终通过缩放操作输出优化后的特征。该机制能够提升小目标及模糊目标的检测能力,同时轻量化设计有助于降低计算成本,适用于工业缺陷检测等高精度、实时性要求较高的任务。




图2 SE注意力机制模块结构

Fig.2 structural diagram of the SE attention mechanism

SE注意力机制算法流程见图3。该方法通过压缩空间维度以提取全局信息,再经变换校准通道权重,对特征图各通道的权重进行调整,从而使模型更加聚焦于关键特征,减少无效信息的干扰。其压缩(Squeeze)步骤如下:输入特征图 U (维度为 $C \times W \times H$),经过全局平均池化操作 F_{sq} ,将空间维度 $W \times H$ 压缩为 1×1 ,生成通道描述符(维度为 $1 \times 1 \times C$),用以聚合各通道的全局信息。计算式为

$$Z_c = F_{sq}(U_c) = \frac{1}{WH} \sum_{i=1}^W \sum_{j=1}^H U_c(i, j), \quad (1)$$

式中: Z_c 为第 c 个通道经全局平均池化后的通道描述符; $F_{sq}(\cdot)$ 为全局平均池化操作函数; U_c 为输入特征图 U 的第 c 个通道(维度为 $W \times H$); W 、 H 分别为输入特征图的宽度和高度; i 、 j 分别为特征图空间维度的列、行索引。

激励(Excitation)步骤为:压缩后通道特征经激励函数 F_{ex} 处理,输出与原通道数一致的权重向量 S (维度为 $1 \times 1 \times C$),实现通道权重的校准,计算式为

$$S = F_{ex}(Z, W) = \delta(W_2 \sigma(W_1 Z)), \quad (2)$$

式中: $F_{ex}(\cdot)$ 为激励操作函数; Z 为压缩步骤生成的通道描述符向量(维度为 $1 \times 1 \times C$); W 为全连接层参数矩阵,其中 W_1 、 W_2 分别为升维、降维全连接层参数矩阵; $\sigma(\cdot)$ 为ReLU激活函数; $\delta(\cdot)$ 为Sigmoid激活函数。

缩放(Scale)步骤为:将校准后的权重向量 S 经缩放操作 F_{sc} 与原特征图 U 逐通道相乘,完成对特征的注意力加权,输出增强后的特征 $\hat{X}$ 。计算式为

$$U'_c = F_{sc}(U_c, S_c) = S_c \cdot U_c, \quad (3)$$

式中: U'_c 为增强后特征图的第 c 个通道(维度为

$W \times H$); $F_{sc}(\cdot)$ 为逐通道缩放操作函数; U_c 为原特征图的第 c 个通道; S_c 为校准后权重向量 S 中对应第 c 个通道的权重值; “ $\cdot$ ” 表示逐元素相乘运算。




图3 SE注意力机制算法流程

Fig.3 flow of the SE attention mechanism algorithm

2.2 结合SE的YOLOv8n

基于SE的结构简单灵活、计算轻量高效的特点,将SE注意力机制嵌入YOLOv8n的颈部网络^[19],以实现铝型材缺陷高精度检测,其模型架构见图4。




图4 YOLOv8n+SE模型架构

Fig.4 YOLOv8n+SE model architecture

将SE注意力机制与YOLOv8n相结合,能够有效增强特征表达能力,突出关键通道特征并抑制无关或冗余通道,从而减少无效特征的干扰。提升网络的自适应学习能力。例如,在面对不同光照条件下的目标检测任务时,SE机制可通过动态调整模型对各通道的关注程度,保持检测性能的稳定。

SE注意力机制帮助YOLOv8n更有效地筛选有用特征,并将计算资源集中于关键区域。一方面,它能够增强重要特征的显著性,促进多尺度目标特征的融合与传递;另一方面,该机制可针对性提升小目标的识别能力,在遮挡严重、光照多变等复杂场景下鲁棒性更强,同时其轻量化设计避免了模型运行速度的显著下降,有助于在检测精

度与推理效率之间实现更优平衡,从而提升模型的综合性能与泛化能力。

3 试验设计与结果分析

3.1 数据集建构与标注

试验使用公开的天池铝型材表面瑕疵识别数据集,该数据集涵盖了强光直射、逆光、高光等工业常见光照场景,涉及多种铝型与缺陷类型,且存在多缺陷共存、相似缺陷易混淆(如凹陷与起坑)等情况。筛选1500张表面缺陷图片,涵盖6种常见缺陷类型(凹陷、涂层开裂、桔皮、不导电、起坑,及凸粉,见图5)。将选取的图片按8:1:1的比例划分为训练集、验证集和测试集。为提升模型泛化能力,试验采用随机旋转、随机缩放、亮度与对比度调整、反光模拟以及多尺度训练等数据增强方法^[20],并在预处理阶段引入光照归一化以降低光照干扰,同时结合模型颈部引入的SE注意力机制强化对缺陷核心特征的筛选,应对光照不一致问题。




图5 铝型材缺陷类型

Fig.5 defect types of aluminum profiles

在进行模型训练前,对收集到的数据集进行预处理与标注。原始图像分辨率为2592×1944像素,训练时将其标准化为640×640像素输入尺寸,并进行光照归一化处理与敏感信息去除。

使用LabelImg完成数据标注,主要采用矩形边界框对每个缺陷区域进行独立标注。数据集中缺陷像素的跨度为5×5像素(如微小起坑)至全图范围(如大面积涂层开裂、凹陷),基本覆盖了工业场景中常见的缺陷尺寸。

为应对跨尺寸检测需求,模型基于YOLOv8n原有的多尺度检测架构(80×80像素、40×40像素、20×20像素3组特征图),分别适配小、中、大尺寸缺陷^[21-22],并结合颈部网络中的SE注意力机制强化对不同尺度特征的筛选能力,从而提升跨尺寸特征的区分性能。

3.2 模型训练与评估

试验在 Windows 操作系统下开展，具体参数配置见表 2。模型初始图像尺寸为 640×640 像素，训练迭代次数设置为 700 轮。在完成数据预处理和标注之后开始进行模型训练，训练参数见表 3。

Tab.2 environmental parameter configuration	
环境参数	配置说明
操作系统	Windows 11 64 位
硬件平台	CPU: Intel i7-14700KF/GPU: RTX 4090
编译器	Pycharm2024 专业版
算法框架	PyTorch 2.0.0+Python 3.12.3+Cuda 12.4

Tab.3 main training parameters	
参数	取值
初始学习率	0.000 5
最终学习率	0.01
置信度阈值	0.3
IoU 阈值	0.5
热身训练轮数	5.0
权重衰减	0.000 1
早停机制	80.0

实验采用准确率 P (precision)、召回率 R (recall)、平均精度均值 (mAP) 作为评价指标，用于评估模型的检测精度；同时使用参数量 (parameters) 和浮点运算量 (GFLOPS) 来衡量模

型的轻量化性能及检测效率。
各评价指标的计算公式^[23]分别为

$$P = \frac{TP}{TP + FP}, \tag{4}$$

$$R = \frac{TP}{TP + FN}, \tag{5}$$

$$mAP = \frac{1}{C} \sum_{i=1}^C AP_i, \tag{6}$$

式 (4) ~ 式 (6) 中：TP 为正确预测的正类样本数；FP 为被误判为正类的负类样本数；FN 为被误判为负类的正类样本数； C 为缺陷检测中的类别总数； AP_i 为第 i 个类别的平均精度。根据 IoU 阈值不同，试验分别采用 $mAP_{0.5}$ 与 $mAP_{0.5:0.95}$ 对模型进行评价。

参数量和浮点运算量的计算公式分别为

$$P_{total} = \sum_{l=1}^n P_l, \tag{7}$$

$$GFLOPS = \frac{F_{total}}{10^9 t}, \tag{8}$$

式 (7)、式 (8) 中： n 为所有网络层的层数； P_l 为单个 layer 网络层的参数量； F_{total} 为模型总浮点运算次数； t 为单次前向推理时间。

在模型训练阶段，通过对比模型预测结果与真实标注之间的差异损失^[24-26]（包括定位损失、分类损失及分布式定位损失），明确模型优化方向。在训练过程中，通过监测损失函数的变化情况评估模型收敛情况，最终以 mAP 等指标综合评价模型性能。训练过程中的损失变化见图 6。




图6 损失函数

Fig.6 loss function

由图6可见,随着迭代次数增加,训练集与验证集的定位损失、分类损失及分布式定位损失均逐渐收敛并趋于平稳。训练中采用了学习率调整、数据增强和早停机制等策略,当验证集 mAP 连续 80 轮未提升,即提前终止训练以避免过拟合。

F1 分数是评估模型性能的综合指标,用于平衡精确率与召回率,其值越趋近于 1 则表明模型的综合性能表现越佳,计算式为

$$F1 = \frac{2PR}{P+R} \quad (7)$$

训练完成后, F1 分数反映了模型在不同置信度阈值下的预测表现,如图 7 所示。图 7 中“全部类别 0.70/0.399”表示当置信度阈值设置为 0.399 时,所有类别的平均 F1 分数达到了 0.70。该点 (0.399, 0.70) 可作为当前模型的最佳阈值选择参考,能在精度和召回之间实现良好平衡。




图 7 不同置信度下的 F1

Fig.7 F1 under different confidence thresholds

由图 7 可见,置信度阈值处于 0.2~0.4 时,各类别 F1 分数均大于 0.6。当置信度阈值超过 0.6 后,多数类别的 F1 分数快速跌落至 0.2 以下。这反映了置信度阈值与模型精度、召回率之间的权衡关系。降低阈值会扩大模型的识别范围,提升召回率,但同时会纳入低置信度的疑似样本,增加误检风险。升高阈值则会收缩识别范围,可减少误检,却会遗漏部分低置信度的真实缺陷,导致召回率下降。因此,在实际应用中可根据具体需求选择合适的置信度阈值。

为验证所提出的 YOLOv8n+SE 模型对铝型材表面缺陷的检测性能,实验选取包含涂层开裂等缺陷类别的铝型材工件数据集开展训练与测试。结果见表 4。在各类缺陷中,涂层开裂因边界清晰、与背景对比度高,且多呈现连续分布的条状纹理,SE 注意力机制能够迅速识别其高辨识度的

通道特征,并通过强化相应特征通道的权重,实现精准定位与低漏检,使其召回率 (0.818) 和精确率 (1.000) 在所有类别中最高。凸粉缺陷的 F1 分数最低 (0.471),主要由于其表面多为微小凸起的粉末状区域,颜色与铝型材基底高度相似,特征辨识度极低,SE 机制难以从复杂背景中筛选出有效特征,导致漏检率高、误判频发。

表 4 模型评估结果

Tab.4 model evaluation results					
类别	目标框数	P	R	mAP _{0.5}	mAP _{0.5:0.95}
整体	211	0.763	0.661	0.750	0.449
涂层开裂	11	1.000	0.818	0.909	0.653
凹陷	20	0.788	0.743	0.807	0.276
不导电	95	0.860	0.684	0.811	0.507
桔皮	18	0.580	0.778	0.781	0.680
起坑	45	0.800	0.533	0.704	0.373
凸粉	22	0.551	0.409	0.485	0.203

注:图像数为 209。

凹陷缺陷由于表面阴影形成的空间结构特征,在通过 SE 强化阴影区域响应后,检测精度较高,漏检率较低。不导电缺陷因无明显视觉边界、特征信号较弱,SE 虽能强化有效通道,但在低对比度区域仍难以区分背景噪声与真实缺陷,召回率偏低。桔皮缺陷具有细微弥散性纹理且轮廓不明确,SE 对这类分散特征的筛选能力有限,部分背景纹理被误判,导致精确率降低。起坑缺陷与凹陷特征相似,但尺寸更小、深度更浅,特征信息易被背景掩盖,SE 对小尺寸、低显著性特征的捕捉不足,因此召回率显著低于精确率。

结合工业场景对检测效率的需求,为进一步验证模型工业化应用潜力,实验基于 NVIDIA GeForce RTX4090 硬件环境开展检测效率测试,模拟铝型材在线连续检测工况进行性能验证。在 640×640 分辨率下,测得模型单张图片推理耗时 4.60 ms、全流程耗时 4.90 ms,检测帧率 (FPS) 达每秒 217.39 帧,每小时理论检测效率超 78 万件,满足铝型材产线高速检测需求。

3.3 模型对比

为验证 SE 注意力机制对 YOLOv8n 模型检测性能的提升效果,采用控制变量法,在保持模型基础架构、训练超参数、数据集等条件一致的前提下,对比原模型与嵌入 SE 注意力机制后的模型在检测精度、参数量、计算复杂度等指标上的差异。选取 Faster R-CNN 作为传统目标检测模型, YOLOv5n 等作为同系列轻量级目标检测模型^[27-28]

并结合不同的模块机制。由表5可知,改进后的YOLOv8n+SE模型性能优于其他模型:在 $mAP_{0.5}$ 指标上,YOLOv8n+SE模型较YOLOv5n+SE模型提升15.4%、较YOLOv11n+SE模型提升29.3%,较YOLOv12+SE模型提升33.9%;参数量仅为YOLOv11n模型的55.2%、YOLOv11n+CBAM模型的42.9%;计算复杂度仅为传统算法Faster R-CNN模型的6%,推理效率大幅提升,在实时性方面可有效满足工业需求。

表5 模型性能对比
Tab.5 model performance comparison

模型	$mAP_{0.5}$	参数量/M	计算复杂度/GFLOPS
YOLOv8n	0.72	11.13	28.4
YOLOv8n+SE	0.75	11.13	28.5
YOLOv5n	0.66	2.50	7.1
YOLOv5n+SE	0.65	2.57	7.1
YOLOv11n	0.57	20.18	66.4
YOLOv11n+SE	0.58	3.59	11.1
YOLOv11n+CBAM	0.64	25.92	87.8
YOLOv12n	0.66	1.38	5.3
YOLOv12n+SE	0.56	1.54	6.6
Faster R-CNN	0.64	28.48	474.2

同时,对于精准度、召回率以及 $mAP_{0.5}$,YOLOv5n模型与SE结合后对凹陷缺陷的检测结果分别提升12.2%、17%和20.6%;YOLOv11n和YOLOv12n模型与SE结合后,对不导电缺陷的检测精度不减反降,而YOLOv8n模型与SE结合则使对不导电缺陷的召回率和 $mAP_{0.5}$ 得到一定提升。

对于凹陷、不导电缺陷,通过结合SE注意力机制,可强化有效特征通道点,降低易混淆缺陷的定位与分类难度,从而提升检测精度。对于涂层开裂缺陷,可融合CBAM注意力机制,利用其通道、空间双维度精准定位的优势,解决涂层开裂缺陷空间分布复杂以及多尺度缺陷的问题。对于桔皮、凸粉等缺陷类型,可通过YOLO系列模型的版本迭代,提升基础特征提取能力,解决小目标、难区分缺陷的问题。YOLOv8n模型结合SE可强化有效特征通道的信息传递,显著改善训练结果;YOLOv11n模型与SE结合易出现功能重叠,导致训练增益较小,但与CBAM结合可补充空间细节,有效改善训练结果。

表5中,较原始YOLOv11n模型,YOLOv11n+SE模型的参数量显著下降,并非为SE模块作用的结果,SE仅校准通道权重并不减少参数。参数下降的核心原因在于,嵌入SE模块时完成了网络通道维度的精准适配优化。原始YOLOv11n模型的

通道配置虽遵循Width为0.25缩放规则,但层间存在未完全精简的冗余预留,导致参数量偏高。而YOLOv11n+SE模型严格按缩放后实际通道数匹配SE模块输入维度,优化模块间通道衔接并剔除冗余参数,同时结合C3k2、C2PSA等轻量化基础模块,最终实现了通道优化与SE特征校准的功能互补。

3.4 目标缺陷检测对比

铝型材表面缺陷检测结果对比见图8。在相同检测任务中,YOLOv8n+SE模型对不导电、桔皮等缺陷的识别更为精准,漏检情况显著减少,检测边界框定位也更加准确。




图8 铝型材表面缺陷检测结果

Fig.8 surface defect detection results of aluminum profiles

4 结论

YOLOv8n+SE铝型材表面缺陷检测方法,有效解决了传统检测模式在多样化缺陷识别与实时性方面的不足,核心优势集中于检测精度与轻量化特性的协同优化。该模型通过引入SE注意力机制,显著增强了对铝型材反光曲面关键缺陷特征的捕捉能力,在保持11.13 M参数量不变的前提下, $mAP_{0.5}$ 提升至0.75,相对提升4.2%,对凹陷、起坑等易混淆缺陷的类间区分能力明显优化,满足工业应用的精度要求。与现有主流模型相比,YOLOv8n+SE模型的计算复杂度仅为28.5 GFLOPS,展现出更优的检测效率与部署灵活性,为铝型材自动化质检提供了高效可靠的技术方案,且可通过适配调整拓展至其他工业材料的缺陷检测场景。研究同时明确了不同YOLO系列模型与注意力机制的适配规律及适用场景,为工业质检场景的模型选型提供了参考依据。

此外,本研究仍存在极端光照条件下检测稳定性不足、对新型缺陷零样本学习能力有限等局限,未来可通过多模态数据融合、迁移学习等技

术进一步提升模型的鲁棒性与泛化能力。

参考文献(References):

- [1] 曾勇杰, 范必双, 杨涯文, 等. 改进 YOLOv8 算法在风机叶片缺陷检测上的应用[J]. 电子测量与仪器学报, 2024, 38(8): 26-35.
ZENG Yongjie, FAN Bishuang, YANG Yawen, et al. YOLOv8 algorithm is improved in the defect detection of wind turbine blades applications[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 26-35.
- [2] TERVEN J, CORDOVA-ESPARZA D M, ROMERO-GONZÁLEZ J A. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS[J]. Machine Learning and Knowledge Extraction, 2023, 5(4): 1680-1716.
- [3] JIANG P Y, ERGU D, LIU F Y, et al. A review of yolo algorithm developments[J]. Procedia Computer Science, 2022, 199: 1066-1073.
- [4] 陈万志, 张春光. 改进 YOLOv5 模型的带钢表面缺陷检测方法[J]. 辽宁工程技术大学学报(自然科学版), 2024, 43(3): 359-365.
CHEN Wanzhi, ZHANG Chunguang. Surface defect detection method of strip steel by improved YOLOv5 model[J]. Journal of Liaoning Technical University (Natural Science Edition), 2024, 43(3): 359-365.
- [5] 彭继慎, 马龙泽, 孙梦宇, 等. 多尺度特征融合增强检测模型 MFFE-YOLO[J]. 辽宁工程技术大学学报(自然科学版), 2024, 43(5): 625-632.
PENG Jishen, MA Longze, SUN Mengyu, et al. A multi-scale feature fusion enhanced detection model MFFE-YOLO[J]. Journal of Liaoning Technical University (Natural Science Edition), 2024, 43(5): 625-632.
- [6] 王明涛. 基于改进 YOLOv8 算法的锯材表面缺陷检测研究与系统设计[D]. 呼和浩特: 内蒙古农业大学, 2024: 38-54.
- [7] 孙铁强, 刘俊, 宋超, 等. 基于改进 YOLOv8n 的铝型材表面小目标缺陷检测方法[J]. 现代制造工程, 2024(12): 120-129.
SUN Tieqiang, LIU Jun, SONG Chao, et al. A small target defect detection method for aluminum profile surface based on improved YOLOv8n[J]. Modern Manufacturing Engineering, 2024(12): 120-129.
- [8] YIN Z J, LI H C, QI B, et al. BBW YOLO: intelligent detection algorithms for aluminium profile material surface defects[J]. Coatings, 2025, 15(6): 684.
- [9] 景会成, 鲍成明. 基于改进 YOLOv12 的铝型材工件缺陷检测技术研究[J]. 电子测量技术, 2026, 49(1): 216-225.
JING Huicheng, BAO Chengming. Research on defect detection technology of aluminum profile workpiece based on improved YOLOv12[J]. Electronic Measurement Technology, 2026, 49(1): 216-225.
- [10] 闵芮, 方凯, 陈娟, 等. 基于改进 YOLOv8n 的钢材表面缺陷检测方法[J]. 物联网技术, 2025, 15(17): 30-36.
MIN Rui, FANG Kai, CHEN Juan, et al. Steel surface defect detection method based on improved YOLOv8n[J]. Internet of Things Technologies, 2025, 15(17): 30-36.
- [11] GUNUKULA A R, DES GUPTA H, SHENG V S. Detecting AI-generated images using a hybrid ResNet-SE attention model[J]. Applied Sciences, 2025, 15(13): 7421.
- [12] WANG X Y, MA S H, WU S T, et al. Detection of surface defects in steel based on dual-backbone network: MBDNet-attention-YOLO[J]. Sensors, 2025, 25(15): 4817.
- [13] XIONG J H, LI P G, SUN Y, et al. An aircraft skin defect detection method with UAV based on GB-CPP and INN-YOLO[J]. Drones, 2025, 9(9): 594.
- [14] XU Y M, ZHANG K, WANG L. Metal surface defect detection using modified YOLO[J]. Algorithms, 2021, 14(9): 257.
- [15] CHEN Q P, XIONG Q Q, HUANG H S, et al. An efficient and lightweight surface defect detection method for micro-motor commutators in complex industrial scenarios based on the CLS-YOLO network[J]. Electronics, 2025, 14(3): 505.
- [16] MA H T, ZHANG Z S, ZHAO J N. A novel ST-YOLO network for steel-surface-defect detection[J]. Sensors, 2023, 23(22): 9152.
- [17] YANG D L, MA C S, YU G T, et al. Automatic defect detection of pipelines based on improved OFG-YOLO algorithm[J]. Measurement, 2025, 242: 115847.
- [18] CHEN R X, CAI D Y, HU X L, et al. Defect detection method of aluminum profile surface using deep self-attention mechanism under hybrid noise conditions[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3524509.
- [19] BIN F, HOU F, CHEN D, et al. BCM-YOLO: an improved YOLOv8-based lightweight porcelain insulator defect detection model[J]. High Voltage, 2025, 10(4): 876-889.
- [20] XIE Y F, HU W T, XIE S W, et al. Surface defect detection algorithm based on feature-enhanced YOLO[J]. Cognitive Computation, 2023, 15(2): 565-579.
- [21] FENG Y F, HUANG J G, DU S Y, et al. Hyper-YOLO: when visual object detection meets hypergraph computation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(4): 2388-2401.
- [22] HUANG J H, ZHANG X L, JIA L J, et al. An improved you only look once model for the multi-scale steel surface defect detection with multi-level alignment and cross-layer redistribution features[J]. Engineering Applications of Artificial Intelligence, 2025, 145: 110214.
- [23] ZHOU S Y, ZENG Y L, LI S C, et al. Surface defect detection of rolled steel based on lightweight model[J]. Applied Sciences, 2022, 12(17): 8905.
- [24] YU L Z, ZHU J H, ZHAO Q, et al. An efficient YOLO algorithm with an attention mechanism for vision-based defect inspection deployed on FPGA[J]. Micromachines, 2022, 13(7): 1058.
- [25] ZHOU Y. A YOLO-NL object detector for real-time detection[J]. Expert Systems with Applications, 2024, 238: 122256.
- [26] LI J Y, SU Z F, GENG J H, et al. Real-time detection of steel strip surface defects based on improved YOLO detection network[J]. IFAC-PapersOnLine, 2018, 51(21): 76-81.
- [27] 马俊杰, 张继红, 王强, 等. 基于改进 YOLOv11 的带钢表面缺陷检测算法[J]. 钢铁研究学报, 2025, 37(10): 1345-1358.
MA Junjie, ZHANG Jihong, WANG Qiang, et al. Strip surface defect detection algorithm based on improved YOLOv11[J]. Journal of Iron and Steel Research, 2025, 37(10): 1345-1358.
- [28] LU L H, CHEN Z C, WANG R F, et al. Yolo-inspection: defect detection method for power transmission lines based on enhanced YOLOv5s[J]. Journal of Real-Time Image Processing, 2023, 20(5): 104.