

## 基于改进 YOLOv8s 的铝型材表面缺陷检测

侯宪庆,黎远松,石睿,王涛

四川轻化工大学 计算机科学与工程学院,四川 宜宾 644000

**摘要:**目的 针对铝型材表面缺陷类别多,缺陷之间差异较大,容易出现漏检、误检等情况,提出一种改进的 YOLOv8s 检测算法。方法 首先,引入扩张式残差模块 DWR(Dilation-wise Residual),基于此重新构造主干网络部分 C2f 中的 Bottleneck 结构,增强网络对复杂特征的提取能力,使网络更高效地获取上下文信息;其次,在原颈部网络中加入小目标检测层,旨在提取和传递那些在小尺寸缺陷中更为关键且判别性更强的小目标特征信息,将浅层和深层特征进行融合,降低漏检率和误检率,提高检测精度;最后,引入 Inner-GIoU(Inner Generalized Intersection over Union) 损失函数,关注边界框内部的重叠部分,加快模型收敛速度的同时提高边界框回归的准确性。结果 将改进算法应用在天池铝型材数据集中,实验结果显示:改进的算法在精确率、召回率和 mAP@0.5 方面分别达到了 88.7%、83.4%和 88.5%的性能指标,相比原始的 YOLOv8s 算法分别提高了 4.1%、2.1%和 2.9%,改进算法能有效识别铝型材表面不同类型的缺陷。结论 通过实验可以证明改进算法的有效性,改善了铝型材部分缺陷检测效果较差的问题,同时减少了漏检和误检情况,满足当前工厂对铝型材表面缺陷的检测要求。

**关键词:**缺陷检测;YOLOv8s;深度学习;Inner-GIoU

**中图分类号:**TP391.41;TG146.21 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2026.0002.015

### Surface Defect Detection of Aluminum Profiles Based on Improved YOLOv8s

HOU Xianqing, LI Yuansong, SHI Rui, WANG Tao

School of Computer Science and Engineering, Sichuan University of Science & Engineering, Yibin 644000, Sichuan, China

**Abstract: Objective** Aiming at the problems that there are many types of surface defects on aluminum profiles and significant differences among these defects, which may easily lead to missed detections and false detections, an improved YOLOv8s detection algorithm is proposed. **Methods** First, the dilation-wise residual (DWR) module was introduced. Based on this, the Bottleneck structure in the C2f of the backbone network was reconstructed to enhance the network's ability to extract complex features and enable the network to obtain context information more efficiently. Second, an additional layer for detecting small targets was integrated into the existing neck network, which aimed to extract and transmit the small target feature information that was more critical and discriminative in small-sized defects. The shallow and deep features were fused to reduce the missed detection rate and false detection rate and improve the detection accuracy. Finally, the inner generalized intersection over union (Inner-GIoU) loss function was introduced to focus on the

**收稿日期:**2024-05-10 **修回日期:**2024-09-22 **文章编号:**1672-058X(2026)02-0116-09

**基金项目:**国家自然科学基金项目资助(42374227,42074218)。

**作者简介:**侯宪庆(1999—),男,山东菏泽人,硕士研究生,从事目标检测研究。

**通信作者:**黎远松(1970—),男,四川自贡人,教授,从事信息安全与深度学习等研究。Email: yuansongli@suse.edu.cn.

**引用格式:**侯宪庆,黎远松,石睿,等.基于改进 YOLOv8s 的铝型材表面缺陷检测[J].重庆工商大学学报(自然科学版),2026,43(2):116-124.

HOU Xianqing, LI Yuansong, SHI Rui, et al. Surface defect detection of aluminum profiles based on improved YOLOv8s[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(2): 116-124.

overlapping part inside the bounding box, accelerating the model's convergence speed while improving the accuracy of bounding box regression. **Results** The improved algorithm was applied to the Tianchi aluminum profile dataset. The experimental results showed that the performance indicators of the improved algorithm in terms of precision, recall, and mAP@0.5 reached 88.7%, 83.4%, and 88.5%, respectively. Compared with the original YOLOv8s algorithm, these values were increased by 4.1%, 2.1%, and 2.9%, respectively. The improved algorithm can effectively identify different types of defects on the surface of aluminum profiles. **Conclusion** The effectiveness of the improved algorithm is verified by experiments. This improved algorithm solves the problem of poor detection results for some aluminum profile defects, reduces missed and false detections, and meets the current requirements of factories for detecting surface defects on aluminum profiles.

**Keywords:** defect detection; YOLOv8s; deep learning; Inner-GIoU

随着我国基础设施投资需求的不断增长和工业化的迅速发展,铝型材因其高强度、耐腐蚀、低密度、使用寿命长等优点,在汽车制造、轨道交通、航空航天等行业得到了广泛应用。在生产和运输过程中,铝型材可能会出现各种缺陷,这些缺陷导致在使用过程中存在安全隐患,因此,快速准确地检测出铝型材缺陷至关重要。

近年来,视觉检测技术凭借其出色的识别精度和可靠的检测性能,逐步替代了传统的人工检测手段。在视觉检测技术中,存在两大主流方法:一种是通过传统图像处理技术结合机器学习算法进行检测,另一种是以卷积神经网络为核心的深度学习方法。

基于传统图像处理的机器学习方法主要通过传统算子提取图像特征,例如使用 GLCM (Gray-Level Co-occurrence Matrix) 算法提取铝型材的纹理特征,以及 Gabor 小波变换等技术。然而,这些方法在处理单张图片中存在的多种缺陷类型时,无法同时准确识别所有类型的缺陷。屈等<sup>[1]</sup>针对传统 Gabor 滤波器处理速度缓慢且参数众多的情况,改进一种复合差分进化滤波器优化策略,该策略对 Gabor 滤波器的参数及其方向进行了优化,提升了 Gabor 模型的实时检测速度。尽管传统图像检测方法能够有效识别金属表面的各种缺陷,但需要根据金属种类和缺陷类型进行手动设置,而且检测结果会受到人工提取特征的影响,在面对相对复杂的生产环境以及多样性的缺陷种类时,金属缺陷检测的稳定性受到影响。

随着人工智能技术的迅猛进步,深度学习在工业缺陷检测领域的应用已日趋普遍。

当前,缺陷检测方法主要可以分为两类:一类是采用区域卷积神经网络 R-CNN<sup>[2]</sup>和 Faster R-CNN<sup>[3]</sup>等两阶段检测算法,另一类是采用 SSD (Single Shot MultiBox

Detector)<sup>[4]</sup>和 YOLO (You Only Look Once)<sup>[5]</sup>等单阶段检测算法。深度学习在铝型材缺陷检测方面的应用受到了广泛关注。例如,姚等<sup>[6]</sup>通过改进 YOLOv3 算法,即通过调整网络结构和增加残差单元,来优化铝型材表面缺陷的检测效果,提升了网络对特征的利用能力;Liu 等<sup>[7]</sup>提出一种创新性的双 CNN 模型融合方法,该方法包含改良的融合层、策略以及分类器,旨在对铝型材的各类缺陷进行更为精确的分类和识别;Neuhauser 等<sup>[8]</sup>运用神经网络识别铝型材表面是否存在缺陷,并成功将该方法应用于视频帧中,实现了对不同缺陷类别的有效识别;Wu 等<sup>[9]</sup>采用 CSPResNeXt 替代 CSPDarkNet,并结合注意力模块,显著提升了模型的分类能力及对多种缺陷的检测精确度;吴等<sup>[10]</sup>通过对铝型材数据集进行扩充,增加模型的预测尺度,从而提高对小缺陷的检测效果。这些研究共同推动了铝型材缺陷检测技术的进步。赵等<sup>[11]</sup>提出一种改进的 YOLOv5s 铝型材表面缺陷检测算法,通过引入自适应加权特征金字塔优化感受野和注意力融合,提高了网络对特征的利用;席等<sup>[12]</sup>在 YOLOv5s 网络中引入 CA 注意力机制和小目标检测层,使网络更好地抑制无效样本的干扰和对小目标缺陷的捕获;邓等<sup>[13]</sup>提出了 KCC-YOLOv5,在主干网络中引入全局注意力模块,增强小目标的语义信息和感知能力,将原上采样方式替换为轻量级上采样算子 CARAFE,进一步提升对铝型材表面缺陷的识别能力。

虽然上述研究方法已经取得了相对满意的检测结果,但仍然面临一些亟待解决的问题。其中,模型的参数量偏大、检测精度有待提高是当前的主要难点。此外,以上单阶段和两阶段方法在处理微弱长条形缺陷和小缺陷时存在明显的漏检问题,这在实际应用中无疑是一个严峻的挑战。再者,目前多数相关研究对于

缺陷类型的探讨还相对单薄,缺乏对多种缺陷类型的深入研究。本文提出的基于 YOLOv8s 的改进算法,有效提高了缺陷检测精度。

本文的主要贡献如下:为了有效提取上下文特征信息,将扩张残差模块 DWR 与主干网络的倒数第一个和倒数第二个 C2f 模块相融;引入小目标检测层,增强网络对小目标缺陷的提取能力;使用 Inner-GIoU 损失

函数,加快模型收敛速度,以提高模型检测精度。

### 1 YOLOv8 网络构建及其改进

#### 1.1 YOLOv8s 网络结构

YOLOv8 目标检测模型是在 YOLOv5 基础上进行的优化升级,包括 n、s、m、l、x 共 5 个版本。YOLOv8s 模型主要包括主干网络(Backbone)、颈部网络(Neck)和检测头(Head)3 个部分,如图 1 所示。

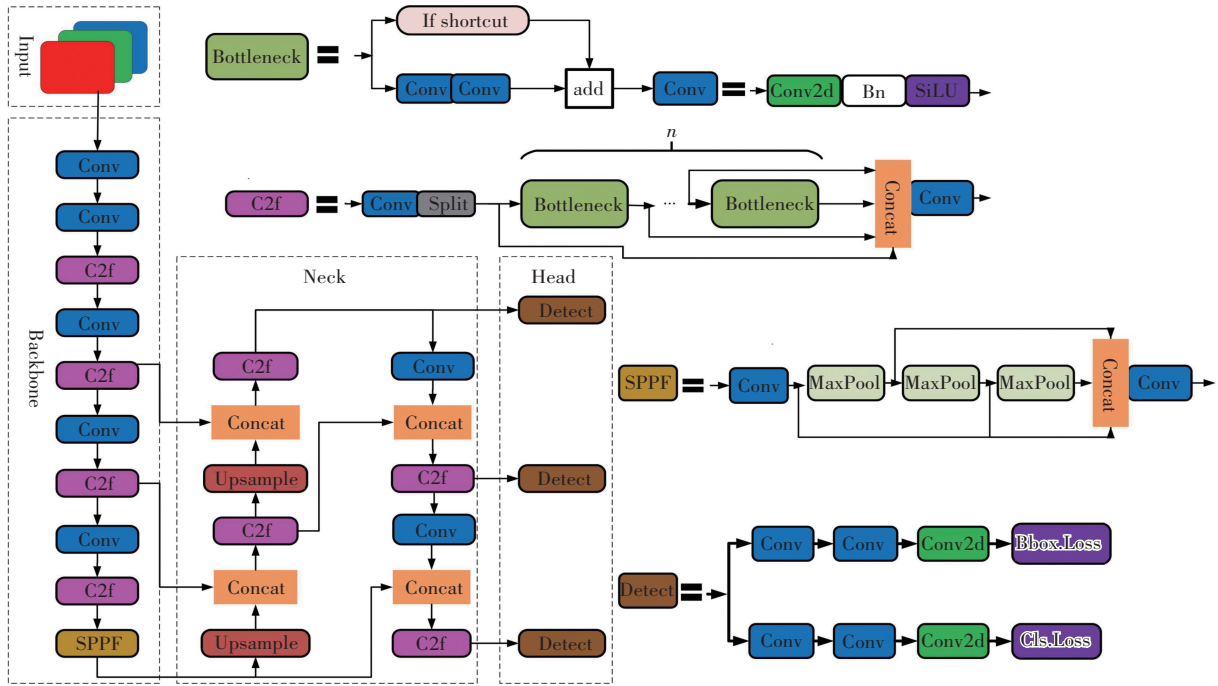


图 1 YOLOv8s 网络结构

Fig. 1 YOLOv8s network structure

输入端进行数据增强以及自适应图片缩放。YOLOv8 的 Mosaic 增强部分引入了 YOLOX 中最后 10 个 epoch 采用的 Mosaic 增强操作,增强了模型的鲁棒性。自适应图片缩放将原始图片统一缩放到同一尺寸,简化了模型复杂度,可以有效提升精度。

主干网络由 Conv、C2f 和 SPPF 等模块构成。Conv 模块主要对特征图进行卷积操作,C2f 模块是提取特征的主要模块,SPPF 用于提取不同感受野特征,这种结构使得网络能更好地适应不同尺度的目标。

颈部网络的核心构造采纳了 FPN-PAN 的架构设计。其中,FPN 即特征金字塔网络,采纳了一种自上而下的结构,它利用上采样技术,实现高层与底层特征信息的有效结合,进而推导出预测所需的特征图。而 PAN,即路径聚合网络,作为对 FPN 的进一步革新,加入了横向连接,不仅丰富了特征的语义内容,还使得自下而上的特征图能够与自上而下的特征图实现更全面的信息整合。这种设计显著提升了特征提取与融合的效率,为后续的预测和分析提供了更为准确和全面的

数据基础。

在检测头层使用轻量化的解耦头替换耦合头,由有锚目标检测代替无锚目标检测。只需对不同尺度特征图的目标中心点和宽高进行回归,极大减少了耗时,最终通过利用来自不同尺度特征图的丰富信息,精确地获取大、中、小尺寸目标物体的分类和位置信息。

#### 1.2 YOLOv8s 网络改进

本文对 YOLOv8 算法的不同版本模型进行了预先的实验验证。基于实验结果及分析,最终选择 YOLOv8s 作为本研究的基础模型。在 YOLOv8 系列算法中,YOLOv8s 展现出相对优越的检测精度与速度。然而,在处理铝型材表面缺陷检测任务时,由于小目标缺陷特征有限,特征信息在网络层容易丢失,且容易受到背景干扰,使得铝缺陷的关键特征难以捕捉。这种情况经常会导致误检和漏检的问题。为了解决这一难题,提出一种改进的 YOLOv8s 检测模型,用于检测 10 种不同类型尺度的铝型材缺陷,提升小目标缺陷的检测精度。改进模型的网络架构如图 2 所示。

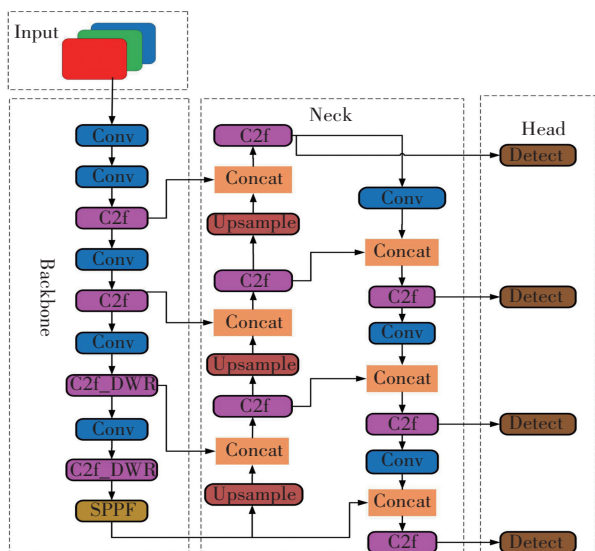


图 2 改进的 YOLOv8s 网络结构

Fig. 2 Structure of improved YOLOv8s network

### 1.2.1 C2f\_DWR 模块

由于铝型材表面缺陷种类多且类别差异大,有些小目标缺陷容易被漏检,细小长纹和点状缺陷检测效果不佳。为了使模型能够更精准地识别和定位目标缺陷,本文引入一种扩张残差模块 DWR (Dilation-wise Residual)。DWR<sup>[14]</sup>模块以剩余方式设计,同时采用残差连接以提升模型的训练稳定性,如图 3 所示。在残差内部,采用两步法高效地绘制多尺度上下文信息,然后融合多尺度感受野生成的特征图。具体来说,将之前的单步多尺度上下文信息获取方法分解为一个两步特征提取方法。

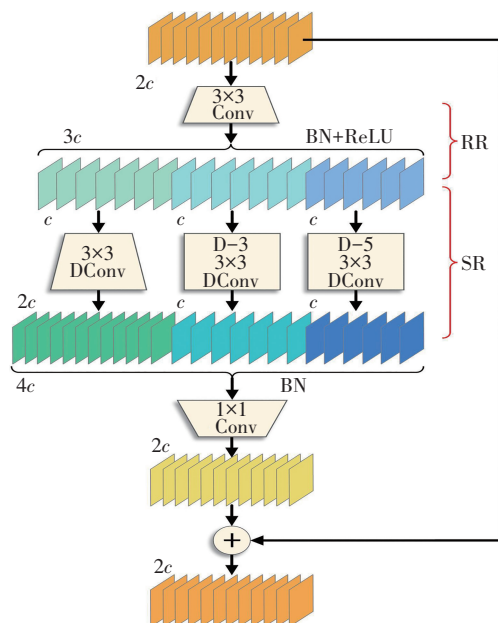


图 3 DWR 结构图

Fig. 3 DWR structural diagram

第一步,首先通过一个标准的  $3 \times 3$  卷积层结合一个批处理规范化层 (Batch Normalization, BN) 和一个 ReLU (Rectified Linear Unit) 激活函数层对输入特征进行初步空间编码。这一层的作用在于提取输入数据的基本特征表示,这一过程被称为区域残差化 (Region Residualization, RR)。第二步,为了捕捉更丰富的上下文信息,模块引入 3 个具有不同膨胀率的  $3 \times 3$  卷积层。这些层能够有效扩大卷积核的感受野,从而捕获到不同尺度的空间结构信息,这一过程称为语义残差化 (Semantic Residualization, SR)。

通过这些多尺度特征在通道维度上进行拼接, DWR 模块能够形成一个全面且多样化的特征集合。为了有效整合这些特征,并减少模型的复杂度,一个  $1 \times 1$  的卷积层被用于降维操作,将拼接后的高维特征映射到一个较低维度的空间。最后,通过引入残差连接,即将降维后的特征与模块的原始输入进行相加。DWR 模块能够实现特征的复用和增强,这不仅有助于梯度的有效传播,还能显著提升模型的训练效率和泛化能力。

基于融合多尺度特征和残差学习的策略与 C2f 模块相融合,其中 Bottleneck 模块被替换为 DWR 模块,构成了新的模块 C2f\_DWR,并替换主干网络的倒数第一个和倒数第二个 C2f 模块。与基准模型相比, C2f\_DWR 模块降低了构建多尺度上下文信息的难度,提高了模型精度,同时降低了模型的参数量,提升了对铝型材表面小目标缺陷的语义信息理解。该模块在保证缺陷检测模型更加高效的同时,能获得更加丰富的梯度流信息,并提高缺陷检测模型计算资源利用率,从而实现缺陷检测整体性能的提升, C2f\_DWR 结构如图 4 所示。




图 4 C2f\_DWR 结构图

Fig. 4 C2f\_DWR structural diagram

### 1.2.2 小目标检测层

在原始的 YOLOv8s 网络中,设置了 3 个检测层级,这些层级分别对应输入图像(尺寸为  $640 \times 640$ )的不同尺度特征图: $80 \times 80$ 、 $40 \times 40$  和  $20 \times 20$ 。这些层级被设计为专门捕捉  $8 \times 8$ 、 $16 \times 16$  和  $32 \times 32$  像素大小的目标。然而,在铝缺陷检测任务中面临一个挑战:当图像中的目标尺寸小于 8 像素时,原始的 YOLOv8s 网络在

检测这些微小目标时表现出明显的局限性,往往导致误检和漏检的情况。

为了克服这一难题,在原始网络的“颈部”引入一个小目标检测层。这个新增的层级提供了一个  $160 * 160$  的特征图,专门用于捕捉  $4 * 4$  像素大小的小目标。该小目标检测层与原有的 8 倍、16 倍和 32 倍下采样层通过 FPN 结构进行了有效整合。通过上采样技术,将高层级的特征信息与低层级的特征信息进行深度融合,从而生成了更为精准的预测特征图。此外还利用 PAN 结构,通过建立横向连接来进一步丰富特征的语义信息,实现跨多个尺度的特征整合。

同时,为了适应新添加的小目标检测层,对检测头进行相应的调整并增加 P2 检测头,如图 5 所示,优化了先验框的尺度和宽高比。这些改进措施不仅显著提高了小目标的检测精度,还优化了目标定位的准确性。因此,在铝缺陷检测检测任务中,由于目标尺寸过小而导致的误检和漏检问题得到了有效缓解。




图 5 小目标检测层和 P2 检测头

Fig. 5 Small object detection layer and P2 detection head

### 1.2.3 Inner-GIoU 损失函数

边界框回归损失函数的计算对目标检测性能至关重要,由于数据集背景和噪音干扰导致原 CIoU 损失函数泛化能力较弱且收敛速度慢,对缺陷识别造成一定的影响,因此将改进的 Inner-GIoU 损失函数替换原损失函数。通过对比预测与真实边界框的差异,模型能精准评估并优化检测准确度,进而提升其泛化能力和鲁棒性。到目前为止,基于 IoU 的损失函数逐渐成为主流和主导,IoU Loss 公式如式(1)所示。其中  $A$  和  $B$  分别表示预测边界框和真实边界框面积大小, $L_{IoU}$  表示 IoU 损失函数值。

$$L_{IoU} = 1 - \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

现有方法大多基于 IoU,并进一步增加新的损失项。当预测框与真实框之间无重叠区域时,IoU 的值为 0,从而无法有效衡量两者之间的距离。GIoU 引入

最小闭包区域,成功克服了这一限制,使得即便在预测框与真实框无重叠的情况下,依然能够为边界框的移动提供明确的指导方向。GIoU Loss<sup>[15]</sup>公式如下所示:

$$L_{GIoU} = L_{IoU} + \frac{|C - A \cup B|}{|C|} \quad (2)$$

式(2)中, $C$ 表示将预测框和真实框围住的最小外接矩形, $L_{GIoU}$ 表示 GIoU 损失函数。如 CIoU、DIoU、SIoU 等一些常见的损失函数通过在 IoU 损失函数中加入新的几何约束,虽然可以加快收敛速度,提高检测性能,但并没有考虑 IoU 自身的限制。Inner-IoU<sup>[16]</sup>提出使用辅助边界框来计算 IoU,以加速回归,而不添加任何新的损失项,其公式如式(3)一式(7)所示。

$$b_l = x_c - \frac{w * r}{2}, b_r = x_c + \frac{w * r}{2} \quad (3)$$

$$b_t = y_c - \frac{h * r}{2}, b_b = y_c + \frac{h * r}{2} \quad (4)$$

其中, $x_c$ 和 $y_c$ 表示预测框的中心点 $x$ 和 $y$ 坐标值,下标 $c$ 表示预测框中心; $h$ 和 $w$ 分别表示预测框的高度和宽度;尺度因子 $r \in [0.5, 1.5]$ ,用来控制辅助边界框的大小;其中 $b_l$ 、 $b_r$ 和 $b_t$ 、 $b_b$ 分别表示预测框左右边界的 $x$ 坐标和预测框上下边界的 $y$ 坐标;下标 $l$ 、 $r$ 分别表示左右,下标 $t$ 、 $b$ 分别表示上下。

$$i = (\min(b_r^{(gt)}, b_r) - \max(b_l^{(gt)}, b_l)) * (\min(b_b^{(gt)}, b_b) - \max(b_t^{(gt)}, b_t)) \quad (5)$$

式(5)中, $b_l^{(gt)}$ 、 $b_r^{(gt)}$ 和 $b_t^{(gt)}$ 、 $b_b^{(gt)}$ 分别表示真实框左右边界的 $x$ 坐标和真实框上下边界的 $y$ 坐标, $i$ 表示辅助预测边界框与辅助真实边界框的交集面积。

$$u = (w^{(gt)} * h^{(gt)}) * r^2 + (w * h) * r^2 - i \quad (6)$$

式(6)中, $gt$ 表示真实框, $h^{(gt)}$ 和 $w^{(gt)}$ 分别表示真实框的高度和宽度, $u$ 表示辅助预测边界框与辅助真实边界框的并集面积。

$$L_{Inner-IoU} = \frac{i}{u} \quad (7)$$

所以,Inner-IoU 计算的是辅助边框之间的 IoU, $L_{Inner-IoU}$ 表示 Inner-IoU 损失函数。Inner-IoU 损失继承了 IoU 损失的一些特点,同时又有其自身的特点,Inner-GIoU 将 Inner-IoU 与 GIoU 的思想相结合,能更精确地度量预测框与真实框之间的相似度,可以克服在泛化能力方面的局限性,提升模型对小目标缺陷的辨别。其公式如式(8)所示, $L_{Inner-GIoU}$ 表示 Inner-GIoU 损失函数。

$$L_{Inner-GIoU} = L_{GIoU} + 1 - L_{IoU} - L_{Inner-IoU} \quad (8)$$

## 2 仿真实验与结果分析

### 2.1 实验环境和参数设置

本文采用 PyTorch 深度学习框架,利用 NVIDIA GeForce RTX 3080 Ti GPU, CUDA11.8,使用 Python3.8 编程。初始学习率设为 0.01,学习率动量为 0.937,权重衰减系数为  $5 \times 10^{-4}$ ,设置批量大小为 16,在本文设定的实验环境下运行 300 个 epoch。

### 2.2 实验数据集

本文采用阿里云天池比赛所提供的铝型材缺陷数据。该数据集共有 10 种缺陷类别,包括不导电 (budaodian)、擦花 (cahua)、角位漏底 (jiaoweiloudi)、桔皮 (jupi)、漏底 (loudi)、喷流 (penliu)、漆泡 (qipao)、起坑 (qikeng)、杂色 (zase)、脏点 (zangdian)。图像分辨率为  $2560 \times 1920$ 。为了解决数据集类别不均衡的问题,本实验使用随机翻转、亮度变换和旋转缩放等方式对数据集进行增强,最终生成 3416 张缺陷样本数量均衡的图像,缺陷图像如图 6 所示。为了能够使模型有效训练,将数据集划分为 7:2:1 的比例,即训练集 2386 张图片、验证集 684 张图片和测试集 346 张图片。





图 6 缺陷示意图

Fig. 6 Schematic diagram of defects

### 2.3 评价指标

在目标检测领域,评估模型的性能至关重要,而检测的准确性是其中一个核心考量因素。本文选用平均精度均值( $f_{mAP}$ )、准确率( $P$ )、召回率( $R$ )、模型计算量 GFLOPs、模型参数量 (Parameters)、检测速度 FPS 作为评估指标,计算公式如式(9)一式(12)所示:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (9)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (10)$$

$$A_p = \int_0^1 P(R) dR \quad (11)$$

$$f_{mAP} = \frac{1}{n} \sum_{i=1}^n A_{P_i} \quad (12)$$

其中,  $N_{TP}$  表示模型正确预测的正样本数目,  $N_{FP}$  表示模型错误预测的负样本数目,  $N_{FN}$  表示模型错误预测的正样本数目,  $n$  表示缺陷类别的数量,  $A_{P_i}$  为第  $i$  个类别的平均精度。

### 2.4 先验实验

根据表 1 结果分析, YOLOv8n 模型展现出最小的计算复杂度和最快的检测速度,然而其检测精度相对较低,这在一定程度上限制了其应用范围。相较于 YOLOv8n, YOLOv8m、YOLOv8l 和 YOLOv8x 模型在检测精度上有了显著提升。但是,这些模型带来的精度提升是以大幅增加计算量和明显降低检测速度为代价的。值得注意的是, YOLOv8s 模型在维持与 YOLOv8n 相近的检测速度的

同时,实现了较高的检测精度。这一优势使得 YOLOv8s 模型在实时性与准确性之间达到了一个较为理想的平衡点。综合考量模型的性能表现及实际应用需求,本研究最终选取 YOLOv8s 作为基准模型,在保持实时检测能力的同时,提升目标检测的准确性。

表 1 基准算法先验实验

Table 1 Prior experiments of benchmark algorithm

模 型	$f_{mAP}/\%$	GFLOPs	FPS
YOLOv8n	79.4	8.1	205
YOLOv8s	85.6	28.5	183.6
YOLOvm	84.4	78.7	142
YOLOv8l	85.8	165.4	86.0
YOLOv8x	85.4	258.2	65.0

## 2.5 消融实验

为了进一步验证不同模块对模型性能的影响,共设计 8 组消融实验,并对每组实验结果进行统计分析,

结果如表 2 所示。其中,以 YOLOv8s 为基准实验,模型 A、B、C 分别表示在 YOLOv8s 的基础上加上 C2f\_DWR、小目标检测层、Inner-Giou 改进后的实验结果,模型 A 更能有效提取上下文特征缺陷信息, $P$ 、 $R$ 、 $f_{mAP}$  分别提升 1.9%、1.4%、1.4%;模型 B 改善了小目标类别缺陷的检测效果,参数量下降了 0.8 M, $P$  提升 2.4%;模型 C 替换原有的损失函数,在不改变参数量和计算量的前提下,更加关注重叠目标,指标均有提升,尤其是  $R$  提高了 2.6%;模型 D 融入小目标检测层和 Inner-Giou,模型 E 融入 C2f\_DWR 和 Inner-Giou,均证明了改进模块的有效性;模型 F 融入 C2f\_DWR 和小目标检测层, $P$ 、 $R$ 、 $f_{mAP}$  分别提升了 2.8%、2.7%、2.0%;与原始模型相比,G 模型参数量减少 0.7 M,且  $P$ 、 $R$ 、 $f_{mAP}$  分别提升了 3.1%、2.1%、2.9%,因为模型更加关注小目标缺陷的检测,使计算量略微增加,检测速度略微降低,但仍然满足检测要求。G 模型即本文改进算法,可以更好地实现铝型材表面缺陷的检测。

表 2 消融实验

Table 2 Ablation experiments

模 型	C2f_DWR	小目标检测层	Inner-Giou	$P/\%$	$R/\%$	$f_{mAP}/\%$	Params/M	GFLOPs	FPS
YOLOv8s	—	—	—	84.6	81.3	85.6	11.1	28.5	<b>183.6</b>
A	✓	—	—	86.5	82.7	87.0	10.9	<b>28.1</b>	181.2
B	—	✓	—	87.0	80.7	85.9	10.9	35.7	170.7
C	—	—	✓	85.1	83.8	86.2	11.1	28.5	180.3
D	—	✓	✓	87.8	79.6	86.5	10.6	34.0	174.8
E	✓	—	✓	88.6	81.6	86.4	10.8	28.3	170.8
F	✓	✓	—	87.4	<b>84.0</b>	87.6	10.4	32.5	165.7
G	✓	✓	✓	<b>88.7</b>	83.4	<b>88.5</b>	<b>10.4</b>	32.5	165.7

## 2.6 对比实验

为了比较本文改进算法与其他算法的效果,使用当前主流检测模型,在相同的实验环境和参数设定下,对同一铝型材缺陷数据集进行对比实验,实验结果如表 3 所示。

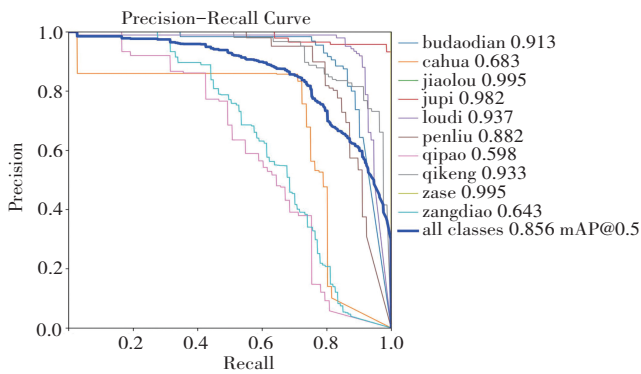
由表 3 可知,Faster R-CNN、SSD 以及最新的 YOLOv9-c 模型,计算量和参数量非常大,检测速度较低,不适宜部署在移动端。本文改进算法相比 YOLOv8s 算法,虽然在计算量上有增加,但是在精确率、召回率以及平均精度均值上均优于其他检测算法模型,平均精度达到 88.5%,比原模型算法提高了 2.9 个百分点。综上所述,相较于目前主流模型,本文改进算法具有更好的检测性能。原 YOLOv8s 算法以及本文

改进算法所有类的 PR 曲线如图 7 所示。


表 3 不同模型对比试验

Table 3 Comparative experiments of different models

模 型	$P/\%$	$R/\%$	$f_{mAP}/\%$	Params/M	GFLOPs	FPS
SSD	79.2	76.4	78.5	26.1	89.5	36.4
Faster R-CNN	85.9	82.3	81.2	28.2	95.1	48.2
YOLOv5s	82.0	80.4	82.7	9.1	23.8	170.3
YOLOX-s	80.4	79.5	83.6	9.1	27.1	160.8
YOLOv8s	84.6	81.3	85.6	11.1	28.5	183.6
YOLOv9-c	86.8	83.4	88.0	51.0	237.8	43.5
改进算法	88.7	83.4	88.5	10.4	36.3	165.7



(a) 改进前 PR 曲线



(b) 改进后 PR 曲线

图 7 YOLOv8s 算法改进前后精确率-召回率曲线对比


Fig. 7 Comparison of precision-recall curves before and after the improvement of YOLOv8s algorithm

### 2.7 检测效果对比


由图 7 可见,擦花和漆泡缺陷检测精度有明显提升。为了更直观地展示本文算法的优劣,由于缺陷种类过多,选取改进算法的部分检测结果如图 8 所示。




(a) 改进前擦花缺陷图



(b) 改进后擦花缺陷图



(c) 改进前漆泡缺陷图



(d) 改进后漆泡缺陷图

图 8 算法改进前后检测效果对比

Fig. 8 Comparison of detection effects before and after algorithm improvement

### 3 结论与展望

针对现有模型对铝型材表面缺陷检测精度低,易出现漏检和误检的情况,提出一种改进的 YOLOv8s 检测算法。首先,将主干网络里面的部分 C2f 模块替换为 C2f\_DWR 模块,提升特征提取效率;然后,在颈部网络增加一个小目标检测层和适配的 P2 检测头,改善模型对小目标特征缺陷的获取能力;最后,通过改进损失函数以加快模型收敛速度,有效改善了算法对小目标的检测效果。经过对比和消融实验发现:改进后的模型检测效果相较于原模型明显提升,符合当前生产中对铝表面缺陷工业级检测的需求。

在未来研究工作中,将持续优化该模型,进一步提高擦花、脏点和漆泡类型的缺陷检测精度,同时也致力于提升所有缺陷平均检测精度以及降低模型的参数量,提高检测速度。尝试将改进模型部署到移动端或者实际生产中,根据生产中的实际问题再对模型进行优化。

#### 参考文献(References):

[1] 屈尔庆,崔月姣,徐森,等. 改进的 Gabor 滤波器带钢表

- 面缺陷显著性检测[J]. 华中科技大学学报(自然科学版), 2017, 45(10): 12-17.
- QU Er-qing, CUI Yue-jiao, XU Sen, et al. Saliency defect detection in strip steel by improved Gabor filter[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2017, 45(10): 12-17.
- [2] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2014: 580-587.
- [3] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [4] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[C]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [5] 王婉婷, 姜国龙, 褚云飞, 等. 从 RCNN 到 YOLO 系列的物体检测系统综述[J]. 齐鲁工业大学学报, 2021, 35(5): 9-16.
- WANG Wan-ting, JIANG Guo-long, CHU Yun-fei, et al. Overview of object detection systems from RCNNs to YOLOs[J]. Journal of Shandong Institute of Light Industry(Natural Science Edition), 2021, 35(5): 9-16.
- [6] 姚波, 温秀兰, 焦良葆, 等. 改进 YOLOv3 算法用于铝型材表面缺陷检测[J]. 计量学报, 2022, 43(10): 1256-1261.
- YAO Bo, WEN Xiu-lan, JIAO Liang-bao, et al. Improved YOLOv3 algorithm for surface defect detection of aluminum profile[J]. Acta Metrologica Sinica, 2022, 43(10): 1256-1261.
- [7] LIU X, HE W, ZHANG Y, et al. Effect of dual-convolutional neural network model fusion for Aluminum profile surface defects classification and recognition[J]. Math Biosci Eng, 2022, 19(1): 997-1025.
- [8] NEUHAUSER F M, BACHMANN G, HORA P. Surface defect classification and detection on extruded aluminum profiles using convolutional neural networks[J]. International Journal of Material Forming, 2020, 13(4): 591-603.
- [9] WU D, SHEN X, CHEN L. Detection of defects on aluminum profile surface based on improved YOLO[C]//Proceedings of the Prognostics and Health Management Conference. Piscataway: IEEE Press, 2022: 468-472.
- [10] 吴晓成, 梁丹, 梁冬泰, 等. 基于 YOLO 深度学习模型的铝型材表面缺陷识别方法[J]. 机械设计与研究, 2021, 37(2): 34-39.
- WU Xiao-cheng, LIANG Dan, LIANG Dong-tai, et al. Surface defect identification method of aluminum profiles based on YOLO deep learning model[J]. Machine Design & Research, 2021, 37(2): 34-39.
- [11] 赵伟, 刘国华. 融合注意力与自适应加权特征金字塔的铝型材缺陷检测[J]. 光电子·激光, 2025, 36(1): 53-60.
- ZHAO Wei, LIU Guo-hua. Aluminum profile defect detection based on attention and adaptive weighted Feature Pyramid [J]. Journal of Optoelectronics · Laser, 2025, 36(1): 53-60.
- [12] 席凌飞, 伊力哈木·亚尔买买提, 刘雅洁. 基于改进 YOLOv5 的铝型材表面缺陷检测方法[J]. 广西师范大学学报(自然科学版), 2024, 42(1): 111-119.
- XI Ling-fei, YAERMAIMAITI Yilihamu, LIUYa-jie. Surface defect detection method for aluminum profile based on improved YOLOv5[J]. Journal of Guangxi Normal University (Natural Science Edition), 2024, 42(1): 111-119.
- [13] 邓光伟, 尤红权, 朱志松. 基于 KCC-YOLOv5 的铝型材表面缺陷检测[J]. 激光与光电子学进展, 2024, 61(4): 231-239.
- DENG Guang-wei, YOU Hong-quan, ZHU Zhi-song. Defect detection on aluminum profile surface based on KCC-YOLOv5[J]. Laser & Optoelectronics Progress, 2024, 61(4): 231-239.
- [14] WEI H, LIU X, XU S, et al. DWRSeg: rethinking efficient acquisition of multi-scale contextual information for real-time semantic segmentation[EB/OL]. 2022: arXiv: 2212.01173. <https://arxiv.org/abs/2212.01173>.
- [15] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 658-666.
- [16] ZHANG H, XU C, ZHANG S. Inner-IoU: More effective intersection over union loss with auxiliary bounding box[EB/OL]. arxiv: 2023: 2311.02877. <https://arxiv.org/abs/2311.02877>.

责任编辑:李翠薇