

YOLO-SBS: 一种改进 YOLOv8s 的钢材表面缺陷检测算法

沙小奇, 黄建, 陈廷伟

(辽宁大学信息学部, 辽宁 沈阳 110036)

摘要: 针对钢材表面缺陷检测任务存在的参数量大、特征融合能力不足和小目标缺陷检测精度不佳等问题, 提出一种改进 YOLOv8s 的钢材表面缺陷检测算法 YOLO-SBS。首先, 设计 SCB 模块改进 YOLOv8 中的 C2f 模块, 提升模型特征提取能力, 降低参数量; 其次, 引入加权特征融合 WFF, 依靠可学习权重动态调整特征图的贡献比例, 强化模型特征融合能力; 最后, 引入针对小目标检测的 SPDConv 模块, 缓解深层网络信息丢失, 提升模型对缺陷检测的整体性能。在 NEU-DET 数据集上的实验表明, 所提模型的 mAP 为 75.0%, 相较于原始的 YOLOv8s 提升 3.7%; 参数量、计算量分别降低 9.9%、6.7%, 实现了参数量、计算量与检测精度之间的平衡, 在钢材表面缺陷检测任务中表现出色。在工业数据集 GC10-DET 中的泛化性验证实验表明, 改进算法具有较好的泛化性。

关键词: 钢材表面缺陷检测; YOLOv8s; 加权特征融合; 小目标检测; C2f_SCB

DOI: 10.11907/jjdk.251119

中图分类号: TP391.4

文献标识码: A

文章编号: 1672-7800(2026)004-0076-07

扫描二维码阅读全文:



YOLO-SBS: An Improved YOLOv8s Algorithm for Steel Surface Defect Detection

SHA Xiaoqi, HUANG Jian, CHEN Tingwei

(Faculty of Information, Liaoning University, Shenyang 110036, China)

Abstract: Aiming at the problems of large parameter quantity, insufficient feature fusion ability, and poor accuracy of small target defect detection in steel surface defect detection tasks, an improved YOLO-SBS algorithm for steel surface defect detection based on YOLOv8s is proposed. Firstly, design the SCB module to improve the C2f module in YOLOv8, enhance the model's feature extraction capability, and reduce the number of parameters; Secondly, weighted feature fusion (WFF) is introduced to dynamically adjust the contribution ratio of feature maps based on learnable weights, enhancing the model's feature fusion capability; Finally, the SPDConv module for small object detection is introduced to alleviate information loss in deep networks and improve the overall performance of the model for defect detection. Experiments on the NEU-DET dataset show that the mAP of the proposed model is 75.0%, which is 3.7% higher than the original YOLOv8s; The parameter quantity and calculation quantity were reduced by 9.9% and 6.7% respectively, achieving a balance between parameter quantity, calculation quantity, and detection accuracy, and performing excellently in the task of steel surface defect detection. The generalization verification experiment on the industrial dataset GC10-DET shows that the improved algorithm has good generalization performance.

Key Words: steel surface defect detection; YOLOv8s; weighted feature fusion; small object detection; C2f_SCB

0 引言

在现代工业领域中, 钢材具有重要地位。钢在产出时受原料、工艺和设备等因素影响, 可能会出现裂缝、杂质和斑块等表面缺陷, 损害钢材强度和韧性, 进而影响钢材质

量, 甚至引发安全事故, 因此检测钢材的缺陷非常重要。传统缺陷检测主要采用人工抽检, 由检验人员主观判别, 但由于缺陷复杂多样, 因此存在漏检、误检和错检等一系列问题。

基于机器视觉的缺陷检测方法需要先人工提取特征, 再进行检测, 存在效率低、鲁棒性差等问题^[1]。目前, 不少

收稿日期: 2025-02-26

基金项目: 辽宁省自然科学基金项目(2023-BS-085); 辽宁省教育厅高校基本科研项目(LJ212410140012)

作者简介: 沙小奇(2000-), 男, 辽宁大学信息学部硕士研究生, 研究方向为深度学习; 陈廷伟(1974-), 男, 博士, 辽宁大学信息学部教授, 研究方向为人工智能、深度学习、区块链。本文通讯作者: 陈廷伟。

学者提出基于深度学习的钢材表面缺陷检测算法, 具有重大意义。深度学习目标检测算法主要分为单阶段检测和双阶段检测两大类。其中, 双阶段检测算法的代表为 Faster R-CNN^[2]; 单阶段检测算法的代表为 SSD (Single Shot Multibox Detector)、YOLO (You Only Look Once) 系列算法^[3-4]。

杨莉等^[5]提出基于改进 Faster R-CNN 的钢材表面缺陷检测方法, 引入 GA-RPN 与可调节机制提升 Faster R-CNN 的性能, 且提出的多任务 FPN 能更好地保留定位信息, 但存在参数量过大的问题。阎馨等^[6]提出的基于改进 SSD 的钢材表面缺陷检测, 添加了 Transfor-mar 多头注意力机制模块筛选重要信息, 使用 Involution 算子代替 Conv7 卷积操作来减少运算过程的参数量, 但模型较为复杂, 对计算资源要求高。黄海新等^[7]在 YOLOv7 主干网络中引入 GhostNet 模块, 再将注意力机制与池化模块相结合, 提升了模型检测复杂钢材表面缺陷的能力, 但面对裂纹等小缺陷检测时的效果较差。黄啸等^[8]提出一种基于 YOLOXs 的改进检测算法, 设计并行注意力模块 EFA 来提升网络对缺陷特征的敏感度, 并引入 Ciou 损失函数加速收敛, 但存在检测速度较慢的问题。张文铠等^[9]在 YOLOv8s 的基础上替换了 C2f_Triple 模块, 引入 CARAFE 上采样算子加强模型感受野和特征提取能力, 但模型参数量有所上升。

本文针对检测算法参数量大、特征融合能力不足及小目标缺陷检测精度不佳等问题, 在 YOLOv8 系列算法的基础上, 提出了一种改进的 YOLOv8s 的钢材表面缺陷检测算法^[10]。本文主要工作为: ①设计 C2f_SCB 模块代替原有的 C2f 模块, 改进模块内部结构, 降低模型参数量, 提升网络特征提取能力; ②在 Neck 中引入加权特征融合 (Weighted Feature Fusion, WFF), 在融合特征图时加入可学习权重, 以增加模型特征融合能力^[11]; ③在最深处预测头前加入 SPDCov 模块, 提升模型对钢材缺陷类小目标的检测性能^[12]。

1 YOLOv8 算法介绍

YOLOv8 是 Ultralytics 公司于 2023 年对 YOLOv5 进行改进所推出的单阶段检测算法, 根据模型大小提供了 5 种配置: YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l 和 YOLOv8x^[13]。其中, YOLOv8 模型由输入 (Input)、骨干网络 (Backbone)、颈部 (Neck) 和检测头 (Head) 4 个部分组成。

YOLOv8 相较于 YOLOv5, 不仅在精度上有所提升, 还更轻量化。首先, 将整个网络的 C3 模块替换为 C2f 模块, 以获得更丰富的梯度信息; 其次, 将 Backbone 中的 SPP 结构换为 SPPF 结构, 使执行时间减少至原来的一半; 再次, 在 Neck 部分移除 PAN 结构中上采样后的卷积运算; 最后, 预测头采用解耦头结构, 在进行端到端预测时效率更高。

2 YOLO-SBS

2.1 网络结构

为了解决钢材缺陷检测中存在的算法参数量大、特征融合能力不足及小目标缺陷检测精度不佳等问题, 提出了 YOLO-SBS 算法。首先, 在 YOLOv8s 的 Backbone、Neck 部分添加新设计的 C2f_SCB 模块, 提升网络对缺陷特征提取效率; 其次, 在 Neck 部分引入加权特征融合, 改善原始的 PAN (Path Aggregation Network)-FPN (Feature pyramid networks), 在融合特征图时加入可学习权重以强化模型的多尺度特征融合能力^[14-15]; 最后, 为了平衡参数量和检测精度, 仅在最深层预测头前引入 SPDCov 模块, 以缓解深层网络因特征图下采样造成的信息丢失。改进后的 YOLO-SBS 算法的网络结构如图 1 所示。

2.2 改进的模块 C2f_SCB

C2f 模块的 Bottleneck 由两个 3×3 卷积组成, 但在面对钢材表面缺陷这种小目标时, 存在特征提取能力不足的问题。为此, 本文提出 C2f_SCB 模块, 设计灵感源于 Rewrite the Stars^[16]。Rewrite the Stars 将元素乘法称为 Star Operation, 证明了其具有将输入映射到高维非线性特征空间的能力, 可增强模型的特征表达丰富性和复杂性。与传统神经网络增加宽度 (通道数) 的不同之处在于: Star Operation 在不同通道上进行成对特征乘法, 类似于多项式核函数, 显著提升了模型表达能力, 即使在紧凑的特征空间内也能实现高维度特征计算。

然而, Star Operation 会导致特征主要集中在局部位置, 缺乏跨通道或跨空间的特征交互。为此, 本文引入一种结合空间和通道注意力机制的卷积块注意力模块 (Convolutional Block Attention Module, CBAM)^[17]。CBAM 由通道注意力模块 (Channel Attention Module, CAM) 与空间注意力模块 (Space Attention Module, SAM) 组成, 从两个维度加权注意力, 既能增强网络聚焦关键信息的能力, 又能提升模型的特征提取能力。

图 2 中的左右部分分别为 C2f_SCB 与 SCB block。SCB block 的优势在于通过深度卷积 (DW-Conv) 配合逐元素乘法操作, 可产生高维度的非线性特征空间, 从而在较低计算量的前提下也能提升模型特征表达能力^[18]。CBAM 注意力模块在通道、空间两个维度上加权注意力, 实现了跨通道和跨空间的特征交互, 增强了对重要特征的关注意度, 并将处理后的特征图与原始特征图进行残差连接以避免梯度消失问题发生。

2.3 加权特征融合

在传统特征融合中, YOLOv8 使用简单的拼接 (concat) 操作 (见式 1), 将不同分辨率的特征图直接沿指定维度拼接, 虽能整合多层信息, 但无法区分不同特征图的重要性。同时, 由于各特征图的分辨率与语义信息差异较大, 在融




Fig. 1 YOLO-SBS network structure

图1 YOLO-SBS网络结构




Fig. 2 C2f_SCB block

图2 C2f_SCB block

合时会导致信息失衡,影响模型检测性能。

$$\mathbf{O} = \text{Concat}(\mathbf{I}_1, \mathbf{I}_2, \dots, \mathbf{I}_n) \quad (1)$$

式中: $\mathbf{O}$ 表示融合后的输出特征; Concat 表示拼接操作; $\mathbf{I}$ 为输入的特征图。

为了优化特征融合效果,使网络自动学习每层特征的重要性权重。本文引入加权特征融合(Weighted Feature Fusion)动态调整特征图的贡献比例,以提升模型特征融合能力^[11]。

$$\mathbf{O} = \sum_{i=1}^n \frac{w_i}{\sum_{j=1}^n w_j + \epsilon} \cdot \mathbf{I}_i \quad (2)$$

式中: $\mathbf{O}$ 表示融合后的输出特征; $\mathbf{I}_i$ 表示输入的特征图; w_i 表示每个输入特征的可学习权重; w_j 表示所有输入特征的权重之和; ϵ 为一个小常数,防止除零错误,从而避免数值不稳定。

在加权特征融合中,每个输入特征图 $\mathbf{I}$ 都对应一个可学习的权重 w_i ,网络根据不同特征的分辨率、语义信息等属性自动学习权重,以反映各层特征图对最终输出的重要性。

2.4 SPDCConv 模块

在目标检测中,较小的目标会限制模型学习上下文信息。例如,在钢材缺陷检测中,裂缝(Crazing)、杂质(Inclusion)、氧化皮(Rolled-in-Scale)等小缺陷检测方面容易出现漏检误检,存在检测精度不足的问题。

目前,YOLO模型通过不同尺度的特征图关注小、中、大目标,基于 80×80 的特征图捕捉图像中的小目标, 20×20 的特征图因感受野大、分辨率低,更适合检测图像中的大目标。深层的 20×20 特征图因网络层数深,下采样多次后会逐渐丢失图像的空间位置信息,无法捕捉图像中的细小特征,意味着深层特征图对小目标的定位和识别能力较弱,容易遗漏小目标。考虑到要控制算法参数量,仅在最深层检测头前加入SPDCConv模块来增强感受野,提升分

类、定位精度,缓解特征图下采样带来的信息丢失问题,减少误检、漏检现象^[12]。SPDConv 由空间到深度(Space-to-depth layer, SPDlayer)层和非跨步卷积(N-S-Conv)层组成,在处理具有低分辨率图像和小物体任务上,相较于传统深度学习模型表现较好,如图3所示(从左至右依次为原始特征图、子特征图、特征图 X' 、特征图 X'')。其中,图中展示了scale为2时的情况。

首先,SPD层将原始特征图((S,S,C1)沿 x,y 方向切分,得到尺寸大小均为(S/scale, S/scale, C1)的子特征图,并将其作为原特征输入 X 的下采样;其次,将所有子特征图沿通道维度相连接,得到通道维度为4C、空间维度为S/2的特征图 X' (S/scale, S/scale, scale*2*C1),相较于原始特征图 X 通道维度增加两倍,空间维度减少一半;最后,将特征图 X' 送入含C2个滤波器的非跨步卷积层(N-S-Conv)得到输出特征图 X'' (S/scale, S/scale, C2),尽可能地保留所有判别信息。




Fig. 3 SPDConv principle

图3 SPDConv原理

3 实验结果与分析

3.1 数据集

本文采用由东北大学开放的 NEU-DET 钢材表面缺陷数据集进行实验。该数据集含有 1 800 幅灰度图像,涵盖裂缝(Crazing)、杂质(Inclusion)、斑块(Patches)、点蚀表面(Pitted-Surface)、氧化皮(Rolled-in-Scale)和划痕(Scratches)等6类缺陷,如图4所示^[19]。同时,按8:1:1的比例划分得到训练集1 440张,测试集、验证集各180张。

3.2 实验环境与参数配置

实验操作系统为 Ubuntu 20.04, 处理器为 Intel(R) Xeon(R) CPU E5-2680 v4@2.4 GHz, 搭载 NVIDIA GeForce RTX3090 24 GB 显卡, 软件环境为 CUDA 11.8、Python 3.8 和 Pytorch 2.0.0。实验使用随机梯度(Stochastic Gradient Descent, SGD)进行训练,训练周期(epochs)为200轮,输入图像大小为320×320,批处理量(Batch Size)为32,初始学习率为0.01,权重衰退值为0.000 5,动量(Momentum)为0.937。




Fig. 4 Examples of 6 types of defects in NEU-DET

图4 NEU-DET 中6类缺陷样例

3.3 评价指标

本文使用平均精度(AP)、平均精度均值(mAP)、计算量(GFLOPs)、参数量(Parameters)、每秒传输帧数(FPS)和P-R曲线(Precision-recall curve)等指标,评估缺陷检测模型的性能。其中,AP表示各类缺陷的平均精度;mAP@50表示IoU=0.5时的平均精度均值;Parameters用来评价模型参数量大小;GFLOPs表示以10亿(Giga)为单位的浮点操作数总数量,以评价模型复杂度。

$$P = T_p / (T_p + F_p) \times 100\% \quad (3)$$

$$R = T_p / (T_p + F_N) \times 100\% \quad (4)$$

$$AP = \int_0^1 P(R) dR \times 100\% \quad (5)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP(i) \times 100\% \quad (6)$$

式中: T_p 表示被模型正确预测的正样本数; F_p 表示被模型错误预测的正样本数; F_N 表示被模型错误预测的负样本数; i 为缺陷类别; n 为缺陷类别数。

3.4 实验结果

3.4.1 消融实验

为了验证所提改进点的有效性,在 NEU-DET 数据集中,以 YOLOv8s 为基准设计消融实验,实验过程中保持参数一致且不使用预训练权重,实验结果如表1所示。其中,C2f_SCB表示把C2f模块换为C2f_SCB模块;W_Concat表示在Neck中引入加权特征融合;SPD表示在大尺寸检测头前加一个SPDConv模块。

由表1可知,YOLOv8原始结构的mAP@50为71.3%,原因为基础模型在钢材表面缺陷检测中存在特征提取、多尺度融合不足的问题,难以应对复杂的缺陷背景和多尺度特征。在基础模型中,使用C2f_SCB模块后的mAP@50提升至72.1%,模型参数量从11.1 MB减少到9.6 MB,优势在于通过更高效的特征提取机制,增加了模型捕捉细节特征的能力,在减少计算量的同时提升了模型性能。在基础模型中引入W_Concat后mAP@50提升至72.2%,改进后的Neck根据可学习的权重区分不同特征的重要性,以动态调整特征图的贡献比例,避免了冗余信息的干扰,使多尺度特征信息能更有效地传递。在基础模型最深层大尺寸预

Table 1 Ablation experiments result
表 1 消融实验结果

算法	Parameters/MB	GFLOPs	FPS	mAP@50/%	AP/%					
					Cr	In	Pa	Ps	Rs	Sc
YOLOv8s	11.1	28.4	86.2	71.3	39.8	77.8	86.1	80.8	53.2	90.4
+ C2f_SCB	9.6	24.6	74.1	72.1	41.0	82.3	87.4	75.5	55.6	90.5
+W_Concat	11.2	28.7	90.1	72.2	36.1	80.6	86.3	76.4	59.9	93.9
+SPD	11.5	30.2	90.1	73.6	45.1	81.1	88.4	80.3	57.4	89.5
YOLO-SBS	10.0	26.5	75.2	75.0	46.9	81.8	92.4	80.1	54.8	94.3

测头前添加 SPDConv 模块后, mAP@50 提升至 73.6%, 避免了 SPDConv 会增加参数量的缺点, 但会消耗更多计算资源。

综上, 将 C2f_SCB、W_Concat 和 SPDConv 三者结合得到的 YOLO-SBS, 在特征提取、特征融合和小目标优化上的协同效果良好, mAP@50 相较基准模型提升了 3.7% (达到了 75.0%), 在 Cr、In、Pa、Sc 等 4 类单类缺陷检测中的效果最优, 既提升了模型检测精度, 又保持了较低的模型参数量, 还解决了引入 SPDConv 会消耗更多计算资源的缺点。虽然, 所提模型在 FPS 指标上有所降低, 但仍能满足工业现场的实时检测需求。

此外, 为了深入探索所提算法的可解释性, 使用 HiResCAM 方法生成可视化热力图, 以直观显示模型在检测钢材表面缺陷时对不同区域的关注程度, 如图 5 所示。由此可见, 所提算法能更准确地识别目标所在区域, 虽然 YOLOv8s 关注更为集中, 但精确性较差, 容易出现漏检、误检现象。




Fig. 5 Heatmap comparison results
图 5 热力图比较结果

3.4.2 比较实验

为了验证所提算法对带钢表面缺陷检测的有效性和先进性, 在 NEU-DET 数据集上将其与较为流行的目标检测算法进行比较, 包括两阶段目标检测算法 Faster R-CNN, 单阶段目标检测算法 SSD、YOLOv5s、YOLOv6s、YOLOXs、RT-DETR 及基线算法 YOLOv8s, 实验过程参数一致且不使用预训练权重, 实验结果如表 2 所示^[20-22]。

在检测精度方面, 所提方法的 mAP 值为 75.0%, 相较

于其他主流算法更优秀。具体地, 所提方法相较于 SSD、Faster R-CNN、YOLOv5s、YOLOv6s、YOLOXs、RT-DETR、YOLOv8s、RT-DETR 算法分别提升 4.1%、9.6%、5.1%、1.5%、1.8%、3.7%、9.9%。在模型复杂度方面, 所提模型参数量明显低于 SSD、Faster R-CNN、YOLOv6s、RT-DETR 和 YOLOv8s 算法, 浮点计算量低于 SSD、Faster R-CNN、YOLOXs、YOLOv6s、RT-DETR 和 YOLOv8s, 仅略高于 YOLOv5s。综上, 本文模型的检测精度优于其他网络模型, 参数量优于多数模型, 能较好地满足钢材表面缺陷检测任务的要求。

Table 2 Results of comparison experiment
表 2 比较实验结果

算法	mAP@50/%	Parameters/MB	GFLOPs
SSD	70.9	24.3	68.8
Faster R-CNN	65.4	41.3	134
YOLOv5s	69.9	9.1	23.8
YOLOv6s	73.5	16.3	44
YOLOXs	73.2	8.9	26.8
YOLOv8s	71.3	11.1	28.4
RT-DETR	65.1	32.0	103.5
Ours	75.0	10.0	26.5

3.4.3 泛化性测试

为了验证算法的泛化性, 在工业数据集 GC10-DET 上与 YOLOv8s 进行比较^[23]。其中, GC10-DET 经处理后包含 2 294 张钢材表面缺陷图像, 涵盖冲孔 (Pu)、焊缝 (Wl)、新月形缝隙 (Cg)、水斑 (Ws)、油斑 (Os)、丝斑 (Ss)、夹杂物 (In)、轧坑 (Rp)、折痕 (Cr)、腰部折痕 (Wf) 10 种类型, 按照 8:1:1 的比例划分数据集, 实验设备与参数保持一致, 实验结果如表 3 所示。由此可知, 所提模型相较于比较模型, mAP@50 提升 2.7%, 参数量降低 1.1 MB, 计算量降低 6.7%, 证实了该算法在检测精度、模型参数量方面性能更优, 在不同数据集和场景下仍具有出色的表现, 泛化性更好。

Table 3 Experimental results on industrial dataset
表 3 在工业数据集上的实验结果

算法	mAP@50/%	Parameters/MB	GFLOPs
YOLOv8s	60.1	11.1	28.4
Ours	62.8	10	26.5

3.4.4 缺陷检测效果

为了验证所提算法的综合检测效果,在 NEU-DET 数据集上获得其与基线算法的 P-R 曲线和检测结果图,以直观进行比较分析,实验结果如图 6、图 7 所示,左侧为 YOLOv8s,右侧为本文模型。其中,P-R 曲线是评估模型性能

的重要指标,P 为纵坐标,R 为横坐标。
由图 6 可见,所提算法优于 YOLOv8s,在缺陷检测性能上更优越。由图 7 可见,相较于 YOLOv8s 而言,所提模型能更准确地定位和识别 Cr、In 等缺陷,避免错检问题发生。




Fig. 6 P-R curve
图 6 P-R 曲线




Fig. 7 Comparison of detection results
图 7 检测结果比较

4 结语

本文针对钢材表面缺陷检测存在的问题,提出一种基于 YOLOv8s 改进的算法 YOLO-SBS。首先,将自设计的模块 C2f_SCB 代替原模块,降低模型参数量、复杂度,增加网络目标特征提取能力;其次,引入加权特征融合,通过可学习权重动态调整特征图的贡献比例,增加模型特征融合能力;最后,在深层预测头前,引入 SPDConv 模块以提升模型对小目标缺陷的检测能力。
在 NEU-DET 数据集上的实验表明,本文算法的检测精度达到 75.0%,相较于 YOLOv8s 模型提升了 3.7%,参数量和复杂度都有所降低,并在 GC10-DET 数据集上证明

了其泛化性较好。虽然,所提算法降低了模型参数、复杂度,提升了检测精度,但裂纹、氧化皮的检测精度和 FPS 还有待提升。后续,将着重针对上述 3 个方面进行研究,以期获得更好的解决办法。

参考文献:

[1] ZHANG Y, FENG F. Analysis of strip surface defect detection technology [J]. Information & Computer (Theory Edition), 2021, 33(11): 19-22.
张艳, 冯锋. 带钢表面缺陷检测技术探析[J]. 信息与电脑(理论版), 2021, 33(11): 19-22.

[2] 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, 2015, 28: 91-99.

[3] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox de-

- tor[C]// 14th European Conference on Computer Vision, 2016: 21–37.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779–788.
- [5] YANG L, ZHANG Y N, WANG T T, et al. New method for steel surface defect detection based on improved Faster R-CNN[J]. Journal of Jilin University (Information Science Edition), 2021, 39(4): 409–415.
杨莉, 张亚楠, 王婷婷, 等. 基于改进 Faster R-CNN 的钢材表面缺陷检测方法[J]. 吉林大学学报(信息科学版), 2021, 39(4): 409–415.
- [6] YAN X, YANG Y C, TU N W. Steel surface defect detection based on improved SSD[J]. Modern Manufacturing Engineering, 2023(5): 112–120.
阎馨, 杨月川, 屠乃威. 基于改进 SSD 的钢材表面缺陷检测[J]. 现代制造工程, 2023(5): 112–120.
- [7] HUANG H X, WU D. Steel defect detection based on improved YOLOv7[J]. Computer Science, 2024, 51(S1): 535–539.
黄海新, 吴迪. 基于改进 YOLOv7 的钢材缺陷检测[J]. 计算机科学, 2024, 51(S1): 535–539.
- [8] HUANG X, WU L, LI Y, et al. Lightweight steel surface defect detection algorithm based on improved YOLOX-s[J]. Journal of Computer Applications, 2023, 43(S2): 201–208.
黄啸, 吴龙, 黎尧, 等. 基于改进 YOLOX-s 的轻量级型钢表面缺陷检测算法[J]. 计算机应用, 2023, 43(S2): 201–208.
- [9] ZHANG W K, LIU J. Steel surface defect detection based on improved YOLOv8s[J]. Journal of Beijing Information Science & Technology University (Natural Science Edition), 2023, 38(6): 33–40.
张文铠, 刘佳. 基于改进 YOLOv8s 的钢材表面缺陷检测[J]. 北京信息科技大学学报(自然科学版), 2023, 38(6): 33–40.
- [10] JOCHER G, CHAURASIA A, QIU J. Ultralytics YOLO (Version 8.0.0) [EB/OL]. <https://github.com/ultralytics/ultralytics>.
- [11] TAN M X, PANG R M, LE Q V. EfficientDet: scalable and efficient object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020: 10781–10790.
- [12] SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects [C]// Joint European Conference on Machine Learning and Knowledge Discovery in Databases, 2022: 443–459.
- [13] JOCHER G, CHAURASIA A, STOKEN A, et al. Ultralytics/yolov5: v7.0 – YOLOv5 sota realtime instance segmentation (v7.0) [EB/OL]. <https://doi.org/10.5281/zenodo.7347926>.
- [14] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759–8768.
- [15] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936–944.
- [16] MA X, DAI X, BAI Y, et al. Rewrite the stars[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2024: 5694–5703.
- [17] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[DB/OL]. <https://arxiv.org/abs/1807.06521>.
- [18] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [DB/OL]. <https://arxiv.org/abs/1704.04861>.
- [19] HE Y, SONG K, MENG Q, YAN Y, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1493–1504.
- [20] LI C Y, LI L, JIANG H L, et al. YOLOv6: a single-stage object detection framework for industrial applications [DB/OL]. <https://arxiv.org/abs/2209.02976>.
- [21] GAO Z, LU C, LI H, et al. A corn seed spacing detection method based on image stitching and YOLOX [J]. Computers and Electronics in Agriculture, 2024, 222: 109087.
- [22] LYU W Y, XU S L, ZHAO Y, et al. DETRs beat YOLOs on real-time object detection [DB/OL]. <https://arxiv.org/abs/2304.08069>.
- [23] LYU X, DUAN F, JIANG J, et al. Deep metallic surface defect detection: the new benchmark and detection network [J]. Sensors, 2020, 20(6): 1562.

(责任编辑: 刘嘉文)