

基于 MSI-YOLO 的钢材缺陷检测算法

董铭扬¹ 赵飞燕^{1*} 任哲¹

DONG Mingyang ZHAO Feiyan REN Zhe

摘要

针对钢材表面缺陷检测中小目标漏检率、多尺度特征提取不足以及模型计算复杂等问题,文章通过对 YOLOv11n 基准模型进行结构优化,提出一种 MSI-YOLO 的检测算法。首先,在主干网络中嵌入多尺度扩张注意力模块(multi-scale dilated attention, MSDA),增强微小缺陷及低对比度区域的上下文信息捕捉能力;其次,利用 GSConv 与 VoV-GSCSP 模块构建轻量级 Slim-neck 结构以替代原颈部网络,压缩参数量并维持特征融合效果;此外,引入 Inner-DIoU 边界框回归损失,提升定位精度与收敛速度。在 NEU-DET 数据集上的测试结果表明,MSI-YOLO 的 mAP@0.5 达到 80.2%,优于 YOLOv5、YOLOv8 及原版 YOLOv11 等对比模型,且参数量仅 2.8×10^6 ,兼具高精度与轻量化实时检测能力。

关键词

钢材缺陷检测; YOLOv11; 多尺度注意力; 轻量化; Inner-DIoU

doi: 10.3969/j.issn.1672-9528.2026.06.035

0 引言

钢材是现代工业的重要材料,表面质量直接影响工程结构安全与寿命,其缺陷不仅会影响产品的外观,还可能降低其机械性能和抗腐蚀能力。近年来,深度学习推动自动化缺陷检测成为工业质控新方向。传统的缺陷检测方法,如人工目视检测、漏磁检测^[1]、涡流检测^[2]和红外检测^[3]等存在效率低、灵敏度不足以及过度依赖经验等问题,难以满足检测要求。相比之下,深度学习通过训练神经网络自动识别缺陷,可实现快速精准的在线检测。

目前,基于深度学习的目标检测模型分为单阶段与两阶段。以 R-CNN 系列(如 Faster R-CNN^[4]、Mask R-CNN^[5])为代表的两阶段模型,通过生成候选区域,进行细致分类和边界框调整,来提高检测的准确性,但其两阶段的设计导致推理速度较慢。而以 YOLO^[6]和 SSD^[7]为代表的单阶段模型,通过单次前向传播在特征图上预测目标类别和边界框位置,检测速度显著提高,适合实时场景,但小目标精度仍需提升^[8]。如何在保证高精度的同时,满足检测速度的实时要求,是钢材表面缺陷检测的实际应用的核心挑战^[9]。

针对这一挑战,研究者们基于 YOLO 算法提出了多种改进算法。Kou 等^[10]通过引入无锚点机制和密集卷积块来增强 YOLOv3 的性能,提升钢材表面缺陷的检测精度。周孟然等^[11]提出 YOLOv5s-FCS 钢材表面缺陷检测模型,通过引入

FReLU 激活函数构建新的卷积模块(CBF),来增强对缺陷特征的提取能力,控制模型复杂度并提升精度。Wang 等^[12]采用去加权的双向特征金字塔网络(BFN)改进 YOLOv7,通过缓解卷积过程中的特征信息丢失问题,以增强检测模型的精度。彭菊红等^[13]在特征提取、目标定位以及多尺度检测方面进行了优化,提出了 YOLOv8n-MDC 的钢材表面缺陷检测算法。徐薪羽等^[14]在 YOLOv8 的基础上引入可变形卷积与 Inner-IoU 损失函数,提高钢材表面缺陷检测精度并控制计算量。尽管现有方法取得进展,但模型复杂度、检测精度与计算成本的协同平衡仍是研究难点,未来需通过优化特征融合机制、增强微小缺陷识别能力及推动模型轻量化设计来进一步提升性能^[15]。

为解决上述问题,本文以 YOLOv11n 为基线,提出改进算法 MSI-YOLO,旨在优化性能并平衡精度与资源消耗。从三个方面进行优化:

(1) 引入多尺度扩张注意力模块(MSDA),通过不同扩张率卷积并行提取上下文信息,结合注意力增强对低对比度、小缺陷的特征聚焦,提升复杂背景下的区分度。

(2) 采用一种轻量化的 Slim-neck 结构替代原颈部网络,以 GSConv 和 VoV-GSCSP 模块替换原颈部 Conv 和 C3k2 层,在保持特征融合能力的同时,减少计算冗余。

(3) 在边界框回归方面,引入 Inner-DIoU 损失函数,通过动态调整辅助边界框策略,提升定位精度并加速收敛。

实验表明,MSI-YOLO 在提升检测准确度的同时,模型参数规模更小且具备实时性,为工业场景提供可行方案^[16]。

1. 宁夏师范大学物理与电子信息工程学院人工智能与基础教育宁夏重点实验室 宁夏固原 756000

1 YOLO11 模型改进

YOLO11 由特征提取主干网络 (Backbone)、特征融合颈部 (Neck) 网络和检测头 (Detect Head) 组成, 如图 1 所示。在钢材表面缺陷检测中, 骨干模块负责基础特征提取任务, 主要从原始图像中捕获与缺陷类型相关的关键信息; Neck 模块通过特征融合机制, 将骨干网络输出的浅层细节特征与深层语义特征进行整合, 增强缺陷特征的表达能力; Head 模块作为最终检测端, 根据融合后的特征对图像数据进行分类与定位, 从而实现对钢材表面缺陷的精准识别和结果输出^[17]。




图 1 YOLO11 网络结构

尽管 YOLOv11 在目标检测领域表现优异, 但在实际应用中仍存在局限: 感受野较大导致小目标空间定位和类别判断精度不足; 对特征不明显目标易出现分类模糊, 且特征金字塔架构简单, 多尺度特征表达能力欠佳, 难以满足不同尺寸目标检测需求。为此, 提出基于 YOLO11 的缺陷检测模型 MSI-YOLO 以解决上述问题, 其结构如图 2 所示。




图 2 MSI-YOLO 网络结构

1.1 MSDA 注意力机制模块

为了解决多尺度与小目标检测难题, 本文在特征融合网络中引入多尺度空洞注意力模块 (MSDA), 其结构如图 3 所示。采用多头并行设计, 通过多尺度扩张机制来有效捕捉不同尺度的语义信息, 其核心架构包括线性投影层、头部分离、多尺度注意力计算和特征聚合四个部分。具体来说, 就是把输入特征图 X 通过三个不同的线性层进行投影, 得到 query (Q)、key (K)、value (V) 三个矩阵, 通过把输入特征图的通道数分成 n 个头 (Head), 降低每个头的计算负担。每个头使用不同的空洞率 (通常为 $r=1, 2, 3, 4$) 来进行滑动窗口膨胀注意力 (SWDA) 计算, 分别对应 3×3 、 5×5 、 7×7 、 9×9 的感受野, 最后将所有头部输出进行拼接, 再通过线性层进行特征融合。其中小空洞率关注局部细节特征, 大空洞率捕获远距离上下文信息。该模块可同时捕捉多尺度语义信息, 在提升小目标检测精度的同时降低计算复杂度与参数量, 实现兼顾精度与速度的工业级检测。




图 3 MSDA 模块的结构

1.2 Slim-neck 模块

为降低模型的参数与复杂度, 颈部网络中的原始卷积层 (Conv) 和 C3k2 模块被 GSCConv 模块与 VoV-GSCSP 模块替代。许多轻量级模型采用深度可分离卷积 (DWC) 来减少参数数量与浮点运算量 (FLOPs), 但在计算过程中会分离输入图像的通道信息, 导致特征表示能力弱于标准卷积 (SC), 为克服这一缺陷, GSCConv 提出了一种混合策略: 通过对 SC 和 DWC 生成的特征进行通道打乱 (shuffle), 使 DWC 的输出尽可能接近 SC 的性能。GSCConv 的实现流程如图 4 所示, 促进了所有通道之间鲁棒且高效的信息交换, 在计算效率和表征能力之间实现了有效平衡。




图 4 GSCConv 模块结构

VoV-GSCSP^[18] 是一种利用 GSBottleneck 搭建的跨层级特征融合网络模块, 主要由 GSConv 和标准卷积层 (Conv) 构成, 目的是在不影响检测精度的前提下通过简化计算步骤降低网络结构的复杂度, 实现模型的轻量化。图 5 为 VoV-GSCSP 的结构, 输入特征图被分为主路和旁路, 将两路得到的特征进行融合, 在增强模型特征提取能力的同时, 降低了计算复杂度与参数量。




图 5 VoV-GSCSP 模块的结构

Slim-neck 颈部网络由 GSConv 与 VoV-GSCSP 协同构建。其中, GSConv 模块负责进行轻量化混合卷积运算, VoV-GSCSP 模块则起到跨级特征融合的作用, 二者相互配合, 在保障模型检测性能的同时, 极大降低计算成本, 适用于实时检测任务以及计算资源受限的应用场景。

1.3 优化损失函数

在实际检测场景中, 由于缺陷目标存在尺度差异、小缺陷占比高、样本分布不均等问题, 而 YOLOv11 默认的 CIoU 损失函数在处理不规则形状缺陷目标时判别能力有限, 且缺乏对不同样本的自适应调整机制, 因此存在一定的局限性。

针对这些问题, 引入 Inner-DIoU 损失函数, 尤其是在 Inner-IoU 损失函数^[19]。基础上的优化, Inner-IoU 损失函数如图 6 所示。




图 6 Inner-IoU 示意图

使用可调节的缩放因子 (ratio), 根据预测框与真实框的 IoU 值动态生成不同尺度的辅助边界框进行计算: 对于高 IoU 样本, 设置 ratio 小于 1, 生成较小的辅助框以加速收敛; 对于低 IoU 样本, 设置 ratio 大于 1, 生成较大的辅助框以扩大有效回归范围, 本文设置 ratio=0.75。

Inner-DIoU 在 Inner-IoU 的基础上添加中心距离和宽高比惩罚项, 通过动态权重实现对不同尺度、形状缺陷目标的自适应调整, 既保留了 Inner-IoU 对冗余区域的抑制能力, 又通过几何属性优化解决了小目标定位模糊、不规则缺陷形状适配性差等问题, 提升精度的同时加速模型收敛。其公式分别为:

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

$$IoU_{inner} = \frac{inter}{union} \quad (2)$$

$$L_{DIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} \quad (3)$$

$$L_{inner-DIoU} = L_{DIoU} + IoU - IoU_{inner} \quad (4)$$

式中: A 、 B 分别为真实框与预测框的区域集合, $inter$ 为真实框与预测框的交集, $union$ 为真实框与预测框的并集^[20], $\rho^2(b, b^{gt})$ 为预测框与真实框中心点的欧几里得距离平方。

2 实验与结果分析

2.1 数据集

本文数据集采用东北大学发布的钢材表面缺陷样本数据集 NEU-DET^[21] 进行实验验证。NEU-DET 数据集包含 1 800 张图片和 6 种典型钢材表面缺陷, 分别为: 裂纹 (crazing)、夹杂 (inclusion)、斑块 (patches)、划痕 (scratches)、氧化轧皮 (rolled in scale) 和点蚀面 (pitted surface), 每个类别各 300 张, 分辨率为 200 px×200 px, 均为灰度图像。将原始数据集以随机选择的方式按照 8:2 的比例分为训练集 (1 440 张)、验证集 (360 张)。各类缺陷图如图 7 所示。




图 7 NEU-DET 缺陷图像示例

2.2 实验环境配置

本实验的操作系统为 Windows11, GPU 为 NVIDIA

GeForce RTX 5070，显存为 8 GB，CPU 为 AMD Ryzen 9 8945HX with Radeon Graphics，编程语言为 Python 3.13，深度学习框架：PyTorch 2.8.0+CUDA12.8，Batchsize 为 16，训练轮数为 300 轮，图片尺寸为 640 px×640 px，使用 SGD 优化器，学习率为 0.01。

2.3 评估标准

为全面评估模型的性能，使用常用的指标：精度（Precision, P ）、召回率（Recall, R ）、平均精度均值（mAP），其中 mAP@0.5 表示 IoU 为 0.5 阈值处的 mAP，mAP@0.5-0.95 则表示 IoU 为 0.5~0.95 阈值的平均 mAP。

精度是指所有被预测为正的样本中实际为正的样本的概率，公式为：

$$P = \frac{TP}{TP+FP}$$
(5)

召回率是指实际为正的样本中被预测为正样本的概率，公式为：

$$R = \frac{TP}{TP+FN}$$
(6)

式中：TP 表示被正确识别为正样本的数量，FP 表示被错误分类为正样本的数量，FN 表示被错误地分类为负样本的数量。

mAP 常用于评估检测精度或目标检测模型准确度的指标，公式为：

$$AP = \int_0^1 P(R)d(R)$$
(7)

$$mAP = \frac{1}{k} \sum_{i=1}^k AP_i$$
(8)

2.4 消融实验

为了验证 MSI-YOLO 中每个新增模块对模型性能的提升效果，以 YOLOv11 作为基础模型，逐个添加各个模块，包括多尺度空洞注意力模块（MSDA），GSCConv 与 VoV-GSCSP 组成 Slim-neck 颈部网络架构和 Inner_DIoU 损失函数。使用 NEU-DET 数据集进行实验，实验结果如表 1 所示。

实验结果显示，各模块均对模型性能提升有所贡献，但它们的侧重点不同。MSDA 模块主要提升模型的精确率（ P ），其单独引入时，模型精确率由基线的 73.6% 提升至 81.2%，说明该模块能有效聚焦关键特征，减少误检。Slim-neck 模块的核心作用在于轻量化模型，在维持较高检测精度的同时，大大降低模型的参数量与计算复杂度，实现了模型的轻量化设计。Inner_DIoU 模块则有助于提升综合精度指标（mAP@0.5），其单独使用时 mAP@0.5 达到 78.7%，有效提高了精度与收敛稳定性。当 MSDA、Slim-neck 与 In-

表 1 消融实验结果

YOLOv11	MSDA	Slim-neck	Inner_DIoU	$P/\%$	mAP@0.5/%	Params/ 10^6
√				73.6	77.8	2.6
√	√			81.2	79.1	2.8
√		√		73.6	79.0	2.5
√			√	77.2	78.7	2.6
√	√	√		72.5	77.8	2.8
√	√		√	71.6	76.8	2.9
√		√	√	74.4	78.3	2.5
√	√	√	√	76.2	80.2	2.8

ner-DIoU 三个模块共同作用时，MSI-YOLO 模型取得了最佳的综合性能（mAP@0.5:80.2%），参数量控制在 2.8×10^6 ，充分证明了本文所改进的有效性与协同性，能够在保持模型轻量化的同时，显著提升检测精度与综合性能。

2.5 对比试验

2.5.1 不同损失函数的比较分析

为了验证本文提出的模型中 Inner-DIoU 损失函数的效果，我们采用不同损失函数进行对比实验，具体结果如表 2 所示。从各类 IoU 损失函数在检测性能和收敛效率上的比较可以看出，边界框回归损失的选择对模型结果影响很大。数据显示，Inner-DIoU 是综合表现最佳的损失函数，其 mAP@0.5 达到 80.2%，排名第一，同时保持了较高的精确率（76.2%）和召回率（74.5%），这说明它在目标定位精度和检测稳定性之间取得了很好的平衡。相比之下，其他损失函数在关键指标上均有明显不足：比如 EIoU 精确率虽然最高（78.5%），但召回率过低（70.1%），而 MPDIoU 虽召回率最高（77.4%），精确率却明显偏低（69.0%）。

表 2 不同损失函数的比较实验

单位：%				
Loss Function	P	R	mAP@0.5	mAP@0.5-0.95
CIoU	72.5	74.5	77.8	44.7
DIoU	77.0	72.8	78.5	45.1
SIoU	74.5	73.3	78.8	46.1
EIoU	78.5	70.1	78.4	45.5
MPDIoU	69.0	77.4	79.0	44.3
WIoU V3	78.2	71.9	79.8	44.9
FocuSIoU	77.4	71.8	78.8	45.3
ShapEIoU	75.0	72.2	78.3	45.1
Inner_CIoU	75.3	74.6	79.2	45.3
Inner_GIoU	76.6	72.0	77.7	43.6
Inner_SIoU	74.1	72.1	77.5	44.2
Inner_DIoU	76.2	74.5	80.2	45.6

2.5.2 与其他基准模型的比较实验

为了进一步证实本文提出的 MSI-YOLO 相对于其他算法的优越性,对 MSI-YOLO 与主流目标检测模型 YOLOv5、YOLOv6、YOLOv8、YOLOv10、YOLOv11、YOLOv12,两阶段检测模型 Faster R-CNN^[4] 以及 SSD^[7] 算法进行了性能对比实验,对比实验结果如表 3 所示。在 NEU-DET 数据集上的综合实验评估表明,MSI-YOLO 模型在检测精度和效率上均表现出明显优势:在主要评估指标 mAP@0.5 上,MSI-YOLO 达到了 80.2%,不仅优于 SSD (68.5%)、Faster R-CNN (63.2%) 及 YOLO 系列对比模型 (77.6%~77.9%),在更严格的 mAP@0.5-0.95 指标上,MSI-YOLO 同样以 45.6% 的表现保持领先,同时其精确率 (76.2%) 和召回率 (74.5%) 也达到较高水平,显示出其在不同置信度阈值下均具备良好的检测稳定性。在模型复杂度方面,MSI-YOLO 参数量仅需 2.8×10^6 和 FLOPs 计算量需 6.0×10^9 ,优于 YOLOv6 (11.7×10^9)、YOLOv8 (8.1×10^9) 等模型,与计算量相近的 YOLOv11 (6.3×10^9) 相比,在 mAP@0.5 上实现了 2.4 个百分点的提升,实现了精度与效率的突破性平衡,为钢材表面缺陷检测提供高精度且轻量化的解决方案。

2.6 可视化结果

图 8 展示了模型在训练与验证过程中各项指标的变化情况。整体来看,模型收敛过程比较平稳,没有出现明显的波动。训练损失与验证损失均随迭代轮次增加而呈现单调递减趋势,且曲线平滑未出现过拟合。同时, Precision、Recall 以及 mAP@0.5 等关键性能指标都稳步上升并最终趋于平稳,该结果,模型经过 300 个 epoch 的训练后达到了充分拟合状态,具备可靠检测能力。

图 9 展示了划痕 (scratches) 缺陷在不同模型上的可视化检测结果对比, YOLOv11 模型对划痕缺陷存在漏检,而 MSI-YOLO 模型有效避免漏检,且对各类缺陷的检测精度优于原始模型,验证了其高性能与泛化能力。

表 3 NEU-DET 数据集上不同模型的比较

	P/%	R/%	mAP@0.5/%	mAP@0.5-0.95/%	Params/ 10^6	FLOPs/ 10^9
SSD	—	—	68.5	31.9	—	—
Faster R-CNN	—	—	63.2	29.2	—	—
YOLOv5	71.2	74.5	77.7	44.1	2.5	7.1
YOLOv6	75.3	71.2	77.6	44.5	4.2	11.7
YOLOv8	76.0	72.5	77.7	44.6	3	8.1
YOLOv10	72.8	69.8	75.5	42.8	2.3	6.5
YOLOv11	73.6	72.5	77.8	44.9	2.6	6.3
YOLOv12	72.0	75.1	77.9	33.6	2.6	6.3
MSI-YOLO	76.2	74.5	80.2	45.6	2.8	6.0






图 8 损失函数和性能指标变化



(a) YOLOv11 缺陷检测结果



(b) MSI-YOLO 缺陷检测结果

图 9 可视化检测结果对比

3 结论

为解决钢材表面缺陷检测中小目标漏检、多尺度特征提取不足及模型复杂度高等问题,本文提出改进轻量化检测算法 MSI-YOLO。该算法通过引入多尺度扩张注意力模块 (MSDA) 增强微小缺陷特征捕捉,构建 Slim-neck 结构降低计算成本,并采用 Inner-DIoU 损失优化边界框回归。实验表明,MSI-YOLO 在 NEU-DET 数据集的 mAP@0.5 为 80.2%, 优于 YOLOv5、YOLOv8 等主

流模型, 参数量仅 2.8×10^6 , 计算量 6.0×10^9 , 实现精度与效率的平衡。消融实验验证了各模块有效性: MSDA 提升低对比度缺陷关注度, Slim-neck 显著降低复杂度, Inner-DIoU 加速收敛并提高定位精度。综上, MSI-YOLO 具备高检测精度、轻量化特性及实时性, 适用于工业现场质检系统, 为智能制造自动化质量控制提供有效技术支持。

参考文献:

- [1] Liu Yajiao, Wang Jiang, Yu Haitao, et al. Surface defect detection of steel products based on improved YOLOv5[C] //2022 41st Chinese Control Conference (CCC). Piscataway:IEEE,2022: 5794-5799.
- [2] Ge Jiuhao, Hu Baowang, Yang Chenkai, et al. Surface profile reconstruction of complex cracks using the signals of rotating eddy current testing through the eddy current imaging method[J]. IEEE Transactions on Industrial Electronics, 2023, 70(9): 9632-9641.
- [3] Xie Jing, Yang Xiaoyan, Xu Changhang, et al. Infrared thermal images detecting surface defect of steel specimen based on morphological algorithm[J]. Journal of China University of Petroleum, 2012, 36(3): 146-150.
- [4] Ren Shaoqing, He Kaiming, 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.
- [5] He Kaiming, Gkioxari G, Dollar P, et al. Mask R-CNN[C]// 2017 IEEE International Conference on Computer Vision (ICCV). Piscataway:IEEE, 2020: 386-397.
- [6] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C/OL]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway:IEEE, 2017: 6517-6525.
- [7] Liu Wei, Dragomir A, Dumitru E, et al. SSD: single shot multibox detector[C]// Computer Vision – ECCV 2016 . Berlin:Springer, 2016: 21-37.
- [8] 许德刚, 王露, 李凡. 深度学习的典型目标检测算法研究综述 [J]. 计算机工程与应用, 2021, 57(8): 10-25.
- [9] 梁礼明, 陈康泉, 钟奕, 等. DCD-YOLOv8n: 一种高效的钢材表面缺陷检测算法 [J]. 计算机工程与应用, 2025, 61(7): 117-127.
- [10] Kou Xupeng, Liu Shuaijun, Cheng Kaiqiang, et al. Development of a YOLOv3-based model for detecting defects on steel strip surface[J]. Measurement, 2021, 182: 109454.
- [11] 周孟然, 王昊男, 高立鹏, 等. 基于 YOLOv5s-FCS 的钢材表面缺陷检测 [J]. 科学技术与工程, 2024, 24(14): 5901-5910.
- [12] Wang Yang, Wang Hongyuan, Xin Zihao. Efficient detection model of steel strip surface defects based on YOLOv7[J]. IEEE Access, 2022, 10: 133936-133944.
- [13] 彭菊红, 张弛, 高谦, 等. 基于改进的 YOLOv8 算法的钢材缺陷检测 [J]. 计算机工程, 2025, 51(7): 152-160.
- [14] 徐薪羽, 沈通, 吕佳. 基于改进 YOLOv8 算法的钢材表面缺陷检测 [J]. 自动化应用, 2024, 65(15): 6-10.
- [15] Li Zhaoguo, Wei Xiumei, Hassaballah M, et al. A deep learning model for steel surface defect detection[J]. Complex & Intelligent Systems, 2023, 10: 885-897.
- [16] Li Bingyi, Xiao Andong, Hu Xing, et al. NGD-YOLO: an improved real-time steel surface defect detection algorithm[J]. Electronics, 2025, 14(14): 2859.
- [17] Zhang Laomo, Wang Zhike, Ma Ying, et al. Steel surface defect detection algorithm based on improved YOLOv10[J/OL]. Scientific Reports, 2025[2026-05-23]. <https://www.nature.com/articles/s41598-025-16725-8>.
- [18] Yi Weiguo, Ma Siwei, Li Ronghua. Insulator and defect detection model based on improved YOLOs[J/OL]. IEEE Access, 2023, 11: 93215-93226.
- [19] Zhang Hao, Xu Cong, Zhang Shuaijie. Inner-IoU: more effective intersection over union loss with auxiliary bounding box[PP/OL]. (2023-11-14)[2026-05-23]. <https://doi.org/10.48550/arXiv.2311.02877>.
- [20] 戴林华, 黎远松, 石睿. 基于改进 YOLOv8 的带钢表面缺陷检测算法 [J]. 制造技术与机床, 2024(11): 139-148.
- [21] Yeung C C, Lam K M. Efficient fused-attention model for steel surface defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2022: 2510011.

【作者简介】

董铭扬 (2002—), 女, 辽宁阜新人, 硕士研究生, 研究方向: 深度学习、目标检测、缺陷识别。

赵飞燕 (1981—), 通信作者 (email: zfynd@163.com), 女, 宁夏固原人, 硕士, 副教授, 研究方向: 计算机视觉与图像处理。

任哲 (2001—), 男, 山西运城人, 硕士研究生, 研究方向: 深度学习、目标检测、缺陷识别。

(收稿日期: 2025-11-25 修回日期: 2026-06-02)