

基于深度学习的金属表面缺陷检测算法

周俊杰, 王 锦*

天津职业技术师范大学电子工程学院, 天津

收稿日期: 2026年7月20日; 录用日期: 2026年8月20日; 发布日期: 2026年8月28日

摘 要

针对金属表面缺陷检测存在背景纹理干扰强、缺陷尺度跨度大、微细缺陷易漏检、模糊缺陷定位不准等问题, 本文基于YOLOv12n模型, 从特征提取、边界回归与激活函数三个维度进行针对性改进, 提出一种适用于金属表面缺陷检测的优化算法。通过构建A2C2f_DFFN_DYT_Mona多尺度频域特征增强模块, 强化复杂背景下的缺陷特征提取能力, 弥补原生模型特征表征不足的缺陷; 融合MPDIoU、Focaler-IoU与动态Wise-IoUv3损失机制, 自适应平衡难易样本权重, 有效抑制标注噪声干扰, 提升微小、模糊缺陷的边界定位精度; 引入Hardswish轻量化激活函数替换SiLU激活函数, 在保证特征拟合能力的前提下降低推理开销, 提升模型实时检测性能。实验结果表明, 相较于原始YOLOv12n模型, 本文改进算法的精度、召回率、mAP50-95与全流程FPS分别提升1.24%、3.07%、0.46%、0.71%, 在提升精度的同时保持了高效率, 能够有效满足工业金属缺陷实时质检需求。

关键词

缺陷检测, YOLOv12, A2C2f_DFFN_DYT_Mona, Wise-IoU, Hardswish

Metal Surface Defect Detection Algorithm Based on Deep Learning

Junjie Zhou, Jin Wang*

School of Electronic Engineering, Tianjin University of Technology and Education, Tianjin

Received: July 20, 2026; accepted: August 20, 2026; published: August 28, 2026

Abstract

For problems such as strong background texture interference, large defect scale range, easy missed detection of micro-defects, and inaccurate positioning of blurry defects in metal surface defect detection, this paper improves the YOLOv12n model from three dimensions: feature extraction, boundary regression, and activation functions, and proposes an optimized algorithm suitable for

*通讯作者。

metal surface defect detection. By constructing the A2C2f_DFFN_DYT_Mona multi-scale frequency domain feature enhancement module, the defect feature extraction ability in complex backgrounds is strengthened, and the deficiency of insufficient feature representation in the original model is compensated; by integrating the MPDIoU, Focaler-IoU and dynamic Wise-IoUv3 loss mechanisms, the weights of difficult and easy samples are adaptively balanced, and the interference of annotation noise is effectively suppressed, improving the boundary positioning accuracy of tiny and blurry defects; by introducing the Hardswish lightweight activation function to replace the SiLU activation function, the feature fitting ability is ensured while reducing the inference cost, and the real-time detection performance of the model is improved. Experimental results show that compared with the original YOLOv12n model, the improved algorithm's accuracy, recall rate, mAP50-95 and the overall FPS have increased by 1.24%, 3.07%, 0.46% and 0.71% respectively. While improving the accuracy, it maintains high efficiency and can effectively meet the real-time quality inspection requirements of industrial metal defects.


Keywords

Defect Detection, YOLOv12, A2C2f_DFFN_DYT_Mona, Wise-IoU, Hardswish

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

金属构件是机械、冶金及精密装备行业的重要基础部件,其表面质量直接决定产品良品率与设备服役安全性。工件在加工生产过程中极易产生各类表面缺陷,若无法及时精准检测,易引发设备故障与安全隐患。因此,高效、精准的缺陷检测技术能够有效规避生产风险,指导企业优化加工工艺,对推动工业质检智能化升级具有重要研究意义与工程价值。

在传统工业质检模式中,金属缺陷检测多依赖人工目视筛查,存在检测效率低、误检率高、稳定性差等问题,难以满足现代化工业批量生产需求。随着人工智能技术发展,深度学习检测算法已成为金属缺陷检测主流方案,其中以 YOLO、SSD [1] 为代表的单阶段算法凭借推理速度快、部署便捷的优势应用最为广泛。目前国内学者已开展大量优化研究:Zhu 等人[2]基于 YOLOv8s 改进特征增强模块,提升了复杂场景微小缺陷检测精度;Cao 等人[3]结合剪枝与知识蒸馏策略实现 YOLOv8 模型轻量化升级;卢开喜等人[4]优化 YOLOv7-tiny 特征融合结构与损失函数,提升了金属表面缺陷检测性能;盛良浩等人[5]通过注意力与卷积重构模块改进 YOLOv8,有效平衡了检测精度与模型体量。

现有检测算法在金属检测任务中虽取得一定效果,但金属表面缺陷存在特征识别难度大、抗干扰性弱、样本分布不均等问题,模型泛化能力有所欠缺。因此,本文在 YOLOv12 的基础上提出改进模型,提升金属表面缺陷检测精度的同时保持高效率。

2. 改进的 YOLOv12 算法

针对金属表面缺陷检测场景,存在缺陷类别繁杂、工件表面纹理干扰强、缺陷尺度跨度较大等难题。将 YOLOv12 模型直接应用于该检测任务,容易出现特征挖掘不充分、微细缺陷漏检、目标定位精度偏低等问题。因此,本文在 YOLOv12 基础上完成多维度针对性改进:通过搭建 A2C2f_DFFN_DYT_Mona 特征增强结构替换原有基础模块,依托多尺度自适应与频域聚合优势,强化复杂背景下缺陷特征的提取能力;采用优化后的特征融合结构,改善多尺度特征融合效果,缓解样本尺度差异带来的检测误差;引入 Wise-IoUv3 动态损失函数优化边界回归逻辑,提升微小缺陷与模糊缺陷的定位精度;同时替换轻量化 Hardswish 激活函数,降低模型推理算力消耗。本文改进后的 YOLOv12

网络整体结构如图 1 所示。




Figure 1. Improved YOLOv12 network structure diagram
图 1. 改进后的 YOLOv12 网络结构图

2.1. A2C2f_DFFN_DYT_Mona 模块

常规 YOLOv12 原生 A2C2f 模块虽搭载区域注意力机制，但内部前馈网络仅采用基础卷积结构，难以充分挖掘频域全局特征，且缺少专用多尺度特征适配模块，在金属缺陷检测的复杂工况下特征提取能力存在明显短板。为此，本文设计 A2C2f_DFFN_DYT_Mona 模块，如图 2 所示，图 2 左侧为 ABlock_DFFN_DYT_Mona 子单元内部数据流，右侧为 A2C2f_DFFN_DYT_Mona 完整模块整体架构，该模块可同步完成多尺度特征聚合、空间注意力建模与频域信息感知，仅小幅增加计算开销即可有效提升复杂场景下的缺陷检测精度。模块采用多分支并行结构实现多层次特征融合，依托内嵌的混合注意力单元自适应强化缺陷有效特征、抑制无关背景干扰，同时结合轻量化瓶颈结构，兼顾检测精度与工业场景的实时推理需求[6] [7]。

A2C2f_DFFN_DYT_Mona 是在 YOLOv12 原生 A2C2f 容器架构基础上进行改进，将内部标准 ABlock 单元替换为 ABlock_DFFN_DYT_Mona 混合注意力单元，显著增强模型的多尺度、跨维度特征交互与融合能力。针对金属表面尺度差异悬殊的各类缺陷，该模块可有效联动浅层轮廓、中层纹理与全局频域特征，弥补原生 A2C2f 前馈网络表征能力薄弱、缺乏多尺度自适应调整机制的不足。模块内部设置多路并行特征分支，构建多条梯度流通路，缓解深层网络训练过程中的梯度消失问题。内嵌的 ABlock_DFFN_DYT_Mona 单元融合区域注意力、动态 DYT 激活、双频聚合 DFFN 前馈网络与 Mona 多尺度适配器。本文将 DFFN、Mona、DYT 三类组件组合搭配并非简单叠加，而是针对金属缺陷检测场景形成完整互补链路：DYT 动态激活作为前置调制器，自适应调整特征映射阈值，放大微小模糊缺陷的弱特征响应、压制杂乱干扰；DFFN 双频前馈网络弥补原生模块缺失频域建模的缺陷，分离高低频特征以区

分缺陷有效纹理与金属基材自带的背景噪声；Mona 多尺度适配器作为后置特征精炼模块，专门应对金属工件缺陷尺寸跨度极大的问题，对提取后的特征进行多尺度融合对齐。三者分工明确、无功能冗余，形成“弱特征增强→频域降噪→尺度适配”的串行互补链路，从弱特征增强、频域降噪、尺度适配三个维度补齐原生模块短板，双向强化空间局部细节特征与全局频域特征，促进跨通道信息互补，最终输出区分度更高、鲁棒性更强的缺陷特征表征。




Figure 2. A2C2f_DFFN_DYT_Mona module
图 2. A2C2f_DFFN_DYT_Mona 模块

2.2. Wise-IoU 边界框回归损失函数

2.2.1. MPDIoU 基础度量框架

为提升缺陷目标边界回归精度，本文采用 MPDIoU 作为边界框相似度度量基础框架。相较于传统 IoU 仅依靠重

叠面积衡量框体相似度, MPDIoU 引入双角点距离约束机制, 通过最小化预测框与真实框对角点欧式距离, 实现重叠与非重叠场景下的稳定回归能力, 具备更强的几何位置感知特性[8]。

MPDIoU 的计算方式由传统交并比与归一化角点距离惩罚项共同构成, 整体定义如下:

$$\text{IoU} = \frac{I}{A^{\text{gt}} + A^{\text{prd}} - I} \quad (1)$$

$$\text{MPDIoU} = \text{IoU} - \frac{d_1^2}{h^2 + w^2} - \frac{d_2^2}{h^2 + w^2} \quad (2)$$

$$l_{\text{MPDIoU}} = 1 - \text{MPDIoU} \quad (3)$$

式中 I 表示预测框与真实框相交区域的面积, A^{gt} 和 A^{prd} 分别代表真实框和预测框的面积, d_1 、 d_2 为边界框对应角点间的欧式距离, h 、 w 分别为输入图像的高和宽。该设计通过归一化处理确保距离惩罚项与图像尺寸无关。

2.2.2. Focaler-IoU 增强机制

针对金属缺陷边界模糊、低对比度样本难优化的问题, 本文引入 Focaler-IoU 非线性重参数化增强策略, 对原始损失分布进行动态重构。通过引入上下界阈值与聚焦因子, 重塑不同质量样本的梯度贡献权重, 实现难易样本自适应均衡优化。

其损失表达式为:

$$\mathcal{L}_{\text{Focal}} = \left(1 - \frac{\text{IoU} - d}{u - d}\right)^{\gamma} \cdot \mathcal{L}_{\text{MPDIoU}} \quad (4)$$

式中 d 为下界阈值, u 为上界阈值, γ 为聚焦因子。该机制通过指数映射实现梯度重分配: 对高 IoU 简单样本进行损失压缩, 弱化其在反向传播中的主导作用; 同时相对放大低 IoU 难样本的梯度权重。金属表面油斑、锈蚀等边界模糊缺陷普遍存在标注不确定性, 导致模型收敛难度大, Focaler-IoU 可有效提升此类低质量样本的优化优先级, 增强模型对模糊缺陷边界的感知能力。

2.2.3. 动态聚焦机制(v3)

为进一步抑制标注噪声与离群样本干扰, 本文采用动态聚焦梯度调制机制, 依托样本实时损失分布特征自适应调整梯度权重。该机制通过样本离群度与动态聚焦系数双变量实现自适应损失校正。

离群度 β 与聚焦系数 γ 定义为:

$$\beta = \frac{\mathcal{L}_{\text{IoU}}}{\bar{\mathcal{L}}_{\text{IoU}}} \quad (5)$$

$$\gamma = \frac{\beta}{\delta \alpha^{\beta - \delta}} \quad (6)$$

最终加权损失为:

$$\mathcal{L}_{\text{WIoUv3}} = \gamma \cdot \mathcal{L}_{\text{Focal}} \quad (7)$$

式中 $\mathcal{L}_{\text{IoU}}$ 为当前样本的 IoU 损失值, $\bar{\mathcal{L}}_{\text{IoU}}$ 为历史 IoU 损失的指数滑动平均, α 与 δ 为可配置超参数。离群度 β 用于判别样本难易程度: $\beta \approx 1$ 为常规样本, 保持原始梯度; $\beta \gg 1$ 为过拟合简单样本, 自动抑制梯度贡献; $\beta \ll 1$ 为噪声离群样本, 通过聚焦系数自适应降噪。该机制适配金属缺陷检测复杂工况: 针对油斑边界歧义、微小冲孔噪声干扰等问题, 动态过滤无效梯度、稳定训练收敛, 同时加速难样本缺陷的拟合精度, 大幅提升模型整体鲁棒性[9]。

2.3. Hardswish 激活函数

YOLOv12 采用 SiLU 作为卷积层激活函数, 凭借平滑连续的梯度获得稳定的训练效果, 但函数内部包含 Sigmoid 指数运算, 在嵌入式与工业边缘设备上推理时算力开销较大; 同时 SiLU 负区间梯度衰减速度较慢, 针对金属微小缺陷

这类弱特征, 梯度传递效率仍存在优化空间。为此, 本文将网络中原有的 SiLU 替换为轻量化 Hardswish 分段线性激活函数, 通过基础四则运算替代指数运算, 在保留非线性拟合能力的同时降低推理延迟, 更契合工业检测实时部署的需求。

Hardswish 分段数学定义为:

$$\text{Hardswish}(x) = \begin{cases} 0, & x \leq -3 \\ \frac{x(x+3)}{6}, & -3 < x < 3 \\ x, & x \geq 3 \end{cases} \quad (8)$$

相较于 SiLU, Hardswish 无指数、对数复杂算子, 前向与反向传播计算量大幅缩减; 对比 ReLU, 其负区间具备连续非零梯度, 能够避免神经元永久坏死, 完整保留划痕、微孔等低对比度微小缺陷的特征梯度[10]。在金属缺陷检测场景下, 替换后的模型可在精度损失极小的前提下提升硬件推理速度, 兼顾特征提取能力与工程落地实时性。

3. 实验结果与分析

3.1. 数据集构建与实验环境

本文数据集来自 AI Studio 网络平台上公开的金属表面缺陷数据集, 选取 5 类缺陷的 1819 张高分辨率图像(冲孔、焊缝、油斑等), 以 8:1:1 的比例划分为训练集、验证集与测试集。

本次实验均在云服务器上实现, 具体实验环境如表 1 所示。

Table 1. Experimental environment

表 1. 实验环境

名称	参数
CPU	18 vCPU AMD EPYC 9754 128-Core Processor
内存	60 GB
GPU	NVIDIA RTX 4090D (24 GB)
操作系统	Ubuntu 22.04.1
编译软件	Jupyter Notebook
GPU 加速库	CUDA11.8
环境	Pytorch2.2.2+cu121、Anaconda_python3.11.11

3.2. 评估指标

为全面评估本文算法在金属表面缺陷检测任务中的综合性能, 选取精确率(Precision, P)、召回率(Recall, R)、mAP50-95 与全流程 FPS 作为评价指标: Precision 用于衡量模型抑制误检的能力, Recall 表征缺陷目标的查全能力, mAP50-95 反映模型对缺陷边界的精细定位精度, FPS 代表全流程每秒处理图像帧数用于评估模型的实时推理速度。部分计算公式如下:

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

$$AP = \int_0^1 P(y) dy$$

$$mAP = \frac{1}{n} \sum_{i=0}^n AP_i \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

式中 TP 为真正例即模型预测正确且成功的正样本, FN 为假负例即模型没有检测出来的真实目标。

3.3. 实验结果分析

本实验共训练 300 轮, 输入图片尺寸设置为 640×640 , 对比实验结果如表 2 所示。在测试集上, 改进算法对比 YOLOv12n 的精确率、mAP50-95、召回率、全流程 FPS 均有提升, 涨幅依次为 1.24%、0.46%、3.07%、0.71%; 相较于 YOLO 系列其他版本算法, 本文方法也存在一定性能优势。

Table 2. Comparison experiments

表 2. 对比实验

模型	<i>P</i>	mAP50-95	<i>R</i>	FPS
YOLOv6n	73.75	31.89	60.83	183.14
YOLOv8n	77.19	32.27	58.8	157.16
YOLOv11n	80.26	32.22	61.6	195.65
YOLOv12n	82.48	32.65	59.69	198.3
本文	83.72	33.11	62.66	199.01

4. 总结

本文针对金属表面缺陷检测的复杂工况, 基于 YOLOv12n 模型完成多维度优化改进。通过特征增强模块强化缺陷特征提取能力, 依托优化损失函数提升缺陷边界定位精度, 搭配轻量化激活函数在提升检测精度的同时维持较高推理效率。实验证明, 本文改进算法相较于原生 YOLOv12n, 四项核心指标均稳步提升, 综合性能优于多款主流轻量化 YOLO 模型, 能够有效适配金属缺陷智能检测场景。但本文算法仍存在明确局限性, 模型对工件表面极低对比度的微小模糊缺陷识别效果不佳, 同时模块叠加带来模型整体计算开销小幅上涨, 无法适配算力资源极度受限的嵌入式设备。后续将针对性开展轻量化结构重构与模型剪枝压缩工作, 降低模型参数量与运算量, 同时面向低对比度微小缺陷优化特征提取支路, 强化弱缺陷特征表达, 进一步提升模型泛化能力与工业场景落地实用性。

参考文献

- [1] Ma, J., Zhou, Y., Zhou, Z., Zhang, Y. and He, L. (2025) Toward Smart Ocean Monitoring: Real-Time Detection of Marine Litter Using YOLOv12 in Support of Pollution Mitigation. *Marine Pollution Bulletin*, **217**, Article 118136. <https://doi.org/10.1016/j.marpolbul.2025.118136>
- [2] Zhu, Y. and Jia, S. (2026) An Improved YOLOv8-Based Algorithm for Industrial Metal Surface Defect Detection. *Journal of Electronic Research and Application*, **10**, 50-68.
- [3] Cao, Y., Yao, Y. and Lu, L. (2026) Lightweight Metal Surface Defect Detection Algorithm Based on Pruning and Knowledge Distillation. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-57496-0>
- [4] 卢开喜, 段先华, 陶宇诚, 等. KThin-YOLOv7: 轻量级的焊接件表面缺陷检测[J]. 电子测量技术, 2024, 47(7): 9-18.
- [5] 盛良浩, 贾小云, 白颖洁, 等. 基于 YOLOv8 的轻量化金属表面缺陷检测模型[J]. 科学技术与工程, 2026, 26(7): 2990-2999.
- [6] 韩涛, 于帅帅, 黄友锐, 等. PV-YOLOv12n: 多模态光伏组件故障检测模型[J]. 激光与光电子学进展, 2026, 63(6): 522-536.
- [7] 郑楠, 付帅, 刘依萍, 等. 面向复杂场景的 YOLOv11n 小目标交通标志检测算法[J/OL]. 电子技术应用: 1-9. <https://link.cnki.net/urlid/11.2305.TN.20260624.1435.002>, 2026-07-19.
- [8] 宋旭东, 顾亚良, 宋亮. 基于图像识别的 PCB 表面缺陷检测方法研究[J]. 大连交通大学学报, 2025, 46(5): 153-160.
- [9] Dang, C.T., Sato, H. and Kubo, M. (2025) EAW-YOLO11: Enhanced YOLO11 Network for Underwater Object Detection. *Artificial Life and Robotics*, **30**, 773-785. <https://doi.org/10.1007/s10015-025-01067-5>
- [10] 张振楷, 张浩, 信恒府, 等. 基于改进 LU2Net 的浑浊水偏振图像增强[J]. 电子测量技术, 2026, 49(4): 236-246.