

DOI:10.19651/j.cnki.emt.2518897

基于改进 YOLOv8 的轻量化钢材表面缺陷检测方法^{*}

胥姜苗 曹爽 管海燕

(南京信息工程大学遥感与测绘工程学院 南京 210044)

摘要: 钢材表面缺陷检测是保障制造业产品质量的关键环节,人工目视与基础光学检测方法存在效率低、漏检率高等问题,且现有数据集样本有限制约模型泛化能力。为此,本文提出一种基于 LS-DCGAN 数据增强与改进 YOLOv8 的轻量化钢材表面缺陷检测方法。首先针对 NEU-DET 数据集样本多样性不足的问题,采用 LS-DCGAN 生成对抗网络进行数据增强,有效补充缺陷样本的形态特征与分布特性;其次对 YOLOv8 模型进行三重优化提出 SPH-YOLO 检测算法:重构 C2f 模块结构增强特征提取能力,嵌入注意力机制提升缺陷区域聚焦度,设计多级特征融合金字塔实现跨尺度信息交互;最后在增强后的 NEU-DET 与 GC10-DET 数据集上进行验证,实验表明改进模型在 mAP@50% 指标上提升 3%,参数量减少 28.5%,计算量降低 12.3%,且改进方法具有泛化能力,检测有效地实现了检测模型轻量化和检测性能的平衡。

关键词: 钢材表面缺陷检测;YOLOv8;LS-DCGAN;轻量化模型

中图分类号: TP391.4; TN911 文献标识码: A 国家标准学科分类代码: 520.6040

Lightweight steel surface defect detection method based on the improved YOLOv8

Xu Jiangmiao Cao Shuang Guan Haiyan

(School of Remote Sensing and Geomatics Engineering Institute of Optics and Fine Mechanics, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Detection of surface defects in steel materials is a key link in ensuring the quality of products in the manufacturing industry. Manual visual inspection and basic optical detection methods suffer from low efficiency and high miss detection rates, and the limited samples of existing datasets restrict the model's generalization ability. Therefore, this paper proposes a lightweight steel surface defect detection method that integrates LS-DCGAN data augmentation with an improved YOLOv8 model. Firstly, to address the issue of insufficient sample diversity in the NEU-DET dataset, we use an LS-DCGAN generative adversarial network for data augmentation, effectively supplementing the morphological features and distribution characteristics of defect samples. Secondly, we conduct triple optimization on the YOLOv8 model to propose the SPH-YOLO detection algorithm: reconstructing the C2f module structure to enhance feature extraction capabilities, embedding an attention mechanism to improve focus on defect areas, and designing a multi-level feature fusion pyramid for cross-scale information interaction. Finally, we validate the improved model on the enhanced NEU-DET and GC10-DET datasets. Experimental results show that the improved model achieves a 3.2% increase in mAP@50%, a 28.5% reduction in parameter count, and a 12.3% decrease in computational load. Furthermore, the improvement method exhibits strong generalization ability, effectively balancing the lightweight nature of the detection model and its detection performance.

Keywords: steel surface defect detection; YOLOv8 algorithm; LS-DCGAN; lightweight model

0 引言

随着制造业智能化升级加速,钢材作为工业基础材料

在汽车制造、建筑工程、机械装备等领域的质量要求日趋严苛,钢材缺陷如裂纹、划痕、孔洞等不仅会影响产品的性能,还可能导致设备故障甚至安全事故^[1]。传统的钢材缺陷检

收稿日期:2025-05-23

*基金项目:国家自然科学基金面上项目(41971414)资助

测方法通常依赖人工目视检查或简单的光学检测设备,这些方法不仅耗时耗力,而且在检测过程中容易出现漏检或误检的情况^[2]。此外,现有钢材缺陷数据集样本数量有限,限制了模型的性能和泛化能力^[3]。

钢材缺陷数据集通常包含多种缺陷,仅仅靠图像采集很难获得充足且特征多样化的数据集。数据增强是解决数据量和数据多样性不足的有效方法,能够扩展样本规模并丰富特征表达空间,提升训练模型的泛化能力。文献[4-7]使用了几何变换和添加噪声等数据增强变换方式,优化了模型的性能,但对复杂纹理缺陷的特征多样性增强有限。除了传统的数据增强方法,生成对抗网络(generative adversarial network, GAN)也常常被用来进行数据增强。Wen 等^[8]通过向 CycleGAN 引入注意力机制来合成缺陷样本,在钢材和布匹数据集上提升了识别准确率,但该方法需配对无缺陷样本辅助生成,制约了其在仅需缺陷样本场景的应用。李春华等^[9]通过添加残差网络和注意力机制改进 DCGAN,增强了生成图像的结构真实性,但纹理细节多样性和微小缺陷生成能力仍有不足。

将生成对抗网络与目标检测模型相结合,已成为解决钢材缺陷检测中数据稀缺与模型性能瓶颈问题的一种有效策略。这种组合不仅能扩充数据集、丰富特征表达,更能直接优化最终检测模型的精度与泛化能力。当前研究主要采用分阶段式实现,近期研究探索了不同生成方式:黄鹏等^[10]通过优化 DCGAN 网络参数并调整生成器结构,生成高分辨率的钢丝帘布缺陷图像以扩充小样本数据集,有效提升了后续 YOLO 模型的检测精度和泛化能力。针对数据集中类别不平衡问题,沈明辉等^[11]提出了 Attention-GAN 模型,在生成器中引入注意力模块以生成更具多样性的缺陷图像,有效解决了某些类别样本不足的问题,再改进 YOLOv8s 模型,轻量化模型在提升检测精度的同时显著减少参数量,有效解决了漏误检率高的问题。梁喜凤等^[12]针对夜间低光照环境下数据质量差和模型特征提取能力不足的难题,融合改进 CycleGAN 生成高质量夜间图像扩充数据集,并构建 NTS-YOLO 模型,最终有效地改善模型在夜间环境下的分割效果。

在目标检测模型本身的研究方面,尤其是针对检测任务对实时性、精度和模型大小的综合需求,YOLO 系列^[13-14]算法因其高效性成为优选,并得到了广泛研究和改进。Lian 等^[15]通过知识蒸馏和预测尺度改进 YOLOv4 模型,mAP@0.5 提升 5.2%。杨森泉等^[16]引入坐标注意力机制,有效地提升了检测精度,但带来一定计算开销。Zhou 等^[17]结合了 Transformer 模块和 CBAM 模块改进 YOLOv5 算法,虽然提升了检测的精度,但是模型体积增大 35%。赵小虎等^[18]的 TCM-YOLO 通过可变形卷积降低漏检率,但增加了计算的参数量。Wang 等^[19]采用 MobilenetV2 压缩 YOLOv5,降低了模型参数量和计算复杂度,但小缺陷漏检率上升。张周强等^[20]构建 SAC-YOLO 模型,模型参数量减少了 45.8%,mAP@0.5 提升 0.5%,在轻量化同时提高了精度,但对多尺度特征融合能力有限。这些改进往往在提升某一指标时,难以避免地牺牲其他方面,尤其在处理钢材表面常见的小尺寸、多尺度缺陷。

综合上述分析,当前钢材表面缺陷检测面临的核心难题体现在两个层面:1)生成图像的质量和多样性仍存在不足,并且复杂的 GAN 改进方案会增加训练成本;2)未达到模型轻量化与检测精度的平衡。虽然提出了一些轻量化的模型,但在降低模型参数量的同时,检测精度提升小甚至有的会有所下降。基于上述情况,本文提出了一种基于 LS-DCGAN 数据增强与轻量化 SPH-YOLO 的钢材缺陷检测方法:1)通过最小二乘损失改进 DCGAN,在保持生成模型结构简洁的前提下,克服传统 GAN 的模式崩溃问题,稳定生成高质量缺陷样本;2)构建轻量化 SPH-YOLO 模型:利用 C2f_SCSA 模块强化空间-通道特征交互、引入 PSA 注意力机制聚焦微小缺陷、设计 HSFPN 通过跨层级特征重构压缩计算量,从而实现精度与效率的协同优化。

1 基于 LS-DCGAN 的数据增强

2015 年,Radford 等^[21]将 CNN 与 GAN 融合,提出了一种新型生成对抗网络 DCGAN,将 CNN 引入到生成模型当中来做无监督的训练,利用 CNN 强大的特征提取能力来提高生成网络的学习效果,DCGAN 的模型结构如图 1 所示。

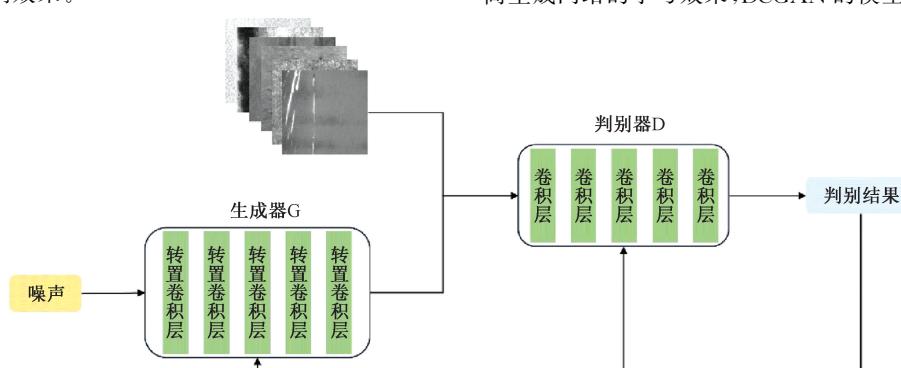


图 1 DCGAN 网络结构

Fig. 1 The model structure of DCGAN

相比于 GAN, DCGAN 进行了多项优化:首先,在生成器中摒弃池化层,转而利用转置卷积操作实现特征图的空间维度扩展,并全连接层替换为卷积层,构建出无全连接约束的端到端卷积网络。其次,针对激活函数,生成器在输出层采用双曲正切(Tanh)函数约束像素值范围,中间层则通过 ReLU 增强非线性表达能力;接着,判别器输出端采用 Sigmoid 函数输出概率置信度,隐藏层使用 Leaky ReLU 缓解梯度稀疏性。最后,网络在生成器与判别器的各卷积层后加入批量归一化(BN),通过规整化特征分布抑制梯度异常波动,显著提升模型收敛效率并降低过拟合风险。

在 DCGAN 框架中,判别器作为二分类器采用交叉熵损失函数,这种设计仅关注分类准确性,在生成对抗训练的后期容易引发梯度衰减问题。当判别器对生成样本的输出值接近 0(假)或 1(真)时,其梯度幅值会随 sigmoid 函数特性呈现指数衰减。尤其对那些判别置信度较高但实际分布仍偏离真实数据的生成样本,生成器难以获得有效的梯度信号进行参数更新,导致模型收敛停滞和生成质量下降。

针对这一关键问题,本研究提出 LS-DCGAN 模型,通过最小二乘损失改进原始框架。判别器采用连续型最小二乘损失,计算其输出与目标分布(真实样本标签为 1,生成样本标签为 0)的平方误差,替代原有的交叉熵损失。当判别器对生成样本的输出偏离目标值时,平方误差损失会施加更强惩罚,迫使生成器持续优化样本分布。最小二乘损失通过平滑的梯度空间缓解模式崩溃,使生成器能稳定学习真实数据分布,尤其在钢材表面缺陷生成任务中,该损失函数对局部纹理梯度变化高度敏感,能够保持缺陷形态多样性与纹理细节真实性。

LS-DCGAN 判别器和生成器的损失函数分别如下:

$$L_D = \frac{1}{2} E_{x \sim p_{data}(x)} [(D(x) - b)^2] + \frac{1}{2} E_{z \sim p_z(z)} [(D(G(z)) - a)^2] \quad (1)$$

$$L_G = \frac{1}{2} E_{z \sim p_z(z)} [(D(G(z)) - c)^2] \quad (2)$$

其中, a 是假数据的标签(通常为 0), b 是真实数据的标签(通常为 1), c 是希望判别器认为生成数据为真实的标签(通常为 1), $P_z(z)$ 代表噪音样本的分布。

2 基于改进 YOLOv8 的钢材缺陷检测

YOLOv8 是由 Ultralytics 团队提出的深度学习网络,其结合了目标检测、实例分割和实时追踪等多项任务。其凭借高效的实时检测能力在工业场景中广泛应用。YOLOv8 的网络结构延续了输入端(Input)、主干网络(Backbone)、颈部网络(Neck)和预测端(Head)的四阶段设计:输入端集成自适应数据增强策略,并引入锚框自优化机制,通过进化算法动态调整预设锚框尺寸;主干网络采用 C2f 模块替代传统 C3 模块,结合深度可分离卷积与跨阶段密集连接,在降低计算复杂度的同时增强多尺度特征

提取能力;颈部网络升级为双向特征金字塔,通过加权双向跨尺度连接实现更高效的特征融合;预测端引入解耦检测头,将分类与回归任务分离以优化梯度传播,并采用 Task-Aligned Assigner 动态标签分配策略,通过概率对齐机制提升正负样本匹配效率。此外,YOLOv8 在损失函数中融合 Distribution Focal Loss 与 CIoU,兼顾分类置信度校准与边界框回归精度,后处理阶段则通过改进的 Cluster-NMS 算法过滤冗余检测框,显著提升复杂场景下的缺陷识别鲁棒性,其结构如图 2 所示。

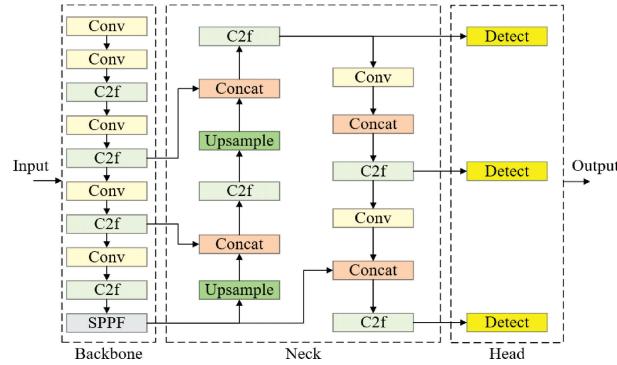


图 2 YOLOv8 网络结构

Fig. 2 YOLOv8 network structure

本文选用 YOLOv8 作为钢材表面缺陷检测的基础模型,但在 NEU-DET 数据集的实际测试中,存在对缺陷区域响应不足的问题,其较高的计算复杂度同时制约了工业场景的实时性需求。因此,本文提出 SPH-YOLO 表面缺陷检测网络模型,创新设计如下:

1) C2f_SCSA 模块:重构多尺度特征交互路径,通过空间-通道双维度信息增强,提升划痕等线性缺陷的跨层级表征能力;

2) PSA 注意力机制:加权融合不同尺度特征图,通过逐位置权重校准聚焦微缺陷区域,增强对微小缺陷的关注能力;

3) Neck 层集成 HSFPN 模块:通过跨层级特征压缩与重参数化设计,优化多尺度信息传递,降低计算和内存消耗。SPH-YOLO 模型如图 3 所示。

2.1 C2f_SCSA

C2f 模块是 YOLOv8 中用于特征提取与特征聚合的重要组成部分,其通过逐层融合不同深度的特征,提升了检测任务的准确性。但 C2f 存在以下局限:空间与通道信息交互不和多语义特征融合欠缺,在多尺度、复杂纹理背景中,特征间的语义差异可能导致关键信息被弱化。本文基于 SCSA 的理论框架^[22],对 C2f 进行改进,提出了 C2f_SCSA 模块,加入的 SCSA 模块,通过整合共享多语义空间注意力(SMSA)和渐进通道自注意力(PCSMA),实现对多语义特征的高效提取和深度融合,能够增强对缺陷特征的捕捉能力。SCSA 由 SMSA 和 PCSA 通过串联连接,其模块结构如图 4 所示。

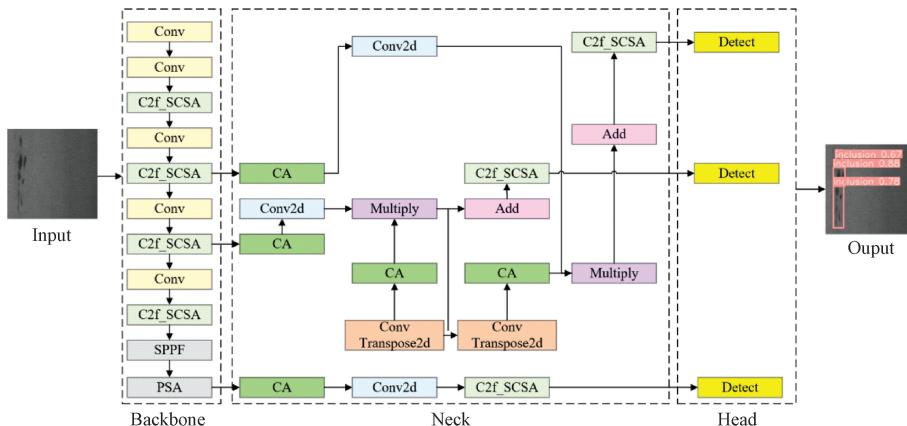


图 3 SPH-YOLO 网络结构
Fig. 3 SPH-YOLO network structure

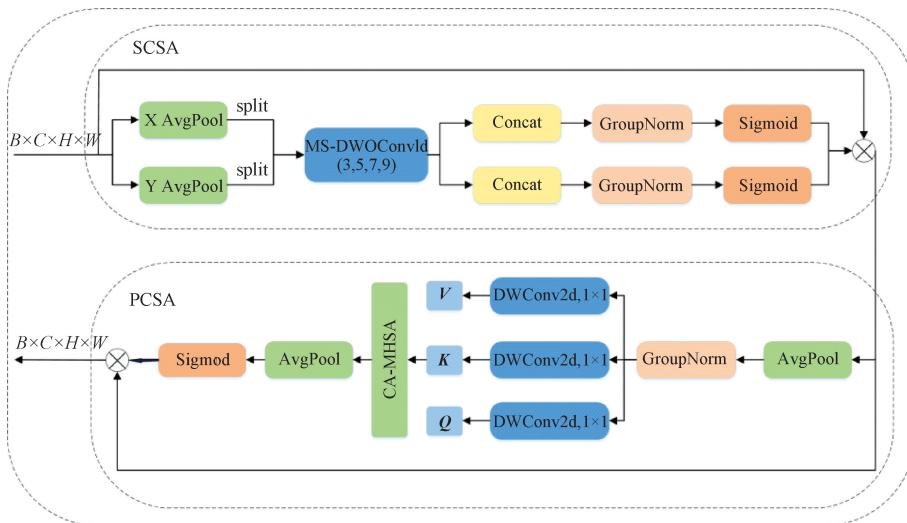


图 4 SCSA 网络结构
Fig. 4 SCSA network structure

SMSA 首先通过双向特征解耦策略, 将输入特征沿高度与宽度维度分别进行全局平均池化, 生成两个独立的一维序列特征。每个序列特征进一步划分为 4 组语义子特征, 分别采用 $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9$ 的多尺度一维深度卷积提取局部-全局空间特征, 并通过共享卷积核实现跨维特征对齐。经过组归一化消除子特征间语义干扰后, 采用 Sigmoid 函数融合多尺度空间先验, 构建具有空间判别力的注意力权重。

PCSA 模块基于渐进式压缩策略优化通道交互。首先对 SMSA 输出的空间增强特征进行动态池化降维, 采用 3 组深度可分离卷积并行生成查询、键、值向量。接着, 通过单头自注意力机制计算通道间相似性矩阵, 结合空间先验引导的特征重校准, 有效缓解多尺度卷积引发的语义差异。最终经层级归一化与非线性激活, 实现通道特征的融合。

$$\text{PCSA}(X_s) = \text{Softmax}\left(\frac{QK^T}{\sqrt{C}}\right)V \quad (3)$$

式中: X_s 为 SMSA 的输出特征, Q, K, V 为通过线性变换从 X_s 提取的查询、键和值矩阵。

SCSA 通过结合 SMSA 和 PCSA 两个模块, 使得通道能够更好地关注重要的空间区域。在 SMSA 中, 多语义空间信息的集成和渐进压缩策略有效地为通道注意力提供了空间先验, 而 PCSA 则利用这些空间信息, 通过自注意力机制进一步优化通道特征, 缓解了不同语义层次的差异。设计的 C2f_SCSA 模块结构如图 5 所示, 将 YOLOv8n 的 C2f 替换成能够有效增强对关键特征提取能力的 C2f_SCSA, 有效地结合了通道和空间注意力的优势, 提高了缺陷检测的准确率。

2.2 PSA 注意力机制

钢材表面缺陷多呈现为多尺度分布特性, 其中划痕呈线状拓扑结构, 裂纹具有分形扩展特征, 这些特征在复杂背景下容易被掩盖, 从而导致漏检或误检的发生。为了应对多样的缺陷形态以及不同尺度的特征, 本文在主干网络

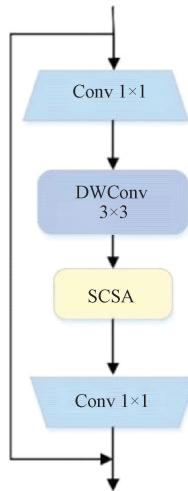


图 5 C2f_SCSA 模块结构

Fig. 5 C2f_SCSA module structure

加入了 PSA 注意力机制, 该机制通过并行处理空间维度上的特征, 高效地提取全局信息并增强对缺陷区域关注能力。

PSA 的结构如图 6 所示首先, PSA 模块将输入特征图在通道维度进行均匀划分, 对部分子特征执行多分支注意力计算: 1) 通过多头自注意力机制 (MHSA) 建立像素级长程依赖关系, 聚焦局部区域的细微纹理变化; 2) 引入带有门控单元的前馈网络 (FFN) 对注意力特征实施非线性变换, 通过特征解耦增强缺陷区域与背景的区分度。最后采

用跨路径特征融合策略, 将注意力路径输出的精细化局部特征与另一路径保留的全局上下文特征进行通道拼接, 在空间-通道双重维度实现互补性特征增强。

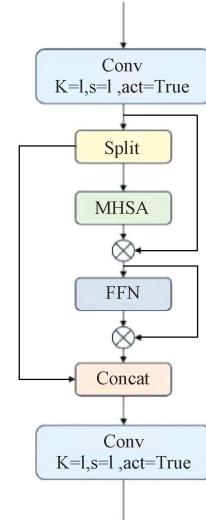


图 6 PSA 模块结构

Fig. 6 PSA module structure

2.3 HSF PN 金字塔结构

HSFPN 多级特征融合金字塔模块旨在通过基于层次尺度的设计来实现多尺度融合, 使得模型能够捕获更全面的目标的特征信息。它主要由特征选择模块和特征融合模块组成, HSF PN 模块的示意图如图 7 所示。

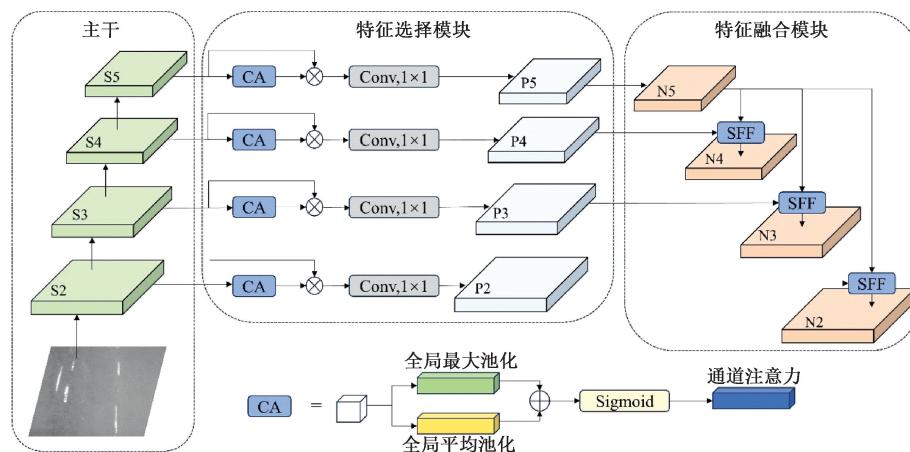


图 7 HSF PN 网络结构

Fig. 7 HSF PN module structure

特征选择模块由 CA 模块和维度匹配模块 DM 共同构建, 他们负责多级特征的提取以及维度匹配工作。在完成骨干网络特征提取后, 注意力增强模块 (CA) 对输入特征映射执行通道校准操作, 该模块采用双池化路径架构: 首先通过全局平均池化与全局最大池化操作并行提取空间上下文信息, 这两种池化策略协同作用以实现特征聚合与维度压缩。随后使用 Sigmoid 激活函数, 生成通道注意力权

重向量用于量化各通道的语义重要性。在特征优化阶段, 维度匹配模块 (DM) 通过 1×1 卷积核将特征映射通道数降至 256 维, 该降维操作确保了后续多层次特征融合过程中不同尺度特征张量的维度一致性, 为构建高效的多层次特征金字塔奠定基础。

SFF 模块的架构设计如图 8 所示, 其核心机制采用双路径特征交互策略: 首先利用深层网络生成的高层语义特

征作为注意力引导,通过动态加权机制对浅层特征中的关键语义信息进行选择性保留;随后将浅层特征与原始高层特征在通道维度进行自适应融合,最终构建出具有多尺度表征能力的特征金字塔。当给定一个输入高级特征 $f_{high} \in R^{C \times H \times W}$ 和一个输入低尺度特征 $f_{low} \in R^{C \times H \times W_1}$ 时,首先通过 3×3 卷积核、步长为 2 的转置卷积层对高层特征进行空间维度扩展,生成与低层特征具有相同空间分辨率的特征大小 $f_{high}^{\wedge} \in R^{C \times 2H \times 2W}$ 。然后,为了统一高级特征和低尺度特征的维度,使用双线性插值来向上或向下采样高级

特征,得到特征 $f_{att} \in R^{C \times H_1 \times W_1}$ 。接着,将经过注意力机制后的低层特征与高级特征在通道维度进行拼接,通过 1×1 卷积实现跨层特征融合,最终输出增强型特征表示,得到 $f_{out} \in R^{C \times H_1 \times W_1}$ 。其中,C 表示通道数,H 表示高级特征图的高度,W 表示高级特征图的宽度, W_1 表示低尺度特征图的宽度, H_1 表示将高级特征进行双线性插值处理后的特征图高度。SFF 选择特征融合过程如式(4)、(5)所示。

$$f_{att} = BL(T - Conv(f_{high})) \quad (4)$$

$$f_{out} = f_{low} \times CA(f_{att}) + f_{att} \quad (5)$$

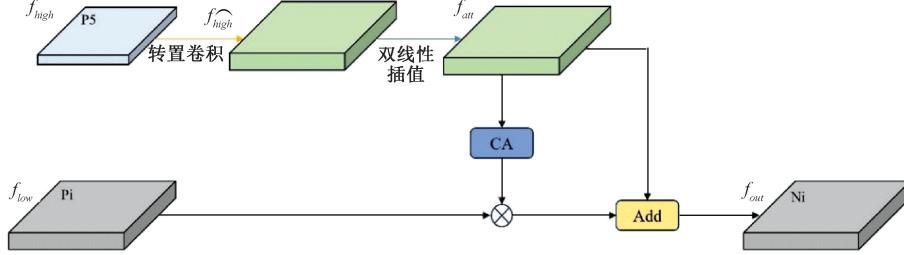


图 8 SFF 结构图

Fig. 8 SFF module structure

3 实验及结果

3.1 NEU-DET 数据集

本实验选用东北大学的热轧带钢缺陷数据集作为缺陷检测数据集,该数据集一共包含 6 类典型工业缺陷类别:裂纹(Cr)、夹杂(In)、斑块(Pa)、麻点(Ps)、铁皮(Rs)以及划痕(Sc)。每类缺陷样本均包含 300 张图像,大小为 200 pixel×200 pixel,均为灰度图像,这 6 类缺陷的部分典型样本图像如图 9 所示。

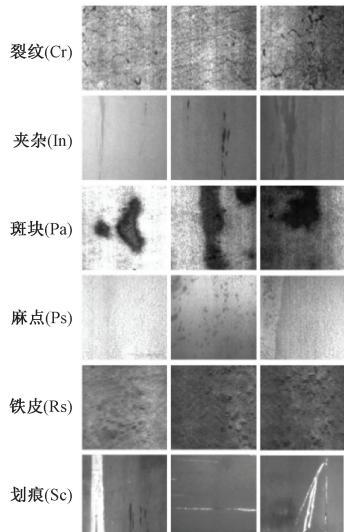


图 9 NEU-DET 缺陷图

Fig. 9 NEU-DET defect images

3.2 LS-DCGAN 数据增强

本实验将 NEU-DET 图像传入 LS-DCGAN 网络中进行训练。实验的硬件环境如表 1 所示。

表 1 实验配置

Table 1 Experimental configuration

| 参数名称 | 实验参数配置 |
|------|--------------------------------------|
| CPU | 12th Gen Inter(R) Core(TM) i5-12400H |
| GPU | NVIDIA GeForce RTX 3060 |
| 内存 | 32 GB |
| 显存 | 12 GB |
| 环境配置 | Python 3.8 CUDA 11.6 Torch 1.12.0 |

在对抗网络的训练中,为了优化目标函数并在接近最优解时实现更好的性能,设置了学习率 lr=0.002。本实验将迭代次数(epoch)设置为 20 000 次,batch_size 设置为 64。实验所采用的梯度优化算法是 Adam 优化算法,其中一阶矩优化指数衰减率为 beta1=0.9,二阶矩优化指数衰减率为 beta2=0.999。

LS-DCGAN 生成的缺陷样本如图 10 所示,在针对钢材表面缺陷生成任务时,能够保持缺陷形态的多样性和纹理真实性。

为了评估生成的图像质量,设计对比试验,评价指标选用弗雷歇初始距离(Fréchet inception distance, FID)。FID 通过比较生成图像与真实图像在特征空间中的分布来评估生成图像的质量,FID 越小,图片的生成质量越好。实验得出,DCGAN 在 NEU-DET 上的 FID 为 139.5,LS-

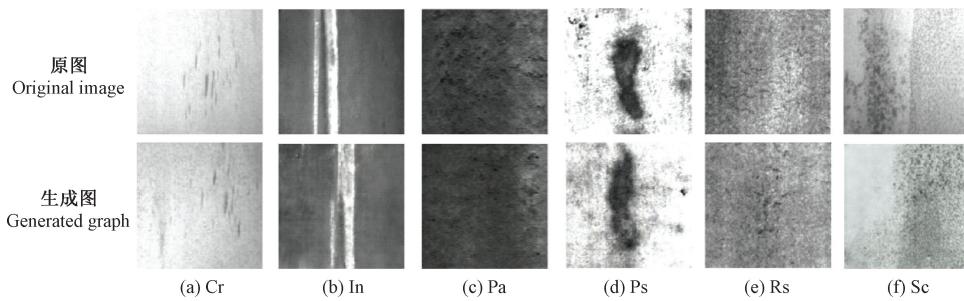


图 10 缺陷样本和生成样本

Fig. 10 Input images and generated images

DCGAN 模型取得了 97.3 的 FID 值。相较于 DCGAN 模型的 139.5, FID 值降低了 30.2%, 这验证了前文所述梯度平滑机制的有效性。

为验证 LS-DCGAN 增强数据的有效性, 基于 YOLOv8 框架设计对比实验; 在 NEU-DET 数据集原始 6 类缺陷(每类增强 200 张)上, 分别测试经典增强(噪声+色彩组合)、DCGAN 生成及 LS-DCGAN 生成 3 种数据方案的性能。如表 2 所示, LS-DCGAN 以 76.3% mAP@50% 领先, 较原始数据提升 1.2%, 较 DCGAN 提升 0.4%。结果表明: 通过最小二乘损失改进的生成模型, 其合成数据可超越传统增强与基础 GAN 方案, 为钢材缺陷检测提供更有效的特征学习样本。

表 2 不同数据增强方法在 YOLOv8 上的性能对比

Table 2 Comparison of detection performance of different data augmentation methods on YOLOv8

| 增强类型 | 方法 | mAP@50/% |
|------|----------|----------|
| 原始数据 | — | 75.1 |
| 经典增强 | 噪声+色彩 | 76.0 |
| | DCGAN | 75.9 |
| 生成式 | LS-DCGAN | 76.3 |

为了保证实验最终的测试集一致性, 本文使用 LS-DCGAN 网络生成的钢材缺陷图像仅添加到训练集。每一类添加 200 张, 扩充后的 NEU-DET 包含数据增强后的 3 000 个图像文件和其对应 YOLO 格式标签文件。本研究将数据集按照 8 : 1 : 1 随机划分成训练集、验证集和测试集进行实验。

3.3 YOLOv8 网络的训练

训练 YOLOv8 网络实验的硬件环境同上表 1 实验配置一致, 将数据集输入网络进行训练, epoch 设置为 300 轮, 设置 batch_size 为 16, 初始学习率为 0.01, 梯度优化算法采用 SGD 优化算法, 未提到的参数均按照 YOLOv8n 官方默认参数设置。

3.4 评价指标

为客观量化模型检测性能, 本实验具体选用以下 3 项作为评估模型性能的核心指标: 1) 平均精度均值 (mean

average precision, mAP), 即基于交并比(IoU)阈值 0.5 的检测框匹配准则计算的类别平均精度均值; 2) 模型参数量 (Params), 反映网络复杂度的可训练参数总量; 3) 浮点运算量 (FLOPs), 表征前向推理过程的理论计算强度。平均精度均值反映模型的检测精度, 参数量和浮点计算量反映模型的大小和计算复杂度。其中平均精度均值和模型的准确率(P)、召回率(R)以及准确率的计算公式为:

$$P = \frac{TP}{TP + FP} \times 100\% \quad (6)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (7)$$

$$AP = \int_0^1 P(R) dR \quad (8)$$

$$mAP = \frac{\sum_{i=1}^n AP(i)}{n} \quad (9)$$

其中, TP 表示模型正确检测出的目标数、FP 表示模型错误检测出的目标数、FN 表示模型未能正确检测出的目标数。AP(i) 表示第 i 类目标的 P-R 曲线面积; n 表示检测缺陷的类别数。

3.5 实验结果对比分析

为了选择更有效地添加 SCSA 模块的方式, 本实验对比了替换不同类别和位置的 SCSA 模块: 组别 1(SCSA1 替换全部 C2f)、组别 2(SCSA2 替换全部 C2f)、组别 3(SCSA1 替换 HEAD 部分的 C2f)、组别 4(SCSA2 替换 HEAD 部分的 C2f)。结果如表 3 所示, 可以看出, 在计算量和参数量基本相同的情况下, 组 1 和组 2 相比原始 C2f 在检测精度上有显著提升, 分别提高了 2.2% 和 1.4%, 组 1 提升最多, 表明在钢材表面缺陷检测中, SCSA1 替换全部 C2f 的方式增强了多尺度下特征融合的效果, 更有利于捕捉特征信息较少的目标, 因此选择这种方式改进 C2f。

为了更加直观的体现本文提出的模型各改进部分对模型检测精度的提升效果, 进行了消融实验, 每次仅改变一个模块, 在保持环境不变的条件下进行实验, 实验结果如表 4 所示, “√”表示在该实验中使用了该模块, “×”表示在该实验中未使用该模块。从表中可以看出, 对比第 1 组和第 2 组实验, 数据增强后检测的 mAP@50% 提升了

1.2%，第3组实验中，SCSA的加入使模型的平均精度均值提升了2%，对参数量和浮点计算量没有太大影响。在第4组实验中，引入的PSA使mAP@50%提高了1.7%，但同时增加了模型的参数量和计算量。在第5组实验中，HSFPN的引入大幅降低了浮点计算量和参数量，但是对mAP@50%的提升有限，提高了0.8%。从第6组实验中可以看出最终改进后的YOLOv8模型在提升了3%平精度均值的同时，使浮点计算量降低了12.3%，参数量降低了26.7%。

表3 不同SCSA配置的检测结果

Table 3 Detection results of different SCSA configurations

| 组别 | mAP@50/% | Parameters/M | GFLOPS/G |
|----|----------|--------------|----------|
| 1 | 78.3 | 3 | 8.1 |
| 2 | 77.6 | 3 | 8.1 |
| 3 | 76.2 | 3 | 8.1 |
| 4 | 76.0 | 3 | 8.1 |

表4 改进模型在数据集上消融实验

Table 4 Ablation experiments of the improved model on the dataset

| 组别 | 是否数据增强 | C2f_SCSA | PSA | HSFPN | mAP@50/% | Parameters/M | GFLOPS/G |
|----|--------|----------|-----|-------|----------|--------------|----------|
| 1 | × | × | × | × | 75.1 | 3.0 | 8.1 |
| 2 | √ | × | × | × | 76.3 | 3.0 | 8.1 |
| 3 | √ | √ | × | × | 78.3 | 3.0 | 8.1 |
| 4 | √ | × | √ | × | 78.0 | 3.2 | 8.4 |
| 5 | √ | × | × | √ | 77.1 | 1.9 | 7.0 |
| 6 | √ | √ | √ | √ | 78.1 | 2.2 | 7.1 |

图11给出了训练后本文提出的轻量化模型和基础模型对数据集进行瑕疵检测的结果。其中第1列是检测的

原图，第2列是基础模型，第3列是本文提出的改进模型。在图11第1、2、3和5行中，基础模型均出现了漏检的情况。其中第1、5行是对铁皮和麻点这种容易混淆目标的漏检，第2、3行是对划痕和夹杂这种稍大目标的漏检。从第4行可看出，相比于基础模型，改进后模型对麻点的检测准确率更高，并且没有出现框的混合情况。

为了验证本研究模型的性能，在相同的实验条件下，将改进后的模型于其他模型进行对比，包括SSD、Faster R-CNN、YOLOv5n、YOLOv6n、YOLOv8n、YOLOv9t、YOLOv10n、YOLO11；此外，在基础模型上复现近几年文献[23]、文献[24]提出的基于YOLOv8改进的方法。详细结果展示在表5中。

表5 不同模型的对比实验

Table 5 Comparison experiments of different models

| 组别 | 模型 | mAP@50 /% | Parameters /M | GFLOPS /G |
|----|-------------|--------------|------------------|--------------|
| 1 | SSD | 69.2 | 24.4 | 30.68 |
| 2 | Faster-RCNN | 75.7 | 28.2 | 37.55 |
| 3 | YOLOv5n | 75.9 | 2.5 | 7.20 |
| 4 | YOLOv6n | 73.4 | 4.2 | 11.90 |
| 5 | YOLOv8n | 76.3 | 3.0 | 8.10 |
| 6 | YOLOv9t | 74.8 | 2.0 | 7.90 |
| 7 | 文献[23] | 76.9 | 2.5 | 6.90 |
| 8 | 文献[24] | 77.8 | 2.8 | 7.70 |
| 9 | YOLOv10n | 73.1 | 2.7 | 8.40 |
| 10 | YOLO11 | 76.0 | 2.5 | 6.40 |
| 11 | Ours | 78.1 | 2.2 | 7.10 |

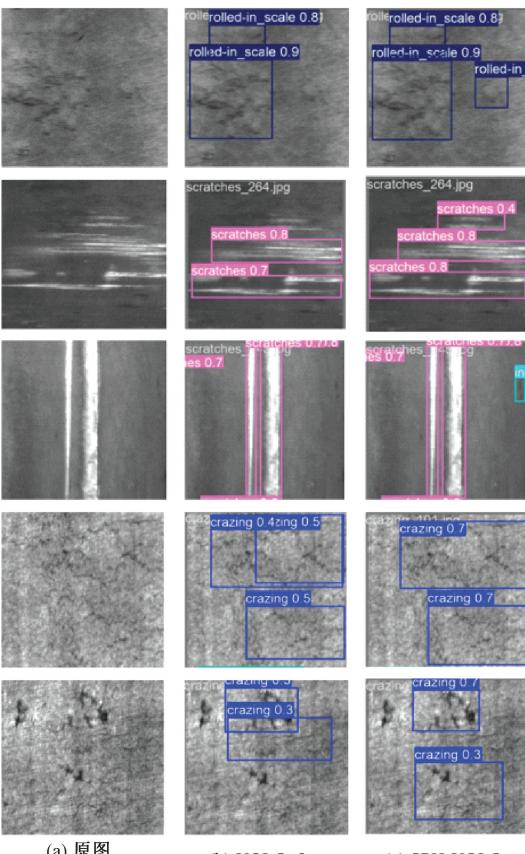


图11 检测效果对比

Fig. 11 Comparison of detection results

可以看出,相比于 YOLOv8n 基础模型,YOLOv5n、YOLOv9t、YOLOv10 n 和 YOLO11 的模型具有更低的计算量或参数量,但是改进后的模型在计算量和参数量降低的情况下,精度提升更大。虽然文献[23]和文献[24]提出的基于 YOLOv8 改进的方法表现出了更低的计算复杂度,但在检测精度上 SPH-YOLO 效果更优。剩下的模型在精度、计算量和参数量方面都不及改进后的模型,其中 SSD 和 Faster-RCNN 的计算量和参数量甚至是其他模型的 3 倍以上。结果表明,设计的 C2f_SCSA、PSA 和 HS-FPN 模块提升了模型在钢材表面缺陷检测的精度,使模型能更好地平衡性能和效率。

为了验证本文提出的 SPH-YOLO 算法的泛化能力,使用 GC10-DET 目标缺陷数据集进行实验,GC10-DET 包含了冲孔(Pu)、焊缝(WI)、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 种缺陷,包含 2 294 张图像。实验将数据集划分为训练集 1 833 张、验证集 229 和测试集 230 张。结果如表 6 和图 12 所示。实验结果表明,改进模型的检测准确率提高了 1.6%,参数量降低了 26.6%,计算量降低了 12.3%,证明了本文改进算法对于目标检测的提升效果良好,具有一定的泛化能力。

表 6 改进模型在 GC10-DET 上的实验

Table 6 Experiments of the improved model on GC10-DET

| 组别 | 模型 | mAP@50/% | Parameters/M | GFLOPS/G |
|----|---------|----------|--------------|----------|
| 1 | YOLOv8n | 63.6 | 3.0 | 8.1 |
| 2 | Ours | 65.2 | 2.2 | 7.1 |

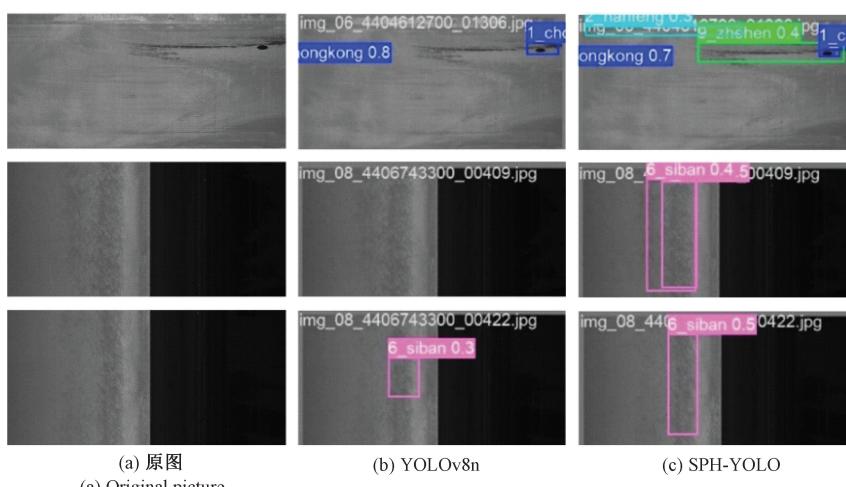


图 12 检测效果对比

Fig. 12 Comparison of detection results

4 结 论

本文提出了一种基于 LS-DCGAN 数据增强与轻量化 YOLOv8 的钢材缺陷检测方法,旨在解决工业场景中钢材表面缺陷样本多样性不足与检测模型部署效率的平衡问题。LS-DCGAN 通过最小二乘损失重构生成过程,FID 值较 DCGAN 降低 30.2%,为检测模型提供更多样的训练数据。在模型改进方面,SPH-YOLO 首先通过 C2f_SCSA 模块强化多尺度特征交互,其次加入的 PSA 注意力机制提升微小缺陷的关注能力,最后使用 HSFPN 轻量颈网降低计算开销。实验结果表明,改进后的方法检测性能更好且不易漏检,实现了检测精度与计算效率的协同优化。未来的研究中考虑把模型进行实际部署,在实际检测系统中验证工程的实用性。

参考文献

[1] 熊鹰.带钢表面缺陷检测及识别关键技术研究[D].重庆:重庆大学,2016.

XIONG Y. Technology research on surface defects detection and recognition of strip [D]. Chongqing: Chongqing University, 2016.

[2] 游青华.基于深度学习的钢材表面缺陷检测方法研究[D].武汉:武汉纺织大学,2021.

YOU Q H. Research on defect detection of steel surface methods based on deep learning[D]. Wuhan: Wuhan Textile University, 2021.

[3] 张宏飞,冯永利,黄金凤.改进 YOLOv5 的输送带缺陷检测[J].电子测量技术,2024,47(22):161-168.

ZHANG H F, FENG Y L, HUANG J F. Improving YOLOv5 conveyor belt defect detection[J]. Electronic Measurement Technology, 2024, 47(22):161-168.

[4] 岳剑峰,李伟明,宁黎华,等.基于 YOLO-DEFW 的焊缝缺陷实时检测算法研究[J].中国激光,2025,52(8):64-76.

YUE J F, LI W M, NING L H, et al. Real-time weld defect detection algorithm based on YOLO-DEFW[J]. Chinese Journal of Lasers, 2025,52(8):64-76.

[5] 周军超,陈鑫,高建杰,等.基于改进 YOLOv8n 算法的城市空间混行交通参与者检测模型[J].中国安全科学学报,2024,34(12):178-186.

- ZHOU J CH, CHEN X, GAO J J, et al. Urban spatially mixed traffic participants detection model based on improved YOLOv8n[J]. China Safety Science Journal, 2024, 34(12): 178-186.
- [6] 胡依伦, 杨俊, 许聪源, 等. PIC2f-YOLO: 金属表面缺陷检测轻量化方法[J]. 光电工程, 2025, 52(1): 89-103.
- HU Y L, YANG J, XU C Y, et al. PIC2f-YOLO: A lightweight method for the detection of metal surface defects[J]. Opto-Electronic Engineering, 2025, 52(1): 89-103.
- [7] 陈思, 李俊萩, 孔德肖, 等. 基于 YOLOv8n 绿橙检测算法研究[J]. 中国农机化学报, 2025, 46(7): 145-152.
- CHEN S, LI J Q, KONG D X, et al. Research on green orange detection algorithm based on YOLOv8n [J]. Journal of Chinese Agricultural Mechanization, 2025, 46 (7): 145-152.
- [8] WEN L, WANG Y, LI X. A new cycle-consistent adversarial networks with attention mechanism for surface defect classification with small samples[J]. IEEE Transactions on Industrial Informatics, 2022, 18(12): 8988.
- [9] 李春华, 付睿智, 刘玉坤, 等. 基于改进 DCGAN 轮胎缺陷图像生成方法[J]. 河北科技大学学报, 2023, 44 (4): 346-355.
- LI CH H, FU R ZH, LIU Y K, et al. A method for generating tire defect images based on improved DCGAN[J]. Journal of Hebei University of Science and Technology, 2023, 44(4): 346-355.
- [10] 黄鹏, 蔡露, 陈彬, 等. 基于 DCGAN 和改进 YOLOv5s 的钢丝帘布缺陷检测方法[J]. 电子测量技术, 2024, 47 (3): 144-155.
- HUANG P, CAI L, CHEN B, et al. Defect detection method of steel cord based on DCGAN and improved YOLOv5s[J]. Electronic Measurement Technology, 2024, 47(3): 144-155.
- [11] 沈明辉, 刘宇杰, 陈婧, 等. 基于改进 YOLOv8s 轻量化网络的组装电脑主板缺陷检测算法[J/OL]. 计算机工程, 1-14 [2025-06-28]. <https://doi.org/10.19678/j.issn.1000-3428.0070196>.
- SHEN M H, LIU Y J, CHEN J, et al. Defect detection of printed circuit board assembly based on lightweight YOLOv8[J/OL]. Computer Engineering, 1-14. [2025-06-28]. <https://doi.org/10.19678/j.issn.1000-3428.0070196>.
- [12] 梁喜凤, 魏志卫. 基于改进 CycleGAN 与 YOLOv8 的夜间番茄茎、枝分割方法[J]. 农业工程学报, 2025, 41 (8): 147-155.
- LIANG X F, WEI ZH W. Segmenting tomato stems and branches at night time using improved CycleGAN and YOLOv8[J]. Transactions of the Chinese Society of Agricultural Engineering, 2025, 41(8): 147-155.
- [13] 易磊, 黄哲玮, 易雅雯. 改进 YOLOv8 的输电线路异物检测方法[J]. 电子测量技术, 2024, 47(15): 125-134.
- YI L, HUANG ZH W, YI Y W. Improved YOLOv8 foreign object detection method for transmission lines [J]. Electronic Measurement Technology, 2024, 47 (15): 125-134.
- [14] SHEN M, LIU Y, CHEN J, et al. Defect detection of printed circuit board assembly based on YOLOv5[J]. Scientific Reports, 2024, 14(1): 19287.
- [15] LIAN J, HE J, NIU Y, et al. Fast and accurate detection of surface defect based on improved YOLOv4 [J]. Assembly Automation, 2022, 42(1): 134-146.
- [16] 杨森泉, 丁凡, 文昊翔, 等. 基于 CA-YOLOv5 的热轧带钢表面缺陷检测方法[J]. 光电子·激光, 2024, 35 (1): 21-28.
- YANG S Q, DING F, WEN H X, et al. Hot-rolled steel strip surface defects detection based on CA-YOLOv5 [J]. Journal of Optoelectronics · Laser, 2024, 35(1): 21-28.
- [17] ZHOU F, DENG H, XU Q, et al. CNTR-YOLO: Improved YOLOv5 based on convnext and transformer for aircraft detection in remote sensing images [J]. Electronics, 2023, 12(12): 2671.
- [18] 赵小虎, 谢礼逊, 慕灯聪, 等. 基于 TCM-YOLO 网络的金属表面缺陷检测方法[J]. 计算机工程, 2025, 51(6): 338-348.
- ZHAO X H, XIE L X, MU D C, et al. Metal surface defect detection based on TCM-YOLO network methods[J]. Computer Engineering, 2025, 51 (6): 338-348.
- [19] WANG J, SU Y, YAO J, et al. Apple rapid recognition and processing method based on an improved version of YOLOv5 [J]. Ecological Informatics, 2023, 77: 102196.
- [20] 张周强, 李成, 王康旭, 等. 基于 SAC-YOLO 的轻量化织物疵点分割算法[J]. 西安工程大学学报, 2025, 39 (3): 59-69.
- ZHANG ZH Q, LI CH, WANG K X, et al. Lightweight fabric defect segmentation algorithm based on SAC-YOLO[J]. Journal of Xi'an Polytechnic University, 2025, 39(3): 59-69.
- [21] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. ArXiv preprint arXiv:1511.06434, 2015.
- [22] SI Y, XU H, ZHU X, et al. SCSA: Exploring the synergistic effects between spatial and channel attention[J]. Neurocomputing, 2025, 634: 129866.
- [23] LIU L J, ZHANG Y, KARIMI H R. Resilient machine learning for steel surface defect detection based on lightweight convolution [J]. The International Journal of Advanced Manufacturing Technology, 2024, 134(9): 4639-4650.
- [24] KONG H ZH, YOU H ZH. Improved steel surface defect detection algorithm based on YOLOv8 [J]. IEEE Access, 2024, 12: 99570-99577.

作者简介

胥姜苗, 硕士研究生, 主要研究方向为工业摄影测量、深度学习、目标检测。

E-mail: E-mail: 1813510516@qq.com

曹爽(通信作者), 博士, 副教授, 主要研究方向为精密工程与工业测量、摄影测量数据处理。

E-mail: caoshuang@nuist.edu.cn