

【工程与技术】

基于改进 YOLOv8 的盘状齿轮表面缺陷 视觉检测方法

李承璋¹, 张鹏魁², 陈君宝¹

(1. 湖北汽车工业学院 汽车智能制造学院; 2. 东风设备制造有限公司, 湖北 十堰 442000)

摘要: 齿轮是机械系统中的核心传动部件, 其表面质量直接影响系统的稳定性和使用寿命。针对传统的人工目测检测方法效率和准确率较低等问题, 提出一种基于 YOLOv8 的自动化齿轮表面缺陷检测算法——YOLOv8-ASR。通过引入 Swin Transformer、AKConv 和 RepViTBlock 等模块提高 YOLOv8-ASR 的性能。实验结果表明, 相较于 YOLOv8, YOLOv8-ASR 在公共数据集上的 *mAP* 提高了 1.9 个百分点, 在自制数据集上的“heipi”缺陷检测任务中表现优异。

关键词: YOLOv8; 齿轮缺陷检测; 机器视觉; 深度学习; Swin Transformer; AKConv; RepViTBlock

中图分类号: TH 132; TP 391 **文献标识码:** A DOI:10.13486/j.issn.2097-4973.2025.04.009

0 引言

齿轮作为关键传动部件, 齿轮表面质量是影响其服役性能和可靠性的关键因素。现阶段齿轮缺陷检测主要依赖传统的人工目测, 该方法效率低下且准确率较低, 难以满足现代制造业对高效和准确检测的需求^[1]。因此, 在复杂多变的环境中快速、准确地检测多种齿轮缺陷, 对于齿轮零部件制造来说尤为重要。

随着深度学习模型的迅速发展, 其逐渐被应用于缺陷检测任务。与基于图像处理和机器学习的方法不同, 深度学习模型能够自动提取特征, 通过逐层变换将原始图像映射到新的特征空间, 简化缺陷检测流程。目前, 已有许多学者将深度学习模型应用于缺陷检测。Huang 等基于 YOLOv4 算法优化了锚框, 从而提高芯片缺陷检测效率^[2]。Chen 等针对紧固件缺陷, 使用三层深度卷积神经网络进行位置识别和分类, 验证了该方法的适应性和鲁棒性^[3]。Ramalingam 等改进 SSD MobileNet 框架, 将飞机表面缺陷检测的准确率提高至 96.2%^[4]。Cha 等利用快速区域卷积神经网络对建筑材料表面缺陷进行检测, 平均检测精度超过 82%^[5]。Hsieh 等使用 YOLOv3 进行铁路轨道扣件缺陷检测, 平均精度为 89%^[6]。吕弢等利用 YOLOv3 解决了传统 AOI 的检测效率问题, 实现了航天系统电路板的高精度缺陷检测^[7]。周曼等通过优化 YOLOv5 成功识别陶瓷表面缺陷^[8]。刘玉龙等使用 Mask R-CNN 进行焊点缺陷检测, 实现了缺陷的定位、分类和分割^[9]。贾东鑫等在 Mask R-CNN 基础上进行数据增强及微调, 实现了对热轧带钢表面缺

收稿日期: 2024-11-20

基金项目: 湖北省科技厅重大专项 (2021AAA007)

第一作者简介: 李承璋 (1998—), 男, 吉林通化人, 硕士研究生, 主要从事视觉缺陷检测研究。

E-mail: 1137304578@qq.com

通信作者简介: 陈君宝 (1975—), 男, 黑龙江哈尔滨人, 教授, 主要从事智能制造、MES 系统研究。

E-mail: 13872821175@139.com

陷的准确判断^[10]。

虽然机器视觉技术和深度学习方法已经在工业检测领域得到了广泛应用,但在应对复杂背景、多尺度目标和光照变化等问题时,处理小目标时容易出现漏检和误检现象,检测精度不足。基于 YOLOv8 模型,结合 Swin Transformer 模块提升特征提取能力,通过 AKConv 和 RepViTBlock 优化检测结构,构建了 YOLOv8-ASR 齿轮表面缺陷检测算法,并引入对比度增强与超分辨率技术,显著改善模型的检测精度和鲁棒性,旨在为齿轮缺陷检测提供高效、精准的技术手段,从而提升机械制造业智能化水平。

1 实验方法

1.1 齿轮缺陷检测设备设计

为了高效和精确地检测齿轮表面缺陷,设计了一套基于机器视觉的自动化检测设备。设备设计目标是确保在复杂工业环境中能够可靠地获取高质量的图像数据,以满足深度学习模型的训练和测试需求^[11]。设备的主要组成部分包括高分辨率工业相机、可调光源、旋转工装台及图像采集与处理系统。

工业相机的选择与配置。选择分辨率为 5 000 万像素的 CMOS 工业相机,其高动态范围(High Dynamic Range Imaging, HDR)特性使其在处理强光和暗光交替出现的场景时,能够捕捉到更多的细节。相机的曝光时间、光圈大小以及帧率均可以根据实际的工业应用场景进行优化配置。

可调光源设计。光源系统由环形光源和可调光强的平行光源构成,以实现均匀的光照覆盖。环形光源用于消除齿轮表面反射造成的局部阴影,而平行光源可以调节光强和角度,适应齿轮表面不同材质的反射特性,保证采集图像的均匀性和清晰度。

旋转工装台设计。齿轮放置在旋转工装台上,通过电机驱动工装台的旋转,实现齿轮表面各个角度的全覆盖拍摄。

图像处理系统。图像处理系统负责对相机采集的原始图像进行预处理,包括噪声滤波、对比度增强和特征标注。图像预处理的目标是最大化图像质量,为后续的深度学习模型提供高质量的输入数据。采用以下图像处理技术。

一是利用高斯滤波,通过卷积操作

$$G(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) * I(x, y)$$

平滑噪声。式中: $I(x, y)$ 为原始图像的像素值, $G(x, y)$ 为滤波后的图像像素值, σ 为高斯核的标准差。

二是对比度受限自适应直方图均衡化(Contrast Limited Adaptive Histogram Equalization, CLAHE)用于提升低对比度图像局部细节,限制直方图均衡化的对比度增强效果,避免过度增强。CLAHE 公式为

$$I' = I \cdot \frac{L_{\max}}{L}$$

式中: L 为原始图像的灰度级数, L_{\max} 为 CLAHE 算法设定的最大灰度级数。

1.2 YOLOv8 模型的改进

YOLOv8 模型在目标检测领域具有实时性和高效性的优势,但在处理复杂工业缺陷检测任务时,对小目标检测精度不够,会出现误检或漏检;在进行多类别检测时,其会混淆不同类别缺陷;该模型处理速度无法满足实时检测需求等,仍存在一定的改进空间。为此,本研究对 YOLOv8 模型进行了三方面的改进:特征提取模块优化、检测头结构调整和数据增强策略优化^[12]。

1.2.1 特征提取模块优化

因盘状齿轮的纹理可能与背景有一定的相似性,导致 YOLOv8 模型卷积操作在提取多尺度特征和复杂纹理信息时能力不足。为此,本文引入 Swin Transformer 模块,通过多头自注意力机制来增强特征提取能力。Swin Transformer 模块的工作流程如图 1 所示。该模块首先将输入图像划分为多个固定大小的

窗口, 然后在每个窗口内应用多头自注意力机制, 以增强局部特征的提取。通过滑动窗口操作, 各窗口之间的特征信息得以融合, 从而逐步扩展至全局, 最终输出每个窗口的特征。




图 1 Swin Transformer 模块结构图

多头自注意力机制定义。设输入特征为 $X \in \mathbf{R}^{N \times d}$, 其中, N 为特征的数量, d 为每个特征的维度, 多头自注意力机制计算公式:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V。$$

式中: $Q = XW^Q$, $K = XW^K$, $V = XW^V$ 分别为查询、键和值; $W^Q, W^K, W^V \in \mathbf{R}^{(d \times d_k)}$ 为可学习的权重矩阵; d_k 为注意力头的维度。

Swin Transformer 的窗口操作。Swin Transformer 使用固定大小的窗口 (如 $M \times M$) 对输入图像进行分块, 每个窗口内独立计算自注意力。这种方式能够保留局部信息, 并通过逐层堆叠逐步扩展到全局。窗口内自注意力的计算复杂度为 $O(M^{2d})$, 相比全局自注意力的 $O(N^{2d})$ 显著降低。通过引入 Swin Transformer 模块, YOLOv8 模型在处理多尺度目标和复杂纹理特征时表现出更强的特征提取能力, 特别是在高精度要求的工业缺陷检测任务中展现出了显著的性能提升。

1.2.2 检测头结构调整

不同盘状齿轮在形状、大小、颜色和材质上可能存在显著差异, 为了提高 YOLOv8 模型在多尺度目标检测中的适应能力^[11], 引入 AKConv 模块和 RepViTBlock 模块。AKConv 模块的工作流程如图 2 所示。




图 2 AKConv 模块自适应卷积结构图

AKConv 模块采用自适应卷积策略, 通过调整卷积核大小和形状, 以动态适应不同尺度的输入特征。该过程首先接收输入特征, 基于初始卷积核 K_0 和可学习的尺度参数 α 计算调整后的卷积核 $K_a = K_0 + \Delta K$ 。在调整完成后进行卷积运算, 最终输出处理后的特征, 以供后续的检测任务使用^[13]。通过学习卷积核的大小和形状, 实现对多尺度目标的高效检测。公式为 $K_a = K_0 + \alpha \cdot \Delta K$, 式中: ΔK 为卷积核的增量, 通过训练过程不断优化。

RepViTBlock 模块的核心结构如图 3 所示。




图 3 RepViTBlock 模块特征融合结构图

RepViTBlock 模块借鉴 Vision Transformer 的结构, 通过残差连接和多头自注意力机制优化特征融合。它利用多头自注意力有效处理复杂背景, 精确提取深层次特征, 捕捉更多上下文信息。同时, 残差连接保留原始输入特征并改善信息流动, 降低梯度消失的风险。这两种机制显著提升了特征融合的完整性和准确性, 增强了模型在复杂背景下的特征提取能力。公式为

$$H = \text{MLP}(\text{LayerNorm}(H + \text{MSA}(H)))。$$

式中: H 为输入特征, MSA 为多头自注意力模块, MLP 为多层感知器。

AKConv 和 RepViTBlock 的引入使模型能够更好地处理不同尺度的目标检测任务,尤其是在复杂背景和尺寸目标下,检测精度得到了显著提升^[12]。

1.2.3 数据增强策略优化

为提高模型的鲁棒性和泛化能力,本文采用了 CLAHE 和纯合成数据训练真实世界的盲超分辨率 (Training Real-World Blind Super-Resolution with Pure Synthetic Data, Real-ESRGAN) 技术对图像数据进行增强处理。CLAHE 用于提升低对比度图像的局部细节,通过限制直方图均衡化的对比度增强效果,避免传统直方图均衡化可能导致的过度增强问题。Real-ESRGAN 是基于生成对抗网络的超分辨率重建算法,通过对低分辨率图像进行超分辨率增强,生成更清晰的训练样本,提升模型对微小缺陷识别能力。

2 实验结果与分析

本部分采用多种研究方法,对 YOLOv8-ASR 模型在自制数据集和公共数据集上的表现进行了深入分析和讨论。综合使用对比分析、消融实验、错误样本分析、时间复杂度分析以及实验结果数据对比,全面评估模型在工业缺陷检测任务中的适用性和有效性^[14]。

2.1 混淆矩阵对比分析

图 4 展示了改进模型 YOLOv8-ASR 在自制数据集和公共数据集上的混淆矩阵。混淆矩阵提供了模型在每个类别上的分类准确率和误差分布情况,是分析模型分类性能的重要工具。

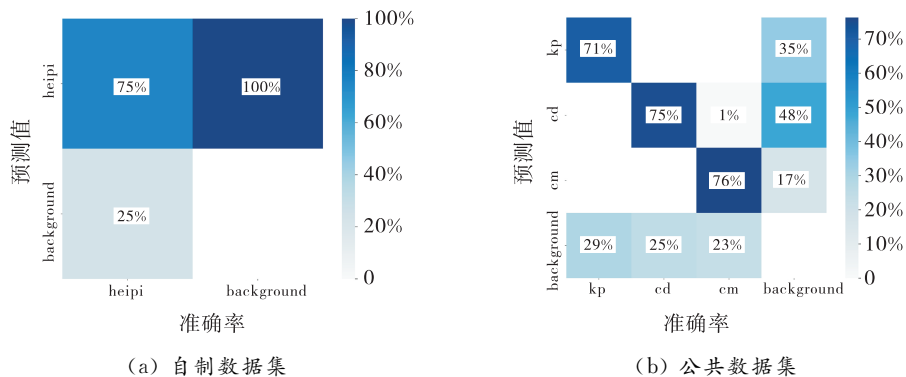


图 4 自制数据集和公共数据集的混淆矩阵

特定缺陷类型的高检测率与偏向性。从图 4(a)可以看出,模型在自制数据集上对“heipi”(“黑皮”缺陷标注为“heipi”)缺陷的检测准确率达到了 75%。这一结果表明,模型能够有效识别数据集中最常见的缺陷类型,并对其特征表现出较强的敏感性^[15]。然而,模型在背景的检测表现上相对较差,准确率仅为 25%。这种差异可能源于训练数据集的偏差,即“heipi”缺陷样本占比过高,导致模型在训练时对该类别特征进行了过度拟合,同时忽视了背景特征的多样性。

多类别检测的平衡性与挑战。在公共数据集中,模型需要同时检测多种类型的缺陷(“齿底黑皮”标注为“cd”、“齿面黑皮”标注为“cm”、“磕碰”标注为“kp”等)[图 4(b)]。混淆矩阵显示,模型在“cm”类别上的检测准确率最高(76%),而在“cd”和“kp”类别上的准确率相对较低。这表明,模型在应对多类别检测任务时存在挑战,尤其是在类别特征相似且样本不平衡的情况下。模型的误检率主要集中在“cd”和“kp”类别上,表明其在识别这两类缺陷时存在混淆问题。

改进建议。增强多样性样本训练与特征差异化处理,在训练过程中引入更均衡的数据集,特别是增加其他类别缺陷的样本数量和多样性。此外,采用特征增强技术,如数据增广和类别自适应权重调整,使模型在学习过程中更关注复杂背景下的微弱特征。

2.2 消融实验分析

为了评估 YOLOv8-ASR 中各种改进在对齿轮缺陷检测的提升效果,进行了消融实验,并计算每种模

型的平均精度均值(mAP)结果如表 1 所示,通过逐步移除或替换特定模块来观察模型性能的变化,分析每个模块的相对重要性。

表 1 不同模块配置下的模型性能对比

项目	YOLOv8-ASR	YOLOv8	YOLOv8-AR	YOLOv8-SR	YOLOv8-AS
$mAP/\%$	73.2	71.3	71.6	72.4	72.9

Swin Transformer 的贡献。消融实验结果显示,YOLOv8-AR 模型 mAP 比 YOLOv8-ASR 模型的 mAP 降低了 1.6 个百分点(表 1)。这表明 Swin Transformer 模块提升了模型的特征提取能力,尤其是在复杂纹理和细节信息的识别方面。通过局部窗口的自注意力机制,Swin Transformer 能够更有效地捕捉全局和局部特征,从而提高模型的检测精度。

AKConv 模块的作用。与 YOLOv8-ASR 模型相对比,移除 AKConv 模块后的 YOLOv8-SR 模型 mAP 降低了 0.8 个百分点,表明 AKConv 模块在多尺度目标检测中有重要作用(表 1)。AKConv 模块通过自适应卷积策略,动态调整卷积核的大小和形状,使得模型能够更好地应对不同尺度的目标检测任务。特别是在大尺寸和不规则形状的缺陷检测中,AKConv 显示出较强的优势。

RepViTBlock 模块的影响。与 YOLOv8-ASR 模型相对比,移除 RepViTBlock 模块后,YOLOv8-AS 模型性能略微下降,说明该模块在特征融合和复杂背景下的目标检测任务中发挥了一定的作用(表 1)。RepViTBlock 通过引入残差连接和自注意力机制,增强了特征的融合能力,提高了模型在复杂工业场景中的适应性和鲁棒性。

2.3 错误样本分析

错误样本主要包括误检和漏检两类。图 5(a)(b)为公共数据集的测试样本对比图,图 5(c)(d)为自制数据集的测试样本对比图。由图 5 可知,YOLOv8-ASR 在误检和漏检方面比初始模型都有显著提升。




图 5 错误样本对比分析

误检样本大多数出现在具有复杂背景的图片中,例如齿轮表面存在油污、划痕或其他类似纹理的区域[图 5(a)(b)]。这些复杂的背景特征可能与实际缺陷特征相似,导致模型误判。在某些情况下,模型会将正常的表面反光误识别为“heipi”或“cm”缺陷^[9]。

漏检样本多集中在光照不足或反射严重的区域[图 5(c)(d)]。这些区域的特征往往不够清晰,导致模型无法有效提取和识别。通过引入更强的图像增强技术(如高动态范围增强技术)或在训练过程中使用更多类似样本进行数据扩展,可以减少漏检。此外,还可以采用自适应图像增强策略,根据实际环境光照条件动态调整图像预处理方法,提高模型的检测能力。

2.4 时间复杂度分析

为了评估 YOLOv8-ASR 模型的计算效率,对其时间复杂度进行了分析。尽管改进后的模型在每一

层的卷积操作和自注意力机制的计算量有所增加,但通过优化特征提取模块和检测头,有效降低了整体推理时间(图 6)。

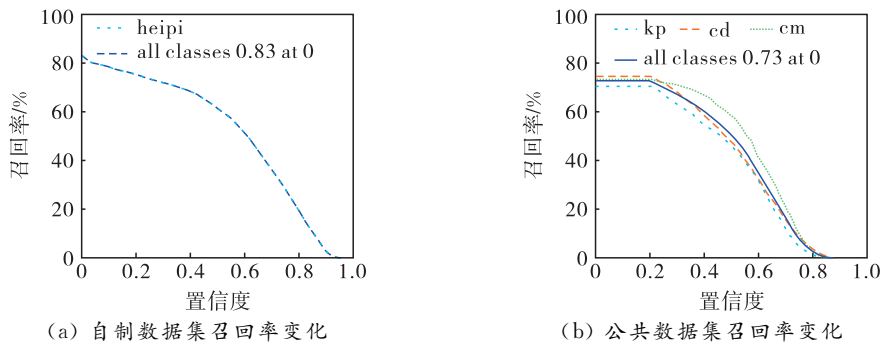


图 6 召回率-置信度曲线

新增的 AKConv 模块通过自适应卷积核大小的调整,提高了卷积操作的计算效率。尽管每一层的计算量增加,但其能够更好地捕捉多尺度目标,所以总体计算时间并未显著增加^[16]。这种优化对于多目标实时检测场景尤为关键,能够有效提升检测精度而不显著增加计算成本。

Swin Transformer 模块尽管增加了特征提取的复杂性,但其基于窗口的自注意力计算策略显著减少了计算量,确保了模型的实时性。通过局部窗口的自注意力操作,模型在保留全局特征的同时,有效减少了计算冗余,这对处理高分辨率图像尤为重要^[17]。

2.5 实验结果数据对比

为了进一步验证 YOLOv8-ASR 的优越性,将 YOLOv8-ASR 与 YOLOv8 模型进行对比,分析各个指标的 *mAP* 变化,实验结果如图 7 所示。图 7(a)(b)分别为公共数据集、自制数据集的 YOLOv8 精确度-召回率曲线,图 7(c)(d)分别为公共数据集、自制数据集的 YOLOv8-ASR 精确率-召回率曲线。

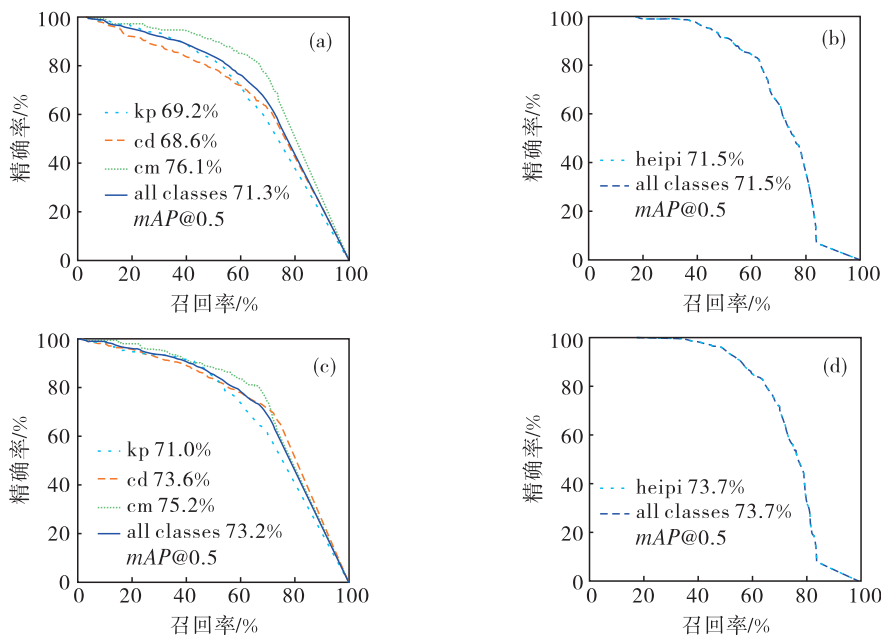


图 7 精确率-召回率曲线对比

在公共数据集[图 7(a)(c)]中,与 YOLOv8 模型相比,YOLOv8-ASR“kp”的 *mAP* 提高了 1.8 个百分点,“cd”的 *mAP* 提高了 5 个百分点,“cm”的 *mAP* 降低了 0.9 个百分点。这是因为在公共数据集中,YOLOv8-ASR 识别背景为金属反光的齿面时,多类别检测能力不足,误检增多,从而导致准确率降低,但

对比整体 mAP 指标时, YOLOv8-ASR 比 YOLOv8 模型提高了 1.9 个百分点, 整体性能得到提升。

在自制数据集[图 7(b)(d)]中, YOLOv8-ASR 的“heipi”与整体 mAP 均为 0.737, 比 YOLOv8 模型提高了 2.2 个百分点, 这证明改进算法对单类别检测能力提升明显, 能够准确检测常见的金属齿轮表面缺陷, 满足实际应用中的精度要求。

2.6 模型性能优化建议

基于上述分析, 提出以下几项模型优化建议, 以进一步提高改进 YOLOv8 模型的性能。一是动态权重调整与类别平衡训练。通过动态调整类别权重, 可以有效减少模型对某些类别的偏差。例如, 针对漏检率高的类别, 可以提高其在损失函数中的权重, 从而在训练过程中更多关注这些类别的特征。此外, 采用类别平衡策略, 如小批量采样和类别均衡损失函数, 也能显著改善模型的多类别检测性能。二是引入在线学习机制。在实际应用中, 缺陷检测模型需要持续应对新的检测场景和缺陷类型^[12]。引入在线学习机制, 使模型能够在部署过程中实时更新和优化, 提高其适应性和长期性能。

3 结论

本研究在 YOLOv8 模型基础上, 引入 Swin Transformer、AKConv 和 RepViTBlock 等模块, 结合 CLAHE 与 Real-ESRGAN 技术, 提出了一种自动化齿轮表面缺陷检测方法——YOLOv8-ASR。相较于 YOLOv8, 该方法显著提升了齿轮表面缺陷检测性能。实验结果显示, 改进后的模型在公共数据集上的 mAP 提高了 1.9 个百分点, 在自制数据集上的 mAP 提高了 2.2 个百分点, 模型在自制数据集上表现优异, 在公共数据集上整体性能有所提升, 但仍有改进空间, 主要方向为继续降低误检和漏检率。消融实验验证了各模块的有效性, Swin Transformer 提高了多尺度特征提取能力, AKConv 和 RepViTBlock 增强了检测精度和鲁棒性。

未来的研究可以考虑引入多模态数据(如红外或深度信息)和优化数据增强策略^[18], 以提升复杂场景下的检测性能和模型的鲁棒性。这些改进将进一步提高模型在工业自动化缺陷检测中的应用效果。

参考文献:

- [1] 于明源, 周景亮, 曾绍锋, 等. 基于 YOLOv8 改进的轴承表面缺陷检测方法[J]. 福建理工大学学报, 2024, 22(3): 280-285.
- [2] HUANG H, TANG X, WEN F, et al. Small object detection method with shallow feature fusion network for chip surface defect detection[J]. Scientific reports, 2022, 12(1): 3914.
- [3] CHEN J, LIU Z, WANG H, et al. Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network [J]. IEEE transactions on instrumentation and measurement, 2018, 67(2): 257-269.
- [4] RAMALINGAM B, MANUEL V H, ELARA M R, et al. Visual inspection of the aircraft surface using a teleoperated reconfigurable climbing robot and enhanced deep learning technique[J]. International journal of aerospace engineering, 2019, 2019(1): 5137139.
- [5] CHA Y, CHOI W, SUH G, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types [J]. Computer-aided civil and infrastructure engineering, 2018, 33(9): 731-747.
- [6] HSIEH C C, LIN Y W, TSAI L H, et al. Offline deep-learning-based defective track fastener detection and inspection system[J]. Sensors and materials, 2020, 32(10): 3429-3442.
- [7] 吕骏, 徐一雄, 符晓刚, 等. 基于深度学习的航天板级组件缺陷检测[J]. 自动化技术与应用, 2023, 42(10): 33-37.

- [8] 周曼,吴天钊,代宝鑫,等.深度学习在陶瓷表面缺陷检测方面的研究进展[J].陶瓷学报,2023,44(5):874-884.
- [9] 刘玉龙,吕权权,吴浩,等.基于深度学习的电子元件焊点缺陷检测方法[J].电子与封装,2023,23(6):38-43.
- [10] 贾东鑫,姚剑敏,严群,等.基于小样本深度学习的热轧带钢表面缺陷检测[J].信息技术与信息化,2023(6):182-185.
- [11] 孙晓辉.基于卷积神经网络的脐橙表面视觉品质检测方法研究[D].北京:中国科学院大学,2021.
- [12] 顾旭.基于视觉的工件表面质量检测系统的设计与实现[D].北京:中国科学院大学,2021.
- [13] 王德伟,刘小芳.基于改进 YOLOv8n 的带钢表面缺陷检测方法[J].国外电子测量技术,2024,43(7):158-169.
- [14] 黄石,李重重,庄伟玮,等.基于改进的 YOLOv8 算法在洗碗机餐具识别上的研究[J].日用电器,2024(2):45-51.
- [15] 王丽朵.基于改进 YOLOv5 的交通标志检测方法研究[D].兰州:西北师范大学,2023.
- [16] 孔佳骏.基于机器视觉的鼓型滚子表面缺陷检测方法研究[D].杭州:浙江工业大学,2023.
- [17] 戚学通,袁红春.基于自注意力机制和改进 YOLOv5s 的小目标生物检测[J].湖南农业大学学报(自然科学版),2024,50(3):108-114.
- [18] 江肖禹.基于机器学习的工业数据增强与数据安全研究[D].杭州:浙江大学,2023.

Research on visual detection method for surface defects of disc-shaped gears based on improved YOLOv8

LI Chengzhang¹, ZHANG Pengkui², CHEN Junbao¹

(1. College of Automotive Intelligent Manufacturing, Hubei University of Automotive Technology;
2. Dongfeng Equipment Manufacturing Co., Ltd., Shiyan 442000, China)

Abstract: Gear is the core transmission component in mechanical system, and its surface quality has a direct impact on the stability and service life of the system. Given the low efficiency and low accuracy of the traditional manual visual inspection method, an automatic gear surface defect detection algorithm named YOLOV8-ASR was proposed based on YOLOv8. The performance of YOLOv8-ASR by introducing such models as Swin Transformer, AKConv and RepViTBlock. The experimental findings show that compared with YOLOv8, YOLOV8-ASR's *mAP* on public data sets has improved by 1.9 percentage points, and it still performs well in the "beipi" defect detection task on self-made data sets. The research results of this study provide an efficient and reliable solution for automatic defect detection in industrial gear manufacturing process.

Keywords: YOLOv8; gear defect detection; machine vision; deep learning; Swin Transformer; AKConv; RepViTBlock

(责任编辑:王新亮)

引用格式 李承璋,张鹏魁,陈君宝.基于改进 YOLOv8 的盘状齿轮表面缺陷视觉检测方法[J].山东航空学院学报,2025,42(4):65-72.

LI C Z, ZHANG P K, CHEN J B. Research on visual detection method for surface defects of disc-shaped gears based on improved YOLOv8[J]. Journal of Shandong University of Aeronautics, 2025, 42(4): 65-72.