

# 融合 DCGAN 与 YOLOv11 的 轴承缺陷检测技术研究与应用

杨棋雯

(天津师范大学, 天津 300387)

**摘要** 工业轴承缺陷样本存在“获取难、数量少”的困境,影响了模型的检测精度与泛化能力。而基于 DCGAN 与 YOLOv11 的缺陷检测方案,很大程度上解决了这一问题。通过 DCGAN 深度学习缺陷的关键特征,生成合成的缺陷样本来扩充数据集,并采用 YOLOv11 检测模型进行缺陷检测。实验结果表明,经数据增强后的样本表现优异,模型 mAP50 达 88.996%,精确率与召回率分别为 91.481% 和 83.880%。同时,检测速度维持在 32 FPS,满足工业实时检测需求。该方案突破了工业轴承缺陷样本获取难的制约,旨在为工业缺陷检测提供参考方案。

**关键词** DCGAN; YOLOv11; 工业轴承缺陷检测; 样本增强

**中图分类号**: TH133; TP3

**文献标志码**: A

**DOI**: 10.3969/j.issn.2097-3365.2026.06.005

## 0 引言

工业轴承是旋转机械的核心部件,广泛应用于多种工业领域。复杂工况易使其产生凹槽、划痕等缺陷,及时、精准、高效地检测缺陷对保障工业生产至关重要。

随着深度学习的发展,基于视觉的检测方法因其检测成本低、适应性好、检测速度快等优点受到了广泛的关注。其中, YOLO 系列算法在工业缺陷检测场景中得到广泛应用。其中侯芯露等的实验证实, YOLOv11 在工业缺陷检测中以 5.0 s 单轮训练耗时和 0.73 的 mAP50 指标,表现优于主流 YOLO 模型,为工业检测提供了可靠算法支撑<sup>[1]</sup>。

设备运行环境复杂、缺陷发生率低等原因会导致轴承缺陷样本难获取。为解决这一问题,数据增强技术成为研究热点。生成对抗网络能够学习真实数据的分布特征并生成高保真的合成样本。陈欣等提出 DCGAN 数据增强与 YOLO 算法结合的检测方案,通过 DCGAN 学习真实缺陷特征并生成高质量样本,融合后用于 YOLO 模型训练,实验证实该方法显著提升了检测准确率与召回率<sup>[2]</sup>。

基于此,本文提出一种基于 DCGAN 与 YOLOv11 的工业轴承样本缺陷检测方案。通过 DCGAN 生成缺陷样本以此扩充数据集,突破工业轴承缺陷数据难获取的问题<sup>[3]</sup>;采用 YOLOv11 作为检测模型,在混合数据集上完成训练与参数优化,并以真实工业轴承缺陷数据

为基础,旨在为工业轴承缺陷检测提供切实可行的技术应用方案。

## 1 工业缺陷检测相关技术与研究现状分析

### 1.1 现有数据增强技术分类及特点

针对工业缺陷数据采集难的问题,现有数据增强技术主要通过优化数据利用效率、补充数据多样性两类路径解决此类问题。

传统数据变换增强针对已收集到的少量真实样本,通过几何变换、像素调整等方式拓展数据规模。这类方法无需复杂算法支撑,能快速扩充样本数量,但仅能对现有样本特征进行简单重构,无法创造新的缺陷形态或纹理特征,对数据多样性的提升有限,难以满足复杂缺陷检测模型的训练需求<sup>[4]</sup>。

生成式数据补充增强借助生成对抗网络(GAN)、物理渲染(PBR)等技术,基于少量真实样本的特征分布,生成高质量、高保真的合成缺陷样本。其中, DCGAN 作为主流生成式增强方法,相较于传统数据变换增强具备显著优势。

### 1.2 GAN 系列模型应用现状与 DCGAN 优势分析

GAN 系列模型已被应用于工业缺陷数据增强,如利用 GAN 生成金属表面裂纹、零件磨损等缺陷样本<sup>[5]</sup>。其中 DCGAN 其可创造全新缺陷特征,无需依赖现有样本的简单变换,能通过学习真实缺陷的纹理、形态、

**作者简介**: 杨棋雯(2005-),女,本科,研究方向:计算机视觉。

分布规律,生成具有全新特征组合的缺陷样本,有效补充真实采集难以覆盖的稀缺缺陷类型;能够提升样本多样性与真实性,生成样本不仅能模拟不同光照、角度下的缺陷表现,还能还原缺陷的细节纹理与结构特征,与真实样本的特征一致性高,能针对性补充少量样本中缺失的特征维度,缓解数据分布不均衡问题。DCGAN 凭借其优异的图像生成能力,成为破解数据难采集困境的有效手段,但针对轴承多类型缺陷,如凹槽、划痕、擦伤的定向生成研究仍需补充。

## 2 基于 DCGAN 与 YOLOv11 的研究方法

### 2.1 核心模型架构设计 (DCGAN 与 YOLOv11)

#### 2.1.1 深度卷积生成对抗网络 DCGAN

DCGAN 是生成对抗网络 (GAN) 的变形,由 Radford 等提出。其核心是将深度卷积神经网络 (CNN) 的层级结构与对抗训练机制结合,替代传统 GAN 的全连接网络架构,成为工业缺陷样本生成、图像风格迁移等领域的主流数据增强技术。DCGAN 由生成器和判别器两个深度卷积子网络构成,二者通过“对抗训练”使生成器能够输出与真实数据分布高度拟合的合成样本。

其判别器 (D) 的 CNN 结构设计 (特征提取端) 为卷积分类网络,核心是层级化提取特征并判断样本真实性,CNN 结构遵循“下采样+特征聚合”逻辑。基础卷积层,用  $3 \times 3/4 \times 4$  小卷积核、Stride=2 实现无池化下采样,保留空间拓扑信息;Same Padding 避免边缘特征丢失,全程无全连接层。激活与正则化,卷积层后接 LeakyReLU ( $\alpha=0.2$ ) 缓解梯度消失,除输入层外均加 BN 层稳定训练;输出层经全局平均池化+全连接,用 Sigmoid 输出 0 至 1 概率值。

生成器 (G) 的 CNN 结构设计 (样本生成端),生成器为转置卷积网络,核心是将低维噪声映射为高维图像,结构与判别器对称,转置卷积层, $4 \times 4$  卷积核、Stride=2 实现上采样,无池化层,保证缺陷细节完整。激活与正则化,隐藏层用 ReLU 增强特征映射,全网加 BN 层避免伪影,输出层用 Tanh 将像素值压缩至  $[-1, 1]$ ,匹配真实样本分布。

#### 2.1.2 YOLOv11

YOLOv11 是 Ultralytics 团队推出的单阶段目标检测算法。其核心架构包含输入层、主干网络、Neck 层与输出层四大模块。其中输入层支持超分辨率输入与多尺度自适应增强,强化对微小缺陷 (轴承细微划痕等) 的特征捕捉;主干网络升级为 C3f 模块,能够高效提取缺陷的纹理、形态等层级特征,兼顾特征表达力与计算效率。Neck 层融合 FPN 与 PAN 双向特征金字塔优势,

新增跨尺度连接通道,优化多尺度缺陷的特征融合效果;输出层采用“解耦检测头结合空间注意力”设计,分类与回归任务独立优化,搭配 EIoU 损失函数,精准修正边界框位置偏差,降低小目标与遮挡缺陷的误检率。此外,模型通过轻量化结构设计优化参数,在工业流水线场景中推理速度可达数十 fps,同时 mAP50 指标较前代显著提升,实现了检测精度与实时性的高效统一,适配工业缺陷检测的核心需求。

### 2.2 数据收集

数据集来源于 CSDN 公开标注数据集,包含轴承凹槽 (aochao)、擦伤 (cashang)、划痕 (huaheng) 三类缺陷,原始数据各 1 000 余张。为凸显小样本场景与 DCGAN 的优势,人工筛选后将样本量精简为:划痕 544 张、擦伤 458 张、凹槽 326 张,仅对稀缺性显著的擦伤缺陷进行 DCGAN 生成扩充。

### 2.3 评价指标

采用目标检测核心指标评估模型性能,包括精确率 (Precision)、召回率 (Recall)、平均精度均值 (mAP50、mAP50-95),同时分析训练过程中的 box\_loss、cls\_loss、df1\_loss 变化以验证模型收敛性。通过混淆矩阵与 PR 曲线,评估模型对不同缺陷类别的识别能力。

### 2.4 实验设计

实验分为两组对比,对照组使用精简后的原始数据集训练 YOLOv11;实验组使用原始数据集+DCGAN 生成的 489 张擦伤合成样本 (已剔除低质量样本) 训练模型。两组均采用统一训练参数 (imgsz=640、batch=2、amp=True),迭代 90 轮后对比检测性能,验证 DCGAN 数据增强的有效性。

## 3 轴承缺陷检测实验实施流程与问题解决方案

### 3.1 实验步骤

硬件使用 CPU 进行训练,软件使用 Python 环境,依赖 OpenCV、PyTorch、Ultralytics 等库,数据集采用 VOC 格式组织,模型训练与推理基于 YOLOv11 框架。

数据预处理,通过 voc\_label.py 将 XML 标注文件转换为 YOLO 格式标签,利用 split.py 按 320:70:54 的比例划分训练集、验证集、测试集。

DCGAN 训练与样本生成,基于 Generator.py 与 Discriminator.py 构建模型,通过 train.py 训练 400 轮后,利用 generate.py 生成擦伤缺陷样本,筛选后保留 489 张高质量样本。

模型训练,通过 train\_yolov11.py 加载 YOLOv11

预训练权重,在混合数据集上训练 90 轮,实时监控损失与评估指标。

性能验证,使用 predict.py 对测试集进行推理,生成混淆矩阵、PR 曲线等可视化结果。

### 3.2 遇到的问题 and 解决方案

合成样本质量参差不齐,通过相似度计算(如直方图匹配、MSE)筛选低相似度样本,剔除 489 张生成样本中效果不佳的部分;模型训练过拟合,采用混合精度训练(amp=True)与数据集随机打乱,结合验证集实时调整学习率,确保模型泛化能力;缺陷类别标注格式不统一,通过 2\_show\_xml.py 可视化目标框,修正标注错误,统一三类缺陷的标签命名与边界框格式。

## 4 结果与分析

### 4.1 实验结果

模型训练至第 88 轮时达到最佳性能,mAP50 达到 88.996%,mAP50-95 达 61.157%,精确率与召回率分别为 91.481% 和 83.880%;三类缺陷中,凹槽、擦伤、划痕的 mAP@0.5 分别为 0.880、0.802、0.912,整体 mAP@0.5 达 0.865;模型检测速度维持在 32 FPS,满足工业实时需求。

### 4.2 数据分析

在训练过程中,训练集 box\_loss 降至 0.84 299、cls\_loss 降至 0.55 031,验证集 box\_loss 降至 1.13 378、cls\_loss 降至 0.71 203,各项损失函数稳定收敛,表明混合数据集有效提升了模型学习效果;擦伤缺陷的识别准确率显著提升,验证了 DCGAN 生成样本对小样本类别的补充作用;模型在高置信度区间(0.923)仍能保持 1.0 的精确率,鲁棒性良好。

### 4.3 结果讨论

实验结果表明,DCGAN 生成的擦伤样本有效弥补了小样本缺陷的特征缺失,使 YOLOv11 模型在三类缺陷检测中均表现优异。相较于未使用 DCGAN 增强的缺陷,经过增强的擦伤缺陷的召回率提升最为明显,说明定向生成稀缺陷样本是破解数据难采集困境的关键。但模型对划痕与擦伤的区分仍存在少量混淆,后续可通过优化 DCGAN 生成策略与 YOLOv11 特征融合模块进一步提升性能。

### 4.4 模型场景适应能力分析

#### 4.4.1 多尺度缺陷适配性

工业轴承缺陷存在显著尺度差异,从微小划痕(像素级)到明显凹槽(厘米级)均有覆盖。实验结果显示,模型对三类缺陷的 mAP@0.5 均超过 0.8,其中划痕(细长型小尺度缺陷)检测精度达 0.912,凹槽(大尺度缺

陷)达 0.880,表明 YOLOv11 的多尺度特征融合能力与 DCGAN 生成样本的特征多样性,能够有效支撑不同尺度缺陷的精准识别,适配工业生产中缺陷形态的复杂性。

#### 4.4.2 复杂环境抗干扰性

在实际工业场景中,轴承图像易受光照变化、油污覆盖、背景噪声等干扰。通过对测试集添加不同强度高斯噪声、调整亮度对比度模拟复杂环境,模型 mAP50 仅下降 3.2%,精确率维持在 88% 以上。这一结果说明,DCGAN 生成样本时学习的缺陷纹理、形态等核心特征具有强鲁棒性,降低了环境干扰对检测性能的影响,满足车间等复杂工况的应用需求。

## 5 结束语

本文针对工业轴承缺陷“获取难、数量少”的样本困境,提出基于 DCGAN 与 YOLOv11 的检测方案。通过 DCGAN 定向生成 489 张高质量擦伤缺陷样本,有效扩充了小样本数据集;YOLOv11 在混合数据集上的训练结果表明,模型 mAP50 达 88.996%,实时检测速度 32 FPS,满足工业应用需求,可为工业现场轴承缺陷检测提供技术支撑,也为同类设备的缺陷检测提供了技术参考。未来可从以下方面进行优化:一是优化模型适配更多类型轴承缺陷检测,提升现场工况适应性;二是推进轻量化部署,强化实时检测与运维预警的工程应用价值;三是将该实用方案推广至同类工业零部件检测,形成通用化小样本检测技术方案,助力工业生产智能化升级。

## 参考文献:

- [1] 侯芯露,黄凌霄,姚新波,等.基于多版本 YOLO 模型的工业缺陷检测性能对比研究[J].电脑知识与技术,2025,21(31):20-25.
- [2] 陈欣,王伟,许威,等.基于 DCGAN 数据增强和 YOLO 算法的不锈钢缺陷检测[J].价值工程,2025,44(28):11-14.
- [3] 胥姜苗,曹爽,管海燕.基于改进 YOLOv8 的轻量化钢材表面缺陷检测方法[J].电子测量技术,2025,48(24):138-147.
- [4] 时培明,申世春,叶蕾,等.基于改进 DCGAN 网络的钢材表面缺陷图像数据增强方法[J].计量学报,2025,46(09):1377-1384.
- [5] 李晋芳,肖立宝,何明桐,等.基于生成式样本合成的工件缺陷样本数据增强[J].广东工业大学学报,2025,42(03):27-35.