

# 基于改进 Faster R-CNN 网络的铝型材表面小目标缺陷检测方法

杨妮, 冯连强, 王志超, 宋美莹, 王富强

(中国重型机械研究院股份公司, 陕西 西安 710032)

**摘要:** 针对铝型材表面漆泡和脏点等小目标缺陷检测中漏检率高、误检频繁等问题, 提出一种基于 Faster R-CNN 网络的改进型铝型材表面小目标缺陷检测方法。首先, 构建小目标缺陷专用数据集, 并结合缺陷尺寸分布与形态特征重新设计 anchor 尺度及比率; 其次, 采用 ROI-Align, 消除像素量化偏差以提升缺陷定位精度; 最后, 引入 Soft-NMS 算法, 优化冗余预测框筛选策略。实验结果表明, 改进后的网络模型对漆泡缺陷的平均精度 (AP) 达 64.06%, 较原始 Faster R-CNN 提升 12.99 个百分点; 对脏点缺陷的 AP 值达 82.98%, 较原始网络提升 6.59 个百分点。该方法有效提升了铝型材表面小目标缺陷的检测性能, 为工业场景下的高精度缺陷检测提供了可行技术解决方案。

**关键词:** 深度学习; Faster R-CNN; 铝型材表面缺陷检测; ROI-Align; Soft-NMS

## 0 引言

铝型材凭借轻质、高强、耐腐蚀等优异特性, 广泛应用于建筑、轨道交通、航空航天等关键领域。在铝型材挤压、轧制、喷涂等生产环节, 受工艺参数波动、环境杂质侵扰等因素影响, 其表面易产生漆泡、脏点、擦花等多种缺陷。其中, 漆泡与脏点因尺寸微小、形态不规则, 检测难度大。小目标缺陷的漏检或误检将直接影响铝型材产品质量与寿命, 实现其高精度检测对保障工业生产具有重要现实意义。

传统铝型材表面缺陷检测依赖人工或接触式检测, 存在效率低、主观性强、抗环境干扰能力弱等问题。基于神经网络的目标检测方法已成为工业缺陷检测领域的主流技术。主要分为两类: 以 R-CNN、Fast R-CNN、Faster R-CNN 等系列为代表的两阶段检测算法, 精度高, 但速度相对较慢; 以 YOLO 系列、SSD 为代表的单阶段检测算法, 速度快, 但小目标检测上精度不足。

近年来, 针对工业产品表面缺陷检测, 国内外学者们提出了多种改进方法。例如, Dai 等通过嵌入特征融合模块改进 R-CNN 算法, 实现精密工件表面缺陷的高效检测; He 等提出基于卷积自编码器 (CAE) 与半监督生成对抗网络 (SGAN) 的检测方法, 提升无标记样本场景下的检测性能; 向宽等引入特征金字塔网络 (FPN), 增强铝材表面小缺陷特征表达能力; 陈坤等加入残差结构并融合多尺度语义信息, 改善小目标与极端长宽比缺陷的检测效果; 沈晓海等提出多任务深度学习框架, 缓解铝材缺陷样本稀疏导致的模型过拟合问题。

现有基于 Faster R-CNN 的改进方法在工业缺陷检测中取得一定进展, 但针对铝型材表面漆泡、脏点

等典型小目标缺陷, 仍存在 anchor 匹配度低、定位不准、冗余框筛选不合理等问题, 导致检测精度难以满足实际生产需求。本文以 Faster R-CNN 为基础网络, 通过优化数据集构建、anchor、改进定位模块及后处理算法, 提出一种适用于铝型材表面小目标缺陷的高精度检测方法, 旨在解决小目标缺陷的漏检与误检问题。

Faster R-CNN 目标检测网络原理

Faster R-CNN 网络主要包括提取目标特征的卷积层、生成待测目标候选区的区域生成网络 RPN (Region Proposal Network)、调节候选区域尺寸的 RoI 池化层以及全连接分类层四部分, 其网络结构如图 1 所示。




图1 Faster R-CNN网络结构

Faster R-CNN 网络是由 Fast RCNN 网络和 RPN 网络组成, 其损失函数包括 RPN 网络损失函数和 Fast RCNN 网络损失函数。RPN 网络的损失函数如式 (1) 所示:

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (1)$$

上式中  $p_i$  表示将第  $i$  个 anchor 预测为目标的概率;  $p_i^*$  为第  $i$  个 anchor 的真实标签情况, 当为正样本时, 其为 1, 当为负样本时, 其为 0;  $t_i$  表示第  $i$  个 anchor 预测的边界框坐标;  $t_i^*$  表示第  $i$  个 anchor 所对应的真实框坐标;  $N_{cls}$  表示一个训练小批量中 anchor 的个数;  $N_{reg}$  表示需要回归的 anchor 个数;  $\lambda$  表示均衡系数;  $L_{cls}(p_i, p_i^*)$  是 RPN 网络中 cls layer 损失;  $L_{reg}(t_i, t_i^*)$  是 RPN 网络中 reg layer 的回归损失。Faster R-CNN 网络的实际训练步骤如图 2 所示。




图2 Faster R-CNN网络训练流程  
实验平台搭建与小目标数据集制作  
检测系统设计

基于改进 Faster R-CNN 的铝型材表面小目标缺陷检测系统由图像采集、离线模型训练与在线缺陷检测三个模块构成, 系统整体结构如图 3 所示。




图3 铝型材表面缺陷检测系统整体结构

### 2.2 小目标数据集制作

高质量数据集是深度学习模型训练的基础, 是小目标缺陷检测的关键。本文采用数据扩充技术增加样本数量与多样性, 具体包括: 水平翻转、垂直翻转、随机旋转、图像缩放、伽马变换及手动复制缺陷目标, 提升小目标缺陷被 anchor 覆盖概率, 小目标缺陷扩增前后被 anchor 包围情况如图 4 所示。




图4 anchor 包围情况

采用 LabelImg 标注工具对所有铝型材表面缺陷图像进行手动精准标注, 并明确缺陷边界框坐标与类别信息。图 5 为漆泡与脏点两类缺陷扩增前后示意图。




图5 小目标缺陷扩增

### 3 改进的小目标缺陷检测方法

本文从 anchor 优化、定位模块改进与后处理算法优化三个关键维度对网络进行改进, 重点强化对小目标缺陷的适配能力。

#### 3.1 改进 anchor 比率

基于数据集中标注的漆泡与脏点缺陷尺寸统计结果, 重新设计 anchor 尺度与比率, 将 anchor 尺度调整为 [4, 8, 16, 32], 以适配小尺寸目标的覆盖需求; 将比率调整为 [1:2, 1:1, 2:1, 3:1], 以匹配条形及不规则形态小目标缺陷。优化后共生成 16 种不同尺寸与比率的 anchor, anchor 优化前后对比如图 6 所示。




图6 anchor 比率优化前后对比

#### 3.2 ROI-Align

采用 ROI-Align 摒弃浮点数取整操作的改进方法, 通过双线性插值算法对特征图上的非整数坐标位置进行像素值计算, 有效提升小目标缺陷的定位精度。ROI-Align 结构如图 7 所示。




图7 ROI-Align

#### 3.3 Soft-NMS

为解决目标检测后处理阶段非极大值抑制 (NMS) 算法阈值设置过大或过小引发漏检、误检问题, 本文引入 Soft-NMS 算法替代传统 NMS 算法。核心改进在

于根据 IoU 大小对其置信度进行衰减, IoU 越大, 置信度衰减越明显, 最终通过置信度阈值筛选保留有效预测框, 该算法可有效区分相邻小目标缺陷与冗余框, 显著提升密集小目标缺陷的检测效果。算法置信度衰减公式如式 (2) 所示。

$$s_i = \begin{cases} s_i, iou(M, b_i) < t \\ s_i(1 - iou(M, b_i)), iou(M, b_i) \geq t \end{cases} \quad (2)$$

#### 4 实验与结果

本文选择 TensorFlow 深度学习数值计算的开源框架, 处理大量数据并建立数学模型。经反复调参得最终超参数设置: 初始学习率设为 0.001, 每迭代 10000 轮学习率衰减 10 倍, 权重衰减系数为 0.0001, 动量值为 0.9, 批量大小为 2。铝型材表面缺陷检测平台, 如图 8 所示。



图8 缺陷检测平台

采用改进后 Faster R-CNN 模型对测试集图像进行检测, 检测效果如图 9 所示。左图为原始图像, 右图为模型检测结果, 改进后的模型能精准识别并定位漆泡与脏点两类小目标缺陷, 未出现明显漏检与误检现象。




图9 缺陷检测效果图

对同一小目标缺陷使用 ROI-Pooling 和 ROI-Align 进行对比。实验结果如表 1 所示, 采用 ROI-Align 对小目标缺陷检测效果有明显提升。

表1 ROI-Pooling 与 ROI-Align 实验对比

	脏点1	脏点2	漆泡1	漆泡2
真实边界框	[572, 602, 628, 669]	[1236, 1469, 1305, 1527]	[895, 1505, 927, 1528]	[2113, 1481, 2157, 1529]
ROI-Pooling	[568, 604, 633, 670]	[1236, 1472, 1309, 1531]	[894, 1502, 933, 1530]	[2109, 1487, 2167, 1529]
IoU1	0.78	0.80	0.61	0.64
ROI-Align	[572, 600, 629, 671]	[1236, 1468, 1306, 1527]	[895, 1505, 929, 1529]	[2112, 1480, 2157, 1531]
IoU2	0.87	0.91	0.79	0.85

#### 4.1 实验结果对比

采用平均精度、精确率、召回率作为核心评价指标, 基于测试集全面评价改进后模型的检测性能, 漆泡和脏点两类缺陷检测性能对比结果如表 2、表 3 所示, 改进后模型的训练损失曲线如图 10 所示。

表2 漆泡检测结果

	AP/%	目标个数	TP	FP	FN
Faster R-CNN	51.07	107	56	24	51
改进后的 Faster R-CNN	64.06	177	129	32	48

改进后 Faster R-CNN 模型对两类小目标缺陷的检测性能均显著提升: 漆泡缺陷, 平均精度值从 51.07% 提升至 64.06%, 提升幅度达 12.99 个百分点, 精确率与召回率分别提升 10.12 个百分点与 20.54 个百分点; 脏点缺陷, 平均精度值从 77.39% 提升至 82.98%, 提升幅度为 6.59 个百分点, 精确率与召回率分别提升




图10 Faster R-CNN损失曲线

6.01 个百分点与 10.10 个百分点。验证了本文提出的 anchor 优化、ROI-Align 替代及 Soft-NMS 优化策略的有效性，能有效解决原始模型对小目标缺陷的漏检与误检问题，显著提升检测性能。

改进前后 Faster R-CNN 网络对漆泡检测效果图如图 11 所示，左、右侧分别为改进前、后。




图 11 Faster R-CNN 网络优化前后对漆泡检测效果

改进前后 Faster R-CNN 网络对脏点类小目标缺陷的检测结果如表 3、图 12 所示。改进后的网络对于脏点类小目标缺陷的检测平均精度值提高了 6.59%，达到 82.98%，左、右图分别为改进前、后。

表3 脏点检测结果

	AP/%	目标个数	TP	FP	FN
Faster R-CNN	77.39	85	69	17	16
改进后的Faster R-CNN	83.98	195	178	29	17




图12 Faster R-CNN网络优化前后对脏点检测效果

## 5 结论

基于 Faster R-CNN 网络改进方法通过构建专用小目标数据集、优化 anchor 尺度与比率、采用 ROI-Align 替代 ROI-Pooling 及引入 Soft-NMS 算法等一系列改进策略，有效提升了小目标缺陷的检测精度与定位精度。在实际工业场景实物平台上验证了其有效性，能精准检测铝型材表面小目标缺陷，满足工业生产的自动化、高精度检测需求。解决铝型材表面漆泡、脏点等小目标缺陷检测中存在的漏检、误检问题。

## 参考文献

[1] 何恺明, 张旭阳, 任少卿, 等. 深度卷积网络中的空间金字塔池化用于视觉识别 [J]. 《IEEE 模式分析与机器智能汇刊》, 2015, 37(9): 1904-

1916.

[2] 任少卿, 何恺明, Girshick R, 等. Faster R-CNN: 利用区域提议网络实现实时目标检测 [J]. 《IEEE 模式分析与机器智能汇刊》, 2017, 39(6): 1137-1149.

[3] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multiBox detector [C] //Proceedings of European Conference on Computer Vision. Heidelberg: Springer, 2016: 21-37.

[4] Sermanet P, Eigen D, Zhang X, et al. OverFeat: integrated recognition, localization and detection using convolutional networks[OL]. [2019-07-03]. <https://arxiv.org/abs/1312.6229>

[5] Bochkovskiy A, Wang C Y, Liao H. YOLOv4: Optimal Speed and Accuracy of Object Detection [J]. 2020.

[6] 何迪, 徐科, 周鹏, 周东东. 基于新型半监督学习方法的钢材表面缺陷分类 [J]. 光学与激光工程, 2019, 117.

[7] 朴杰康, 权培根, 朴俊赫, 康东忠. 基于机器学习的表面缺陷检测成像系统 [J]. 精密工程与制造国际期刊-绿色技术, 2016, 3(3).

[8] 徐秀, 宣静怡, 曹桐滔, 代作晓. 基于 Faster R-CNN 的圆柱形金属工件表面缺陷检测 [J]. 软件导刊, 2019, 18(05): 130-133.

[9] 向宽, 李松松, 栾明慧, 杨莹, 何慧敏. 基于改进 Faster RCNN 的铝材表面缺陷检测方法 [J]. 仪器仪表学报, 2021, 42(01): 191-198.

[10] 陈坤, 徐向纭. 改进 Faster RCNN 在铝型材表面缺陷检测中的应用研究 [J]. 中国计量大学学报, 2020, 31(02): 240-246.