

引文格式: 王珏, 卢震宇, 张晓巍, 等. 基于多级卷积与形状增强的蒙皮缺陷检测方法[J]. 航空制造技术, 2026, 69(6): 25010131.

WANG Jue, LU Zhenyu, ZHANG Xiaowei, et al. Skin defect detection method based on multilevel convolution and shape enhancement[J]. Aeronautical Manufacturing Technology, 2026, 69(6): 25010131.

基于多级卷积与形状增强的蒙皮缺陷检测方法

王珏¹, 卢震宇^{2,3}, 张晓巍¹, 孙玉文^{2,3}, 朱丽¹

(1. 沈阳飞机工业(集团)有限公司, 沈阳 110850;

2. 大连理工大学机械工程学院, 大连 116024;

3. 大连理工大学高性能精密制造国家重点实验室, 大连 116024)

[摘要] 飞机蒙皮作为飞机关键结构部件, 表面缺陷直接影响飞机整体结构性能和隐身性能。本文提出一种基于 RT-DETR 模型的深度学习检测网络, 以提升飞机蒙皮缺陷检测的准确性与鲁棒性。针对缺陷多尺度、形态多变, 以及分布复杂的问题, 设计多项创新技术予以优化。特征提取阶段引入多级卷积块(Multilevel convolution blocks, MCB), 通过多层次卷积操作强化不同尺度特征的判别性, 有效捕捉各层次细节信息; 特征融合阶段采用多尺度特征增强(Multiscale feature enhancement, MSFE)模块, 通过多尺寸深度卷积核构建上下文信息, 提升网络对多尺度缺陷特征的鲁棒性与适应性; 回归阶段引入形状感知(Shape-IoU)优化模块, 通过优化边界框与缺陷轮廓的匹配度, 显著提升检测结果的精确度。试验结果显示, 所提出的检测网络在 Aircraft 数据集上的 mAP@0.5 达 94.8%, 较原 RT-DETR 模型提升 12.7%; 在 NEU-DET 测试集上的 mAP@0.5 为 92.5%。上述结果验证了该模型在提升飞机蒙皮缺陷检测精度与泛化能力方面的有效性。

关键词: 蒙皮缺陷检测; 多级卷积块; 多尺度特征增强; 目标检测; 损失函数

中图分类号: V267+2

文献标志码: A

DOI: 10.16080/j.issn1671-833x.25010131



王珏

研究员, 研究方向为钣金加工。

飞机蒙皮缺陷检测对保障结构安全性、延长服役寿命至关重要。蒙皮作为飞机结构最外层, 既承受气动载荷, 又承担密封、防腐蚀及内部结构保护等功能, 造成其缺陷类型多样(如裂纹、凹陷、腐蚀、撞击痕迹等), 尺寸与形态差异显著(从微小裂纹至较大凹陷)。由于分布受气动载荷、温度变化等外部因素影响而极具复杂性, 部分缺陷仅在特定角度或条件下可见^[1]。缺陷多样性与变异性导致传统图像处理方法检测效率低、精度不足, 难以识别微小及隐蔽缺陷。现有超声波^[2-3]、涡流^[4-5]、红外热成像^[6-7]等自动化检测技术虽提升了

检测精度, 但因设备昂贵、检测范围有限, 对操作环境敏感, 仍难以充分适配复杂蒙皮结构的检测需求。因此, 设计一种可处理不同尺度与形态缺陷, 且具备高适应性的图像识别技术, 成为保障飞机结构安全与延长服役寿命的关键^[8]。

现有研究多采用卷积神经网络基于分类与分割模型实现缺陷图像的识别与定位。Zhao 等^[9]采用编码器-解码器结构的 U-Net 对蒙皮图像进行初步分割, 通过引入残差块增强特征传播能力, 以挖掘更多缺陷细节特征信息, 利用视觉注意机制提升缺陷区域权重, 削弱光照不均带来的

收稿日期: 2025-09-02; 退修日期: 2025-11-11; 录用日期: 2025-11-28

基金项目: 国家自然科学基金(52535011)

干扰。Wu 等^[10]提出适用于低图像复杂度场景的增强目标检测算法,为验证该方法,构建了包含 5 种损伤类型,图像背景只有飞机蒙皮的损伤数据集。试验结果显示,所提出的加性特征融合注意机制在该类低复杂度场景中,可在保证模型精度的同时降低模型参数。RT-DETR^[11]、Faster R-CNN^[12]、RetinaNet^[13]等先进目标检测算法,在缺陷检测中表现出高精度与实时性兼顾的优良性能。Wu 等^[14]提出基于改进 Mask Scoring R-CNN 的损伤检测方法,通过在特征提取网络中嵌入注意力模块,强化特征表达能力,提升损伤检测与分割效果。Li 等^[15]提出高效的飞机蒙皮紧固件缺陷检测网络,其采用四层检测层与残差空间金字塔池化模块,所设计的注意力融合特征金字塔网络,可自适应融合特征,并净化语义冲突,且构建含旋转变压器模块与坐标注意力的注意力头作为特征检测模块,提升缺陷定位精度。然而,上述方法仍存在小样本数据依赖性强、轻微缺陷敏感性不足等局限。

为此,本文提出一种基于多级卷积块与形状感知增强的新型检测网络,在飞机蒙皮缺陷数据集上完成了试验评估与结果验证。该方法通过智能图像识别算法实现多类缺陷的高效准确识别,且具备非接触、自动化、广覆盖等优势,为飞机蒙皮智能检测与维护提供可靠支撑。

1 蒙皮缺陷检测方法

该模型基于 RT-DETR 改进,输入阶段先对蒙皮图像执行初步卷积^[16]与最大池化^[17],完成基础特征提取与空间下采样,为深层建模提供语义基础。针对裂纹缺陷细长、方向多变的特性,引入多级卷积块强化细节结构的连续性与方向敏感性;针对凹陷缺陷边缘过渡平缓、形状多样的特点,采用多尺度卷积提取局部曲面形态信息。为提升特征表达能

力,模型集成多级卷积块(Multilevel convolution blocks, MCB)模块^[18]与自适应特征融合模块^[19],在维持语义一致性的前提下动态融合多级信息,通过 1×1 卷积完成通道压缩,针对缺失螺栓体积小、形状规则的特性,自适应融合可放大细微结构差异,强化目标与背景对比度;针对漆面剥落纹理复杂、边界不规则的特点,MCB 模块在多层特征融合中保留纹理细节与颜色变化信息。在多尺度鲁棒性方面,多尺度特征增强(Multiscale feature enhancement, MSFE)模块引入 5×5 、 7×7 、 9×9 、 11×11 的多尺寸深度卷积核构建 Focus Feature 结构^[20],结合 Identity 映射与 C2f 连接方式,在保障特征连续性的同时提升上下文表达能力。针对划痕细长曲折、跨度不一的特性,大尺寸卷积核强化长程依赖建模能力,小尺寸卷积核捕捉局部边缘细节。解码器将融合特征上采样至原图尺寸,实现精准目标回归与分类。引入 Shape-IoU 模块^[21],在传统 IoU 回归基础上嵌入形状感知机制,同步优化边界框位置与轮廓匹配度,有效降低裂纹、划痕等非规则缺陷的漏检与误检率,进而在多种复杂缺陷场景下维持优异检测性能(图 1)。

1.1 多层次卷积模块

为解决飞机蒙皮缺陷在不同尺度与形态下特征难以同步捕捉,局部纹理细节易丢失,以及小目标易被忽略的问题,设计并引入 MCB 模块。

首先通过两个并行 1×1 卷积层与一个 MCB-DRB 模块执行特征处理

$$\begin{aligned} F_1 &= \text{Conv}_{1 \times 1}^{(1)}(X) \\ F_2 &= \text{MCB-DRB}(X) \end{aligned} \quad (1)$$

式中,MCB-DRB(X)表示多尺度膨胀残差块,输入 X 先经普通卷积与激活

$$U = \sigma(\text{Conv}_{3 \times 3}(X)) \quad (2)$$

随后再通过一个 1×1 卷积层整合输出结果。其中 MCB-DRB 模块输入特征图经过 3×3 卷积和 ReLU 激活后,分成 3 个分支

$$B_1 = \text{Conv}_{3 \times 3}(U) \quad (3)$$

$$B_2 = \text{DilatedConv}_{3 \times 3, d=r_1}(U) \quad (4)$$

$$B_3 = \text{DilatedConv}_{3 \times 3, d=r_2}(U) \quad (5)$$

式中: d 表示膨胀率; r_1 、 r_2 为不同的膨胀参数,最后进行融合输出,其中 Y 为最终输出特征图。

$$Y = \text{Conv}_{1 \times 1}^{(2)}(F_1 \oplus F_2) \quad (6)$$

该设计通过多尺度感受野与残差融合,可同步捕捉细长裂纹、曲线划痕的全局轮廓特征,留存漆面剥落与凹陷的局部纹理细节,并强化缺失螺栓等小目标显著性,进而显著提升复杂背景下不同类型缺陷的识别与定位精度。多层次卷积块可从多尺度提取图像特征,使模型可同步捕捉细微与全局缺陷信息,这对检测细小裂纹、较大黑点等不同尺寸及形态的缺陷至关重要。膨胀重参数化模块(Dilated re-param block)采用膨胀卷积与重参数化技术,通过多并行路径提取,并融合不同膨胀率特征,经 1×1 卷积层整合以提升特征表达能力。多尺度特征提取增强了对不同形态、不同尺寸缺陷的捕捉能力,高效特征融合提升了复杂缺陷模式的辨识性能,膨胀卷积扩大感受野,增强了微小缺陷识别鲁棒性。多层次卷积块提取的特征具有更高层次性与表达能力,可更全面反映蒙皮缺陷表面的复杂结构与纹理,助力模型更好地理解、区分不同类型缺陷(图 2)。

1.2 多尺度特征增强框架

针对飞机蒙皮缺陷形态与尺度差异显著的问题,对于细长裂纹、划痕需捕捉跨尺度连续边缘特征;凹陷、漆面剥落需保留局部纹理细节;缺失螺栓需突出小目标显著性。设计了一种多尺度特征增强框架,对不同层次的特征图(即网络中各层次提取到的不同尺度的特征表示)进行分层处理与融合,强化特征表达能力。首先通过 C2f 模块细化输入特征图,经卷积层(Conv, $k=3$, $s=2$)完成下采样,再通过维度感知选择性

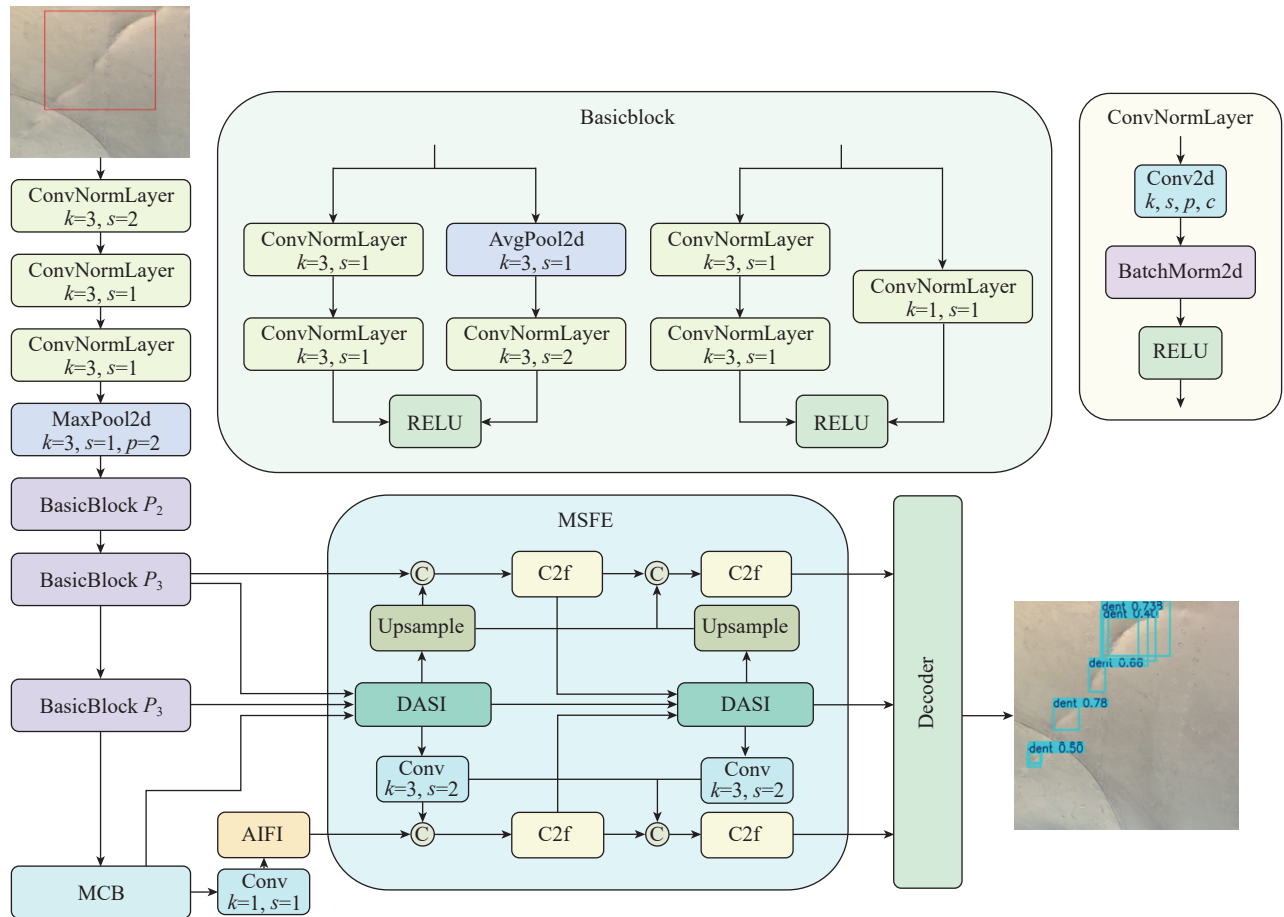


图1 网络结构示意图

Fig.1 Schematic diagram of network structure




图2 MCB结构示意图

Fig.2 Schematic diagram of MCB structure

集成模块 (Dimension-aware selective integration module, DASI) 整合、增强多尺度特征; 随后经上采样层恢复特征图分辨率, 再通过 C2f 模块优化细节。该流程确保多尺度特征充分建模与融合, 使网络同步捕捉大尺度结构与细微缺陷特征, 进而提升蒙皮缺陷精细检测的精度。其中, DASI 通过多种卷积操作、双线性插值处理输入特征图, 采用分组卷积降低计算复杂度 (图 3)。特征图经加权求和、拼接等步骤融合多层次信息, 最终通过逐点卷积与批归一化生成综合后的特征表示。DASI 模块具备多尺度特征融合、维度感知选择、计算效率提升及特征增强等核心优势。

1.3 损失函数

边界框回归损失是缺陷检测网络定位分支的核心模块, 在蒙皮缺陷

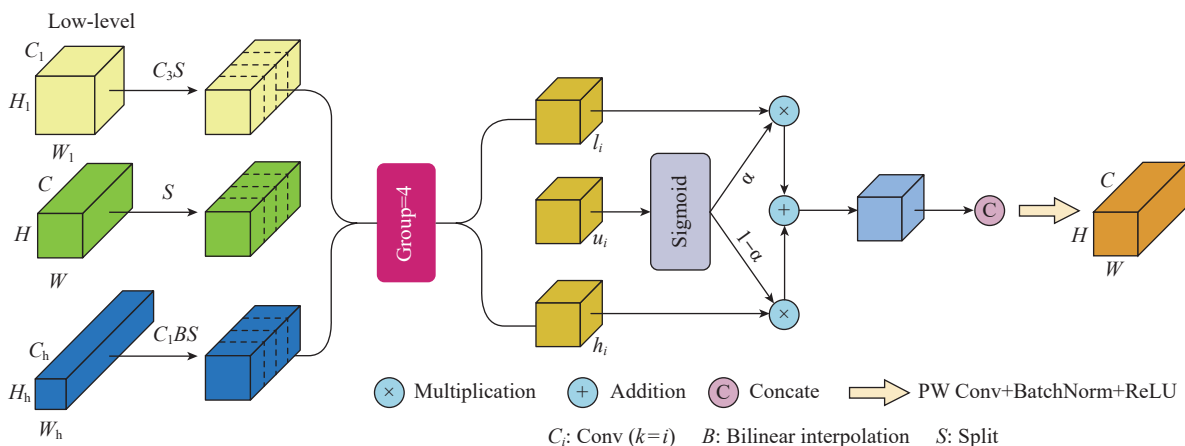


图3 DASI结构示意图

Fig.3 Schematic diagram of DASI structure

检测任务中亦起到关键作用^[22]。现有主流边界框回归方法多聚焦于预测框与真实框的几何关联,一般依托二者相对位置和尺寸来构建损失函数。但这类方法忽略了边界框自身形状特征与尺度因子对回归精度的影响,在处理结构复杂、缺陷形态多变的蒙皮表面时,极易产生定位偏差。对此,本文引入一种新的 Shape IoU (Shape intersection over Union) 损失函数,该方法通过度量预测框与 GT 框的形状匹配度,融入形状一致性与尺度约束,从而更精准地引导边界框回归过程。Shape IoU 为改进型边界框回归损失函数,其在传统 IoU 基础上增加了边界框形状与尺度的结构约束^[23],可有效提升目标边界的拟合精度。传统 IoU 通常定义为预测框 B_p 与真实框 B_g 的交并比

$$\text{IoU}(B_p, B_g) = \frac{|B_p \cap B_g|}{|B_p \cup B_g|} \quad (7)$$

然而,该度量仅反映重叠区域的几何关系,无法区分两个边界框是否具有相似的形状或尺度。因此,Shape IoU 在上述基础上进一步引入形状一致性因子 S_{shape} 和尺度相似性因子 S_{scale} ,定义如下:

$$\text{Shape IoU}(B_p, B_g) = \text{IoU}(B_p, B_g) \cdot S_{\text{shape}}(B_p, B_g) \cdot S_{\text{scale}}(B_p, B_g) \quad (8)$$

其中,形状一致性因子定义为预测框

与真实框宽高比的相似度

$$S_{\text{shape}}(B_p, B_g) = \exp \left[-\lambda_1 \cdot \left| \log \left(\frac{W_p / h_p}{W_g / h_g} \right) \right| \right] \quad (9)$$

尺度相似性因子则度量两者面积比例的接近程度

$$S_{\text{scale}}(B_p, B_g) = \exp \left[-\lambda_2 \cdot \left| \log \left(\frac{w_p h_p}{w_g h_g} \right) \right| \right] \quad (10)$$

式中, (w_p, h_p) 、 (w_g, h_g) 分别代表预测框与真实框的宽和高, λ_1 和 λ_2 为控制形状与尺度敏感度的超参数。

通过显式建模形状与尺度信息,Shape IoU 在保持 IoU 鲁棒性的同时,可引导模型学习更准确的边界框几何属性,进而在蒙皮缺陷检测等需要精细定位的任务中实现更优检测性能。大量试验验证,该方法在蒙皮缺陷检测任务中定位性能更优,不仅提升了整体检测精度,还在多个主流检测基线上实现了性能超越(图4)。

2 模型训练与性能评估

2.1 试验环境与数据集

本研究选取了飞机蒙皮缺陷检测数据集 (Aircraft) 作为试验对象,涵盖了飞机蒙皮常见的 5 种缺陷类型(图5): 裂纹 (Crack) (500 张图像)、凹陷 (Dent) (450 张图像)、缺失

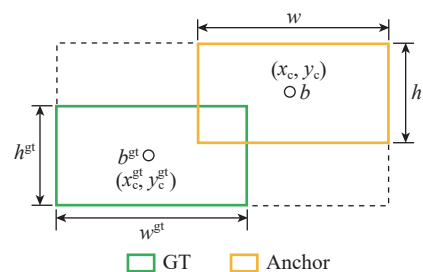


图4 预测框与真实框的空间几何关系
Fig.4 Spatial geometric relationship between predicted box and ground truth box

螺栓 (Missing-head) (400 张图像)、漆面剥落 (Paint-peel-off) (550 张图像) 以及划痕 (Scratch) (400 张图像)。这些缺陷的尺寸范围从大约 1 mm (如细小裂纹和划痕) 到 10 mm (如凹陷和漆面剥落) 不等,具体尺寸因缺陷类型及实际情况而异。在物体检测领域,一般将小目标定义为小于 32×32 像素的物体;中目标为 32×32 到 96×96 像素;大目标为大于 96×96 像素。本文中所涉及的缺陷大多属于小目标和中目标范畴。数据集中的图像均经过人工标注,提供了精确的缺陷位置和边界框信息,可用于目标检测与分类任务。为了增强模型的泛化能力,原图像数据集经过数据增强处理,包括随机旋转、亮度调整、添加传感器噪声以及应用棱镜模糊等方法,最终生成了 2300 张图像。为保证模型训练与评估的公平性与

可靠性,数据集按照 8 : 1 : 1 的比例划分为训练集、验证集和测试集,其中训练集用于模型参数的学习,验证集用于参数调整与过拟合监控,测试集用于最终性能评估。

本文采用 RT-DETR 作为基准框架,检验所提出检测网络的有效性。试验环境和训练策略见表 1。

2.2 评价指标

评价目标中检测模型性能指标包括精确度 (Precision)、召回率 (Recall)、平均精确度 (mAP) 等^[24]。这些指标综合衡量模型在检测目标时的准确性、覆盖率及其整体表现,通过比较模型预测与真实目标的重叠程度和检测准确性,全面反映模型的优劣。精确度指所有被模型检测到的目标中,真正目标的比例。其中,TP (True positive) 代表模型正确预测为正类的样本,即实际为正类并被预测为正类的数量,表示真正检测到的目标;FP (False positive) 代表模型错误地预测为正类的样本,即实际为负类,但被预测为正类的数量,表示错误检测的目标。计算公式为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (11)$$

召回率指所有实际存在的目标中,被模型正确检测到的比例。其中, FN (False negative) 代表模型错误地预测为负类的样本,即实际为正类,但被预测为负类的数量,表示未被检测到的目标。计算公式为

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (12)$$

平均精确度是指在不同阈值下,精确度与召回率曲线下的面积 (Average precision, AP) 的平均值。mAP 指多个类别下的平均精度。对于每个类别计算其平均精度,然后对所有类别的 AP 求平均值。mAP 是一种衡量模型整体性能的指标,综合考虑了模型对各类目标的精确度和召回率。

计算公式为

$$\text{mAP} = \frac{\sum_{j=1}^N \text{AP}(j)}{N} \quad (13)$$

2.3 消融试验

为评估不同模块对模型性能的影响并确定最优组合,本研究设计并进行了多组消融试验。由表 2 可见,各模块在独立加入模型时,均带来了不同程度的性能提升。

以 RT-DETR 为基准模型,逐步引

入不同模块以观察性能变化趋势。结果显示,加入 MCB 模块时, mAP@0.5 提升 11.6%; 将 MSFE 模块独立集成至基准模型, mAP@0.5 提升 1.2%。当 MCB 与 MSFE 同时应用时, mAP@0.5 的增益进一步提升 12%。在此基础上,引入 Shape IoU 模块后, mAP@0.5 最终提高 12.7%。整体趋势表明,各模块均能带来正向性能增益,且组合应用可实现累积提升。

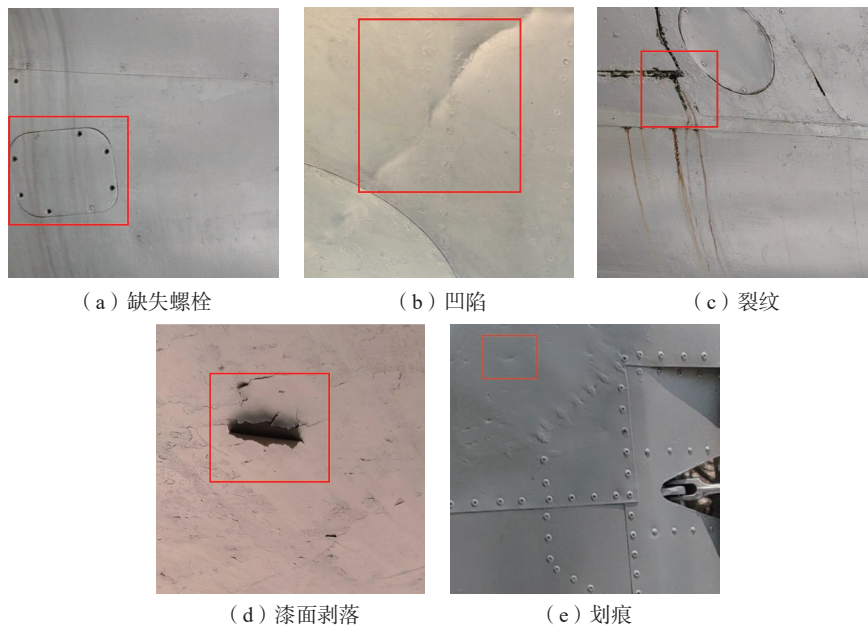


图 5 蒙皮缺陷类型图

Fig.5 Types of skin defects

表 1 硬件/软件环境和训练策略

Table 1 Hardware/software environment and training strategy

| 环境和策略 | 内容 |
|-------|--|
| 硬件 | CPU 为 Intel Xeon Platinum 8255C 2.50 GHz |
| 软件 | 内存 30 GB |
| | 图形处理器 RTX 2080Ti |
| | 操作系统 Linux |
| | 运算平台 CUDA 11.8 |
| 训练策略 | Python 版本 3.8 |
| | PyTorch 版本 2.0.0 |
| | 优化器 SGD |
| | 批量大小 32 |
| | 学习率 0.0001 |
| | 衰减率 0.05 |

2.4 对比试验

在 Aircraft 数据集上对模型进行评估,从试验结果(表 3)可以看出,不同检测模型在 Aircraft 数据集上的检测性能和计算复杂度存在明显差异。两阶段检测器 Faster R-CNN 在 mAP@0.5 指标上仅取得 54.2%, mAP@0.5:0.95 为 23.7%,推理效率较低。YOLOv7 在 mAP@0.5 指标表现优异,但参数量和计算开销较大。YOLOv8 与 YOLOv11 在保持较低计算量的同时,也取得了较高的检测精度,其中 YOLOv8 的 mAP@0.5 达到 79.5%, mAP@0.5:0.95 为 41.3%。相比之下,本文提出的模型在计算量和参数量均处于中等水平的情况下, mAP@0.5 达到 94.8%, mAP@0.5:0.95 达到 68.1%,在保证较高检测精度的同时降低了计算开销,体现出较优的性能与效率平衡。

该结果表明, Faster R-CNN 在蒙皮表面缺陷检测应用场景中适用性有限。在模型性能优化层面, YOLO 系列模型整体可实现检测速度与精度的良好平衡,但本研究提出的模型在精度、计算效率、模型大小之间达到最优折中,在 Aircraft 数据集中,本模型的 mAP@0.5:0.95 值达到 68.1%,较原 RT-DETR 提升了 14.5%。这一检测精度超过了参考对比模型,检测结果展示在图 6 中。本研究开发的模型在蒙皮表面缺陷检测方面展示了卓越的鲁棒性。

2.5 验证试验

为验证蒙皮缺陷检测算法的准确性与鲁棒性,本文引入 NEU-DET 表面缺陷数据集(试验 http://faculty.neu.edu.cn/songkechen/zh_CN/zdylm/263270/list/)开展验证试验。该数据集包含 1800 张分辨率为 200×200 的灰度图像,覆盖 6 类典型缺陷:压入氧化皮(RS)、块状缺陷(Pa)、龟裂(Cr)、点蚀(PS)、夹杂物(In)与划痕(Sc),并按照 8:1:1 划分为训练集、验证集与测

表 2 不同模块在 Aircraft 数据集上的消融研究结果

Table 2 Ablation study results from different modules on the Aircraft dataset

| MCB | MSFE | Shape IoU | 模型检测速度 FPS/(f/s) | 模型检测精度 mAP@0.5:0.95/% | 模型检测精度 mAP@0.5/% |
|-----|---------|-----------|---------------------|--------------------------|---------------------|
| | RT-DETR | | 62.1 | 53.6 | 82.1 |
| ✓ | | | 68.5 | 65.4 | 93.7 |
| | ✓ | | 63.2 | 54.5 | 83.3 |
| | | ✓ | 60.0 | 55.1 | 84.2 |
| ✓ | ✓ | | 55.1 | 67.3 | 94.1 |
| | ✓ | ✓ | 61.5 | 58.6 | 85.5 |
| ✓ | | ✓ | 66.7 | 57.7 | 87.6 |
| ✓ | ✓ | ✓ | 63.5 | 68.1 | 94.8 |

表 3 不同模型在 Aircraft 数据集上的检测结果

Table 3 Detection results from different models on the Aircraft dataset

| 模型 | 浮点运算次数 GFLOPs/G | 模型参数量/M | 模型检测精度 mAP@0.5/% | 模型检测精度 mAP@0.5:0.95/% |
|--------------|--------------------|---------|---------------------|--------------------------|
| Faster R-CNN | 180 | 42.1 | 54.2 | 23.7 |
| SSD | 31.4 | 23.2 | 36.5 | 17.5 |
| YOLOv5 | 60 | 7.2 | 72.1 | 35.4 |
| YOLOv7 | 104.7 | 34.7 | 78.2 | 37.2 |
| YOLOv8 | 8.7 | 3.6 | 79.5 | 41.3 |
| YOLOv9 | 76.8 | 2.0 | 81.4 | 44.5 |
| YOLOv11 | 21.5 | 9.4 | 86.8 | 47.2 |
| RT-DETR | 90 | 44 | 82.1 | 53.6 |
| Ours | 31.3 | 41.2 | 94.8 | 68.1 |




图 6 Aircraft 数据集检测标记结果

Fig.6 Aircraft dataset detection results

试集。试验选取 Faster R-CNN、SSD、YOLOv3、YOLOv3-tiny、YOLOv5s、YOLOv7、YOLOv8 与 YOLOv11 作为对比模型,统一训练与推理设置,并在 NEU-DET 测试集上进行评估,结果见表 4。试验结果显示,本模型的检测精度 $mAP@0.5$ 为 92.5%,相对 YOLOv11 提升 14.9%;与参数量接近的 YOLOv5s 相比, $mAP@0.5$ 与 $mAP@0.5:0.95$ 分别提升 19% 和 17.4%;即便对比参数近 8 倍的 YOLOv3,精度仍有显著提高。上述结果表明,本研究所提方法不仅在飞机蒙皮缺陷场景中兼具更优的精度与稳定性,在 NEU-DET 等表面缺陷数据集上亦展现出良好的鲁棒性与跨域泛化能力。

3 结论

针对飞机蒙皮缺陷多尺度、形态多变及分布复杂的检测难题,本文提出一种融合多级卷积块、多尺度特征增强与形状感知优化的新型深度学习检测网络。该方法基于多尺度特征提取与自适应融合来提升特征表达能力。其中,MCB 模块强化了不同层级特征的判别性;MSFE 模块借助多尺寸深度卷积核构建上下文信息以增强多尺度鲁棒性;Shape-IoU 模块通过引入形状匹配约束,有

效提升了边界框与缺陷轮廓的一致性。在 Aircraft 数据集上的试验显示,模型 $mAP@0.5$ 达 94.8%,较原 RT-DETR 提升 12.7%;在 NEU-DET 测试集的验证中,其 $mAP@0.5$ 指标为 92.5%。试验结果证实,该网络在飞机蒙皮缺陷检测的准确性上优于对比模型。未来工作将聚焦于模型轻量化与实时性优化,以进一步拓展其在全机表面巡检,以及在复合材料结构检测的应用潜力,助力智能检测技术的工程化落地与产业级应用。

参考文献

- [1] PILA J, KOZUBA J, MARTINEC F. Aircraft skin corrosion and structural safety considerations[J]. De Securitate et Defensione, 2021, 7(2): 149–163.
- [2] PUTHILLATH P, ROSE J L. Ultrasonic guided wave inspection of a titanium repair patch bonded to an aluminum aircraft skin[J]. International Journal of Adhesion and Adhesives, 2010, 30(7): 566–573.
- [3] SÉGUIN-CHARBONNEAU L, WALTER J, THÉROUX L D, et al. Automated defect detection for ultrasonic inspection of CFRP aircraft components[J]. NDT & E International, 2021, 122: 102478.
- [4] PELLETIER E, GRENIER M, CHAHBAZA, et al. Array eddy current for fatigue crack detection of aircraft skin structures[C]. 5th International Workshop, Advances in Signal Processing for Non Destructive Evaluation of

Materials. Québec, 2005.

- [5] ELSHAFIEY I. Modeling of magneto-optic eddy current inspection of hidden flaws in aircraft skin[C]. The Sixteenth National Radio Science Conference. NRSC'99. Cairo, 1999.
- [6] FARMAKI S, EXARCHOS D A, TRAGAZIKIS I K, et al. A novel infrared thermography sensing approach for rapid, quantitative assessment of damage in aircraft composites[J]. Sensors, 2020, 20(15): 4113.
- [7] CIAMPA F, MAHMOODI P, PINTO F, et al. Recent advances in active infrared thermography for non-destructive testing of aerospace components[J]. Sensors, 2018, 18(2): 609.
- [8] WANG Y, HU S G, XIONG T, et al. Recent progress in aircraft smart skin for structural health monitoring[J]. Structural Health Monitoring, 2022, 21(5): 2453–2480.
- [9] ZHAO J, HUANG K J, WANG G J, et al. Biological visual attention convolutional neural network for aircraft skin defect detection[J]. Measurement: Sensors, 2024, 31: 100974.
- [10] WU J, ZHANG Y J, SHAN T F, et al. An additive feature fusion attention based on YOLO network for aircraft skin damage detection[J]. The Journal of Supercomputing, 2025, 81(4): 627.
- [11] SUVITTAWAT N, KURNIAWAN C, DATEPHANYAWAT J, et al. Advances in aircraft skin defect detection using computer vision: A survey and comparison of YOLOv9 and RT-DETR performance[J]. Aerospace, 2025, 12(4): 356.
- [12] DING M, WU B E, XU J, et al. Visual inspection of aircraft skin: Automated pixel-level defect detection by instance segmentation[J]. Chinese Journal of Aeronautics, 2022, 35(10): 254–264.
- [13] BHATIA V, ARORA R, SIDHARTH S. Deep learning for automated aircraft surface defect detection[C]. 2024 International Conference on Intelligent Computing and Emerging Communication Technologies (ICEC). Guntur, 2025.
- [14] WU B E, DING Y Y, DING M, et al. Aircraft skin damage detection method based on improved mask scoring R-CNN[C]. 6th International Conference on Information Science, Computer Technology and Transportation. Xishuangbanna, 2021.
- [15] LI H P, WANG C Q, LIU Y. YOLO-FDD: Efficient defect detection network of aircraft skin fastener[J]. Signal, Image and Video Processing, 2024, 18(4): 3197–3211.
- [16] BOHNER M, GUSEINOV G S.

表 4 不同模型在 NEU-DET 数据集上的检测结果

Table 4 Results of detection on the NEU-DET dataset with different models

| 模型 | 模型检测精度 $mAP@0.5/\%$ | 模型检测精度 $mAP@0.5:0.95/\%$ | 模型参数量/M | 模型检测速度 FPS/(f/s) |
|--------------|------------------------|-----------------------------|---------|---------------------|
| Faster R-CNN | 64.5 | 31.2 | 41.42 | 48 |
| SSD | 71.1 | 37.5 | 25.13 | 72 |
| YOLOv3 | 73.7 | 41.6 | 61.54 | 83 |
| YOLOv3-tiny | 55.8 | 23.7 | 8.77 | 260 |
| YOLOv5s | 73.5 | 40.9 | 7.12 | 130 |
| YOLOv7 | 74.0 | 39.8 | 36.5 | 86 |
| YOLOv8 | 76.2 | 42.8 | 11.2 | 122 |
| YOLOv11 | 77.6 | 44.1 | 9.6 | 126 |
| Ours | 92.5 | 58.3 | 7.16 | 75 |

The convolution on time scales[J]. *Abstract and Applied Analysis*, 2007(1): 058373.

[17] MURRAY N, PERRONNIN F. Generalized max pooling[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, 2014.

[18] YANG Y, NIE Z P, HUANG S Y, et al. Multilevel features convolutional neural network for multifocus image fusion[J]. *IEEE Transactions on Computational Imaging*, 2019, 5(2): 262–273.

[19] SHANG R H, ZHANG J Y, JIAO L C, et al. Multi-scale adaptive feature fusion network

for semantic segmentation in remote sensing images[J]. *Remote Sensing*, 2020, 12(5): 872.

[20] BOLLES R C, CAIN R A. Recognising and locating partially visible objects: The local-feature-focus method[M]//*Robot Vision*. Berlin: Springer, 1983.

[21] ZHANG H, ZHANG S J. Shape-IoU: More accurate metric considering bounding box shape and scale[EB/OL]. (2023–11–01)[2025–11–10]. <https://arxiv.org/abs/2312.17663>.

[22] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for

bounding box regression[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 12993–13000.

[23] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. *Neurocomputing*, 2022, 506: 146–157.

[24] PADILLA R, NETTO S L, DA SILVA E A B. A survey on performance metrics for object-detection algorithms[C]. 2020 International Conference on Systems, Signals and Image Processing (IWSSIP). Niteroi, 2020.

Skin Defect Detection Method Based on Multilevel Convolution and Shape Enhancement

WANG Jue¹, LU Zhenyu^{2,3}, ZHANG Xiaowei¹, SUN Yuwen^{2,3}, ZHU Li¹

(1. Shenyang Aircraft Corporation, Shenyang 110850, China;

2. School of Mechanical Engineering, Dalian University of Technology, Dalian 116024, China;

3. State Key Laboratory of High-Performance Precision Manufacturing, Dalian University of Technology, Dalian 116024, China)

[ABSTRACT] To address the impact of surface defects in aircraft skin—critical structural components—on overall structural performance, this paper proposes a deep learning detection network based on the RT-DETR model, aiming to enhance the accuracy and robustness of aircraft skin defect detection. In response to the challenges posed by defects of varying scales, morphologies, and complex distributions, a series of innovative techniques were adopted for optimization. First, in the feature extraction stage, multilevel convolution blocks (MCB) were introduced. Through multi-layer convolution operations, the discriminative power of features at different scales was strengthened, effectively capturing details at various levels. Second, in the feature fusion stage, a multiscale feature enhancement (MSFE) module was employed, using multi-size depthwise convolution kernels to build contextual information, thereby improving the network’s robustness and adaptability to multi-scale defect features. Finally, in the regression stage, a shape-aware (Shape-IoU) optimization module was introduced, which optimizes the matching between bounding boxes and defect contours, significantly improving detection accuracy. Experimental results show that the proposed network achieved an mAP@0.5 of 94.8% on the Aircraft dataset, representing a 12.7% improvement over the original RT-DETR model. Furthermore, on the NEU-DET test set, the model attained an mAP@0.5 of 92.5%. These results validate the effectiveness of the model in improving both the precision and generalization capability of aircraft skin defect detection.

Keywords: Skin defect detection; Multilevel convolutional blocks (MCB); Multiscale feature enhancement (MSFE); Object detection; Loss function

(责编 大漠)