

DOI: 10.13382/j.jemi.B2508677

# 基于 GCSS-YOLOv8 的涂层表面微小缺陷检测\*

贾琦<sup>1</sup> 王国磊<sup>2</sup> 路敦民<sup>1</sup>

(1. 北京林业大学工学院 北京 100083; 2. 清华大学机械工程系 北京 100084)

**摘要:** 涂层表面微小缺陷的自动检测在制造业质量控制中具有重要意义。针对大尺寸飞机壁板表面涂层质量检测的关键需求,提出一种基于机器视觉的多尺度缺陷协同检测方法,重点解决毫米级麻点、鱼眼、气泡与厘米级划痕、流挂等跨尺度缺陷的同步识别难题。首先系统分析了现有检测方法在多尺度缺陷同步识别,以及实时性和高精度之间平衡方面的不足,并在此基础上展开研究。完成的核心内容包括构建了多光源协同图像采集平台,建立覆盖5类典型缺陷的涂层图像数据集;设计了一种融合非线性光照校正与多尺度增强的复合图像预处理方法,有效解决了由局部反光及明暗突变引起的亮度梯度异常问题;提出了改进的 GCSS-YOLOv8 深度学习模型,以提升对不同尺度缺陷的检测性能。实验结果表明,所提出方法在自建数据集上的平均检测精度(mAP@0.5)达到91.4%,较原始 YOLOv8 模型提升1.9%,验证了其有效性与实用价值。

**关键词:** 涂层表面质量检测;多尺度缺陷;图像预处理;GCSS-YOLOv8

**中图分类号:** TP391.4; TN98 **文献标识码:** A **国家标准学科分类代码:** 510.4050

## GCSS-YOLOv8-based tiny defect detection on coating surfaces

Jia Qi<sup>1</sup> Wang Guolei<sup>2</sup> Lu Dunmin<sup>1</sup>

(1. School of Technology, Beijing Forestry University, Beijing 100083, China;

2. Department of Mechanical Engineering, Tsinghua University, Beijing 100084, China)

**Abstract:** Automatic detection of tiny defects on coating surfaces holds significant importance in manufacturing quality control. Addressing the critical need for quality inspection of coating surfaces on large-scale aircraft panels, this paper proposes a machine vision-based multi-scale defect collaborative detection method, focusing on solving the challenge of synchronously identifying cross-scale defects including millimeter-scale pits, fisheyes, and bubbles as well as centimeter-scale scratches and sags. This paper first systematically analyzed the shortcomings of existing detection methods in terms of synchronous recognition of multi-scale defects and balancing real-time performance with high precision, and conducted research accordingly. The core contributions completed include: constructed a multi-light source collaborative image acquisition platform and established a coating image dataset covering five typical defect types; designed a composite image preprocessing method that integrates nonlinear illumination correction and multi-scale enhancement, effectively addressing brightness gradient anomalies caused by local reflections and sudden brightness changes; and proposed an improved GCSS-YOLOv8 deep learning model to enhance detection performance for defects of different scales. Experimental results show that the proposed method achieves a mean Average Precision (mAP@0.5) of 91.4% on the self-built dataset, which is 1.9% higher than the original YOLOv8 model, verifying its effectiveness and practical value.

**Keywords:** coating surface quality inspection; multi-scale defects; image preprocessing; GCSS-YOLOv8

## 0 引言

喷涂是现代工业生产制造过程中的重要环节,广泛应用于船舶、汽车和航空航天等领域中<sup>[1]</sup>。由于受到车间环境、涂料配比、工艺方法、操作不当等多种因素的影响,喷涂过程中和喷涂结束后工件涂层表面会产生麻点、鱼眼、气泡、流挂、划痕、龟裂等各种缺陷<sup>[2]</sup>。导致工件的外观、质量、性能等受到影响。因此,快速、高效、精准地检测并区分缺陷种类,然后采取相应的修复与补救措施,对保证基底材料功能、延长工件的使用寿命、提高产品性能具有重要意义<sup>[3-4]</sup>。

涂层表面微小缺陷如果采用人工检测,不仅效率低下、劳动强度高,而且易受环境干扰和主观性限制,难以满足高精度和实时性需求<sup>[3-6]</sup>。随着计算机视觉和深度学习技术的发展,涂装缺陷的自动化检测技术在工业生产中逐步替代传统的人工检测方式<sup>[4]</sup>。

目前主流的缺陷识别方法主要有传统视觉检测方法和深度学习技术<sup>[7]</sup>。传统视觉检测是通过图像处理算法实现缺陷位置的识别,例如,广泛应用于国外众多车企的自动化车身涂装缺陷检测系统<sup>[8]</sup>。Moradi 等<sup>[9]</sup>针对涂层缺陷中的气泡缺陷进行视觉检测,使用了两个自适应阈值处理和分水岭算法进行特征提取。Baygin 等<sup>[10]</sup>提出了一种用于检测印刷电路板孔洞是否缺失的算法,采用 Otsu 阈值法与 Hough 变换对参考和检测图像进行特征提取,对提取出的特征进行精准匹配,进而判断孔洞是否缺失。田鑫亮<sup>[11]</sup>针对航空制造业涂装表面质量控制难题,构建了基于传统机器视觉的缺陷检测系统,采用高斯带阻滤波与纹理滤波融合算法消除碳纤维编织纹理干扰,通过主成分分析降维与 K 近邻分类器实现五类典型缺陷的智能识别。骆亚微<sup>[12]</sup>针对汽车车身漆膜的起泡、流挂和划痕等缺陷问题,提出了基于形态学的图像增强方法,并对基于图论的传统图像分割算法进行了改进。由于传统的图像处理方法需要手动设计合适的特征提取器,无法适用于工业复杂环境。而且由于单一的图像处理技术分割复杂、泛化能力弱,目前已不再将其单独作为检测方法。随着以卷积神经网络为代表的深度学习模型在计算机视觉领域的成功应用,深度学习技术逐渐被应用于基于机器视觉的缺陷检测中<sup>[13-14]</sup>。

聂晋峰等<sup>[15]</sup>设计了一种基于快速区域卷积神经网络(faster regions with convolutional neural network, Faster-RCNN)的海上升压站涂层缺陷智能检测算法,在骨干网络中引入形变卷积,增强网络对形状多变缺陷特征的提取能力,并提出了一种多尺度空洞卷积的特征融合策略。谢凌望等<sup>[16]</sup>提出了一种基于 ResNet 和 DenseNet 模型的铝罐表面涂层缺陷检测方法。赵辉等<sup>[3]</sup>提出了一种检测

网络 YOLOv4-tiny-SR,大幅降低了特征使用量,提升了特征利用率,针对小目标检测问题以及涂层表面缺陷的特点,分别提出了几何平均聚类 and 包围盒聚焦损失函数两种优化策略。

除了涂层表面缺陷检测,机器学习方法在工件或材料的外观缺陷检测方面也有广泛应用。马志程等<sup>[17]</sup>将深度学习算法应用到光学元件缺陷检测,并根据划痕缺陷的特点,对 Mask R-CNN 网络模型进行了改进。刘琼等<sup>[18]</sup>提出了一种基于改进 YOLOv5 的缺陷检测方法,对裂纹、腐蚀、划痕和撞击等 4 类缺陷进行检测。汤占军等<sup>[19]</sup>利用引入注意力机制的 CNN 提取风机叶片图像特征,将使用主成分分析(principal component analysis, PCA)方法降维后的局部二值模式(local binary pattern, LBP)特征融合 CNN 提取的特征作为特征矢量。全卫国等<sup>[20]</sup>以 Faster-RCNN 为基础模型,提出了融合多尺度特征与注意力机制的风机桨叶缺陷检测方法。Liu 等<sup>[21]</sup>提出了一种基于领域适应的时序方法用于印刷电路板(printed circuit board, PCB)缺陷检测,通过集成 YOLOv5 和 Res2Net 模块,确保在模糊或遮挡条件下的鲁棒性,保证实时性的同时大幅提升 PCB 缺陷检测的准确率。

由于涂层缺陷尺寸较小、形态复杂且易与背景混淆,同时毫米级麻点、鱼眼、气泡与厘米级划痕、流挂等多尺度缺陷的需要同步识别,现有方法仍然面临挑战,特别是在实时性和高精度之间的平衡上仍有待研究。鉴于现有模型的局限性,本文对 YOLOv8 进行改进,提出了 GCSS-YOLOv8 模型,实现对飞机壁板表面涂层缺陷的较高精度和速度的检测,增强模型对多尺度小目标缺陷的检测精度。

## 1 缺陷图像的采集及预处理

### 1.1 缺陷种类及数据集的制备

飞机壁板涂层表面可能出现多种微小缺陷,如鱼眼、麻点、气泡、流挂、划痕等<sup>[22]</sup>,如图 1 所示。




图 1 各类缺陷

Fig. 1 Various types of defects

这些涂层缺陷在工业生产中较为常见,因特征多样、形态复杂、尺寸细小且分布随机,给自动化检测带来了挑战。

由于目前针对涂层表面缺陷检测的研究较少,没有可以直接使用的数据集,为了满足涂层缺陷检测模型的训练需求,本文构建了涂层表面微小缺陷数据集。结合人工制备和真实采集两种方式(真实采集数据较少),建立涵盖多种缺陷类型的样本库,并进行系统化的数据标注与预处理。

人工制备典型涂层缺陷,采用飞机壁板相同材料的小尺寸试件,使用相同的喷涂设备和漆料,具体方法如下:

1) 流挂缺陷,通过调整喷涂工艺参数(喷涂压力、流速、喷枪移动速度等),在试件表面形成不同程度的流挂缺陷,并控制缺陷的形态和分布,以增强模型的泛化能力。

2) 划痕缺陷,利用刻刀、砂纸等工具,在涂层表面制造不同深度和宽度的划痕,并喷涂透明保护漆模拟复杂表面划痕。

3) 麻点缺陷,在涂层未完全固化前,通过控制环境湿度、气流扰动等因素,使涂层表面形成微小颗粒状突起,以模拟实际生产中常见的麻点缺陷。

4) 鱼眼缺陷,通过在涂层中混入微量不相容物质,使漆面产生局部收缩,形成鱼眼缺陷。

5) 气泡缺陷,在调漆过程中人为增大油漆稀释剂比例,或者在涂层未固化前通过加热或施加溶剂诱导气泡的产生,模拟喷涂工艺不稳定造成的气泡缺陷。

制备过程中,按照工业标准控制缺陷的形态、尺寸和分布,以保证数据的稳定性和可重复性。

1.2 图像采集设备

缺陷采集通常依赖于高分辨率的工业相机和精密的光源系统,以确保采集到的图像能够清晰展现缺陷的细节。光源的布置对缺陷采集至关重要,常用的光源类型包括环形光、斜射光、漫射光等,能够有效增强不同缺陷的对比度,使其在图像中更易于被识别。此外,为了提升检测系统的适应性,还使用多角度、多光谱或多模态采集方法,以获取更加全面的缺陷信息。在数据采集过程中,还需要保证数据的多样性和均衡性,确保采集到的缺陷类型、大小、形状和位置有足够的覆盖范围,以避免模型训练过程中出现偏差。

本研究采用的图像采集设备包括工件放置平台、照明光源、工业相机、相机镜头、升降装置、计算机等,如图 2 所示。工件放置平台提供稳定支撑,并保证其在拍摄过程中的稳定性和精确位置。照明光源用于提高目标亮度、优化光照条件、突出缺陷细节、减少阴影和反射,因此选用可以突出缺陷的四面条形光源,4 根光源分别可调

整亮度和角度,便于突出不同缺陷信息。工业相机是设备的核心部件,具有高分辨率和高灵敏度,能够捕捉到微小缺陷。相机镜头根据不同需求调整焦距和视角,以便获取所需的缺陷图像细节。升降装置可调节相机与工件之间的距离,确保不同尺寸和角度的缺陷都能清晰拍摄。计算机作为设备的控制中心,负责图像存储、数据处理以及与其他硬件设备的协同工作<sup>[4]</sup>。设备的主要硬件配置如表 1 所示。




图 2 图像采集设备  
Fig. 2 Image acquisition equipment

表 1 设备配置  
Table 1 Equipment Configuration

| 名称    | 配置                                   |
|-------|--------------------------------------|
| 工业相机  | MV-CS200-10GM                        |
| 相机分辨率 | 5472×3648                            |
| 工业镜头  | MVL-KF1624M-25MP                     |
| 焦距    | 16 mm                                |
| 放置平台  | 600 mm×700 mm                        |
| 工作光源  | 4×400 mm 四面条形光源                      |
| 计算机   | Geforce RTX 3080Ti<br>Core i9-12900H |

采集时,将人工制备的缺陷样本板依次放置在图像采集平台上,调整拍摄角度,以获得多角度、多光照条件下的缺陷数据。采集过程中,详细记录采集时的关键参数(如拍摄角度、拍摄高度(相对于样本)、光源亮度等),例如在采集流挂缺陷时所记录的不同拍摄环境参数如表 2 所示。

表 2 流挂缺陷拍摄环境参数  
Table 2 Sagging Defect Imaging Environment Parameters

| 拍摄环境 | 光源入射角度/(°) | 光源高度/cm | 四条光源亮度/(cd·m <sup>-2</sup> ) | 相机高度/cm | 相机焦距/mm |
|------|------------|---------|------------------------------|---------|---------|
| 1    | 90         | 24.45   | (0,700,80,0)                 | 46.32   | 7.8     |
| 2    | 90         | 21.85   | (150,500,150,150)            | 43.72   | 6.6     |
| 3    | 75         | 24.45   | (0,700,80,0)                 | 46.32   | 7.8     |

1.3 图像预处理

喷涂件原始图像在四面条形光源多角度照射下,虽

有效改善了整体光照均匀性,但受限于工业现场环境,仍需应对以下挑战:多光源叠加区域的局部高光效应、曲面工件表面反射率差异导致的明暗过渡不连续,机械振动导致的运动模糊,以及环境粉尘附着引发的随机噪声干扰。

因此,针对工业图像中由局部反光及明暗突变引起的亮度梯度异常问题,提出一种融合非线性光照校正与多尺度增强的复合图像预处理方法。如图 3 所示,算法流程包含 3 个核心模块:首先通过 Gamma-Log 双域变换构建自适应亮度校正模型,随后采用高斯混合滤波实现噪声鲁棒性增强,最后结合局部锐化与全局直方图重构提升缺陷区域的可辨识度。




图 3 复合图像预处理方法

Fig. 3 Composite image preprocessing method

针对鱼眼、麻点、气泡、流挂和划痕这 5 种缺陷图像,经本方法处理后,缺陷特征优化效果如图 4 所示。处理前,鱼眼缺陷受噪声干扰,灰度区分度不足;麻点缺陷因背景与缺陷灰度差异小,部分细节被掩盖;气泡缺陷轮廓模糊,边缘界定不清;流挂和划痕缺陷受光照不均影响,纹理特征表现欠佳。处理后,鱼眼缺陷轮廓锐利,灰度对比度提升,圆环特征突出;麻点缺陷细节清晰展现,微小麻点明确凸显;气泡缺陷轮廓边界清晰,内外区域灰度差异增强,实现精准界定;流挂和划痕缺陷经光照均衡处理,纹理特征更连贯鲜明,缺陷形态完整呈现。

亮度校正、噪声去除以及区域重构的图像预处理流程,不仅显著提升了缺陷区域的可见度,也为后续深度学习模型提供了高质量的输入图像,保障了缺陷检测的鲁棒性与精度。

最终形成的缺陷样本采集结果以及剔除掉异常样本后的信息如表 3 所示。




图 4 缺陷预处理结果

Fig. 4 Defect preprocessing results

表 3 缺陷样本信息

Table 3 Defect sample information

| 组别 | 缺陷名称 | 标签      | 样本数量   | 剔除异常样本后的样本数量 |
|----|------|---------|--------|--------------|
| 1  | 鱼眼   | eye     | 10 961 | 8 750        |
| 2  | 气泡   | bubble  | 10 301 | 6 400        |
| 3  | 麻点   | point   | 13 737 | 9 800        |
| 4  | 划痕   | scratch | 10 502 | 8 500        |
| 5  | 流挂   | sagging | 11 118 | 9 500        |

2 缺陷检测算法

2.1 YOLOv8 网络模型

YOLOv8 是近年来在目标检测领域取得显著进展的深度学习模型,基于卷积神经网络结构,旨在通过端到端的训练实现实时、高效的目标检测<sup>[23]</sup>。相较于 YOLO 系列的前几个版本,YOLOv8 采用了 C2f 模块,这一改进增强了特征提取能力,提升了对复杂场景中中小目标和细微特征的识别能力。在检测头部分,YOLOv8 使用了 anchor-free 策略,并且网络的检测和分类的卷积是解耦的,这使得模型在处理多尺度和密集目标时更加灵活。在损失函数部分,YOLOv8 结合了分类二值交叉

熵(binary cross-entropy, BCE)损失、回归完全交并比(complete intersection over union, CIoU)损失和新增的Varifocal损失,从而提高了目标定位和分类的精度。这些创新使得YOLOv8在精度、速度和鲁棒性上相比YOLO系列前期版本有了显著提升,尤其在实时检测和高精度需求的应用中表现出色。

## 2.2 GCSS-YOLOv8 网络模型

为了提升微小缺陷的检测性能,本文对YOLOv8进行改进,提出了GCSS-YOLOv8模型,用于更加快速精确的检测涂层表面微小缺陷。GCSS-YOLOv8模型首先在主干网络中加入了无参数注意力机制模块(simple attention module, SimAM),为卷积神经网络提供三维注意力权重,有效增强了模型对微小缺陷的关注能力。其次,对原有的C2f模块进行了改进,设计了融合全局上下文信息的G-C2f模块。该设计能够提升全局信息建模能力,优化特征重加权过程,在不显著增加网络复杂度的情况下,增强特征表达,提升模型对微小缺陷的检测精度。最后,将YOLOv8的损失函数替换为Shape\_IoU函数,以优化边界框回归,减少漏检和误检现象。综合来看,这些改进可使改进后的YOLOv8在微小涂层缺陷的检测中具有更高的精度和稳定性,网络结构如图5所示。




图5 GCSS-YOLOv8 网络结构

Fig. 5 GCSS-YOLOv8 structural framework

为进一步直观验证改进模型对缺陷区域的关注性能,本文引入模型可视化对比实验,以热力图形式呈现不同模型在典型缺陷样本上的关注区域差异。以下以两类典型缺陷(流挂/划痕、麻点)为例展开分析。两个模型的特征关注效果对比如图6所示,图6中上方样本为流

挂/划痕缺陷,下方样本为麻点缺陷(麻点以红框标注)。图6(a)为样本原图,图6(b)为YOLOv8原模型的热力图,图6(c)为本文改进模型的热力图。相较于YOLOv8模型,本文模型的热力图在目标区域激活层面表现更优:针对如流挂/划痕这类细长目标,能够清晰定位目标位置并凸显轮廓;针对麻点类微小目标,在目标与背景区分上展现显著优势,热力图中目标区域呈现强烈且集中的激活响应,背景无效激活被大幅抑制,可清晰界定微小麻点目标与背景的边界。




图6 模型特征关注效果对比

Fig. 6 Comparison of model feature attention effects

### 1) SimAM 注意力机制

SimAM是一种无参数、基于神经元重要性的注意力机制,其核心逻辑为通过特征自身的统计信息计算神经元重要性得分,实现特征的自适应加权,无需额外学习参数。对于特征图中位置 $i$ 处的神经元激活值 $x_i$ ,其重要性得分 $S_i$ 的计算公式为:

$$S_i = \frac{1}{N-1} \sum_{j=1, j \neq i}^N (x_i - x_j)^2 \quad (1)$$

式中: $N$ 代表当前特征图参与计算的神经元总数。

由于得分越低的神经元与周围神经元的差异越小,信息重要性越高,因此对得分取倒数,并与原激活值加权得到输出 $y_i$ 。

$$y_i = x_i \cdot \frac{1}{S_i + \delta} \quad (2)$$

式中: $\delta$ 为极小常数。最终输出特征图 $Y$ 由所有位置的 $y_i$ 组成。

SimAM具有计算效率高、易于集成等优势,广泛适用于各种深度学习模型,特别是在高效视觉任务中表现出色<sup>[24]</sup>,图7所示为SimAM工作流程。

### 2) G-C2f 模块

C2f模块是YOLOv8中的关键模块之一,主要作用是实现分阶段的高效特征融合与轻量化设计。然而,在涂层微小缺陷检测任务中,由于缺陷通常尺寸微小且全局信息分布不均,C2f模块的局部感知能力可能不足以捕捉全局上下文关系,导致对复杂背景中的小缺陷表现出较




图7 SimAM 工作流程

Fig. 7 SimAM work flow

低的鲁棒性。为解决这一问题,本文将 Global Context 模块嵌入 C2f 模块,设计了 G-C2f 模块,通过全局池化生成全局上下文向量,将全局信息融入局部特征中,增强了模型对缺陷区域的整体感知能力,该结构如图 8 所示。




图8 G-C2f 模块

Fig. 8 G-C2f module

Global Context 模块是一种特征增强模块,通过在局部特征的基础上引入全局上下文信息,增强模型对空间关系和背景信息的理解,从而提高模型在复杂场景下的鲁棒性和准确性,该模块的工作原理如图 9 所示<sup>[25]</sup>。




图9 全局上下文模块

Fig. 9 Global context module

首先,上下文建模模块采用  $1 \times 1$  卷积  $W_k$  和 Softmax 函数获取注意力权重,然后进行注意力池化以获得全局上下文特征 ( $C \times 1 \times 1$ )。全局上下文特征先通过  $1 \times 1$  卷

积  $W_v$  及非线性激活  $\delta$ ,再通过  $1 \times 1$  卷积  $W_u$ ,输出再和输入特征图  $X$  融合,输出包含全局感知能力的特征图  $Y$  ( $C \times H \times W$ )。该过程以轻量计算整合局部与全局信息,增强特征的全局关联性。

$Y$  的计算公式为:

$$Y = X + (W_u \cdot \delta(W_v \cdot (\text{Softmax}(W_k \cdot x) \cdot X))) \quad (3)$$

GC 模块通过全局池化捕捉特征图的全局语义信息,并将其与局部特征相结合,能够显著增强模型对缺陷区域的定位和识别能力。这种全局与局部信息的融合,特别适用于检测那些在复杂背景中对比度低的小缺陷,从而在降低误检率的同时提升了检测精度。此外,GC 模块对背景噪声具有较强的抑制作用,能够更加突出关键区域的特征表达,为精确识别微小缺陷提供了有力保障。与此同时,GC 模块计算复杂度较低,与 C2f 模块的多尺度特征提取机制形成高效互补,既不会显著增加模型的计算负担,又能够满足工业环境中对实时性和效率的高要求。

这种改进能够在保持模型轻量化的同时,有效避免传统模型中局部信息不足或背景干扰导致的误检问题,显著提升对复杂缺陷区域的检测能力,为小尺度缺陷检测任务提供了一种精细化且高效的解决方案。

### 3) Shape\_IoU 损失函数

Shape-IoU 损失函数是一种针对目标检测任务中边界框回归优化的损失函数,旨在克服传统 IoU 损失函数在处理形态复杂或不规则目标时的局限性<sup>[26]</sup>。Shape-IoU 的计算过程是通过综合考虑预测框和真实框的形状和位置差异进行的。首先,根据预测框和真实框的宽高比例定义权重系数,并结合两者的中心点偏移计算距离项  $distance^{shape}$ ,从而量化位置误差。然后,基于宽和高的差异,计算相对权重  $w_w$  和  $w_h$ ,进一步衡量宽高的匹配程度。最后,通过指数衰减函数累加上述误差,得到形状匹配度指标  $\Omega^{shape}$ 。这一方法显式地将形状特征融入 IoU 计算,能够更准确地评估复杂目标的检测性能,计算公式如式(4)。

$$Loss = 1 - IoU + distance^{shape} + 0.5 \times \Omega^{shape} \quad (4)$$

本文将 YOLOv8 中使用的传统损失函数替换为 Shape-IoU 损失函数,通过引入形状匹配,能够有效提升模型在涂层缺陷检测、工业视觉检测等应用中的精度和鲁棒性,尤其在复杂背景下的小目标检测中,表现出更高的定位精度和检测稳定性。

## 3 测试与验证

### 3.1 实验环境与参数设置

在本研究的深度学习实验设计中,关键训练参数经

系统性调优:将图像输入尺寸规范为 640×640 pixels,批量大小设定为 16,训练迭代设定为 300 次,优化参数方面,学习率采用 0.01 初始值,损失函数动量设为 0.99,权重衰减配置为 0.000 01。此外,实验融入数据增强策略,以 0.5 的概率执行随机水平翻转、垂直翻转操作,同时结合随机裁剪与颜色抖动技术,从几何变换和色彩偏移维度丰富图像样本特征,扩大训练数据多样性,使模型学习更具鲁棒性的特征表达,进一步强化泛化性能。实验环境的配置如表 4 所示。

表 4 实验环境配置

| Table 4 Experimental environment configuration |                                      |
|------------------------------------------------|--------------------------------------|
| 配置环境                                           | 配置名称(版本)                             |
| 操作系统                                           | Windows 10                           |
| CPU                                            | 12th Gen Intel(R) Core(TM) i9-12900H |
| GPU                                            | NVIDIA Geforce RTX 3080Ti            |
| 深度学习框架                                         | Pytorch 1.12.0                       |
| 加速模块                                           | CUDA11.7+cu113                       |

3.2 评价指标

网络模型的评价使用了 4 个指标,包括精确率(P)、召回率(R)、平均精度(AP)以及平均精度均值(mAP),这些参数验证了网络的学习效果。各指标的计算公式如下:

$$R = \frac{TP}{TP + FN} \tag{5}$$

$$P = \frac{TP}{TP + FP} \tag{6}$$

$$AP = \int_0^1 P(r) dr \tag{7}$$

$$mAP = \frac{1}{c} \sum_{i=1}^c AP_i \tag{8}$$

式中:TP 表示将正样本识别为正样本;FN 表示将正样本识别为负样本;FP 表示将负样本识别为正样本;AP 是根据不同的置信度阈值计算出来的 PR 曲线下的面积,表示了检测算法在不同置信度阈值下的性能表现;mAP 是对每个类别的 AP 进行平均得到的结果<sup>[27]</sup>。

3.3 消融实验

为验证各改进模块对模型性能提升的有效性,在自建数据集上开展了系统性的消融实验,实验结果如表 5 所示。所有实验均以 YOLOv8 基础模型为基准,围绕 SimAM 注意力机制、G-C2f 全局上下文模块以及 Shape-IoU 损失函数 3 种改进策略进行组合设计,共构建 8 组对比实验。其中,模型 1 为未引入任何改进模块的基准模型;模型 2~4 分别引入 SimAM、G-C2f 和 Shape-IoU 单一模块,用以分析各模块的独立作用;模型 5~7 分别组合 2 种改进模块,用于评估不同模块间的协同效果;模型 8 为完整改进模型,同时引入 SimAM、G-C2f 及 Shape-IoU,以验证本文提出方法的整体有效性。

为全面衡量模型检测性能,实验采用 P、R、mAP@0.5 以及 mAP@0.5:0.95 作为评价指标,从检测精度、目标召回能力及定位精度等多个维度对各改进模块的性能贡献进行定量分析。

以未引入任何改进模块的基准模型为参照,引入 SimAM 模块的模型 2 在 R 与 mAP 指标上均取得提升,表明 SimAM 通过增强关键区域特征响应,有效改善了模型对弱小缺陷目标的感知能力。仅引入 G-C2f 模块的模型 3 在 P 指标上表现更优,说明全局上下文建模有助于抑制误检,但对目标召回能力的提升相对有限。模型 4 采用 Shape-IoU 损失函数后,在 mAP@0.5 及 mAP@0.5:0.95 上均有所提升,验证了改进回归损失函数对检测框定位精度的积极作用。

在双模块组合实验中,模型 5 在 P 与 R 上实现同步提升,说明局部注意力增强与全局特征建模具有良好的互补性;模型 6 在保持较高召回率的同时进一步提升了综合定位精度;模型 7 则在 P 与 mAP 指标上取得稳定提升,表明上下文特征建模与回归策略优化之间同样具备协同增益。最后,完整改进模型(模型 8)在 P、R 以及 mAP@0.5 和 mAP@0.5:0.95 指标上均达到最优,充分验证了本文所提出多模块联合优化策略在特征提取与目标定位全流程中的综合优势。

表 5 消融实验

| Table 5 Ablation experiment |       |       |           |      |      |           |                |
|-----------------------------|-------|-------|-----------|------|------|-----------|----------------|
| 编号                          | SimAM | G-C2f | Shape-IoU | P/%  | R/%  | mAP@0.5/% | mAP@0.5:0.95/% |
| 1                           |       |       |           | 87.2 | 86.1 | 89.5      | 54.7           |
| 2                           | √     |       |           | 87.5 | 87.2 | 90.0      | 55.1           |
| 3                           |       | √     |           | 88.3 | 85.8 | 89.8      | 55.0           |
| 4                           |       |       | √         | 86.8 | 85.6 | 90.2      | 54.9           |
| 5                           | √     | √     |           | 88.9 | 87.4 | 90.6      | 56.0           |
| 6                           | √     |       | √         | 88.2 | 87.6 | 90.8      | 55.7           |
| 7                           |       | √     | √         | 88.6 | 86.2 | 90.4      | 55.5           |
| 8                           | √     | √     | √         | 90.2 | 89.8 | 91.4      | 56.5           |

## 4 结 论

本文以大尺寸飞机壁板部件的麻点、鱼眼、气泡、划痕及流挂 5 类多尺度缺陷自动检测为背景,针对现有方法在微小缺陷漏检、复杂形态误判及多尺度检测矛盾等痛点,提出全局-局部特征协同增强的 GCSS-YOLOv8 检测框架,并通过多组消融实验验证了模块设计的合理性与有效性。从消融实验结果可以看出,各改进模块对模型性能的影响具有一定差异性。单一模块引入时,模型性能均呈现不同程度的优化趋势;仅加入 SimAM 模块时,模型在召回率与 mAP 指标上实现稳定提升,说明注意力机制有助于增强关键缺陷区域的特征响应;仅引入 G-C2f 模块时,精确率表现更为突出,而召回率存在小幅波动,表明全局上下文建模在抑制误检方面具有积极作用;单独采用 Shape-IoU 损失函数时, mAP @ 0.5 及 mAP@0.5:0.95 指标均有所提升,验证了改进回归策略对目标定位精度的促进效果。相比之下,多模块协同组合能够进一步发挥各模块的互补优势,其中 SimAM 与 G-C2f 的联合显著提升了特征表达的完整性,使得  $P$ 、 $R$  及 mAP 指标同步增长。最终,集成 SimAM、G-C2f 与 Shape-IoU 的 GCSS-YOLOv8 模型在 mAP @ 0.5 和 mAP@0.5:0.95 上均取得最优性能,相较基准模型有效降低了微小缺陷的漏检率与复杂形态目标的误判率,体现出在多尺度缺陷检测任务中更优的检测精度与鲁棒性。

未来研究将聚焦模型轻量化设计,推动其在嵌入式设备上的高效部署,适配真实飞机壁板的现场检测场景;同时计划引入自监督学习技术,降低对大规模标注缺陷数据的依赖,进一步提升方法的工程实用性。

## 参考文献

- [1] 张博文,任寿伟,王健,等. 航空领域自动喷涂技术的应用现状与前景[J]. 科技和产业, 2025, 25(2): 64-71.  
ZHANG B W, REN SH W, WANG J, et al. Application status and prospects of automatic spraying technology in the aviation field[J]. Science Technology and Industry, 2025, 25(2): 64-71.
- [2] 吴文娇. 汽车涂装漆膜缺陷分析[J]. 现代涂料与涂装, 2024, 27(1): 60-63.  
WU W J. Defect analysis of automobile painting surface[J]. Modern Paint & Finishing, 2024, 27(1): 60-63.
- [3] 赵辉,侯旭涛,宋龙,等. 基于 YOLOv4-tiny-SR 的涂层表面缺陷嵌入式检测方法[J]. 计算机工程与应用, 2025, 61(8): 239-249.  
ZHAO H, HOU X T, SONG L, et al. Embedded detection

- method of coating surface defects based on YOLOv4-tiny-SR[J]. Computer Engineering and Applications, 2025, 61(8): 239-249.
- [4] JIA Q, LU D, TIAN X, et al. Deep learning-based detection of coating sagging defects [C]. The 17th International Conference on Intelligent Robotics and Applications, 2024.
- [5] 叶益,汉继程,赵起锋,等. 视觉识别在涂层缺陷检测研究与应用进展[J]. 涂层与防护, 2025, 46(6): 18-25.  
YE Y, HAN J CH, ZHAO Q F, et al. Progress in visual recognition for coating defect detection[J]. Coating and Protection, 2025, 46(6): 18-25.
- [6] 赵朗月,吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022, 43(1): 198-219.  
ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision[J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 198-219.
- [7] 李丹,王慢慢,刘俊德,等. 基于轻量级卷积神经网络的带钢表面缺陷识别[J]. 仪器仪表学报, 2022, 43(3): 240-248.  
LI D, WANG M M, LIU J D, et al. Steel surface defect recognition based on a light weight convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 240-248.
- [8] MUÑOZ A, MAHIQUES X, SOLANES J E, et al. Mixed reality-based user interface for quality control inspection of car body surfaces [J]. Journal of Manufacturing Systems, 2019, 53: 75-92.
- [9] MORADI N, KANDI S G, YAHYAEI H. A new approach for detecting and grading blistering defect of coatings using a machine vision system [J]. Measurement, 2022, 203: 111954.
- [10] BAYGIN M, KARAKOSE M, SARIMADEN A, et al. Machine vision based defect detection approach using image processing [C]. 2017 International Artificial Intelligence and Data Processing Symposium. Malatya, Turkey, 2017.
- [11] 田鑫亮. 基于机器视觉的涂装表面缺陷检测系统研究[D]. 北京: 北京林业大学, 2022.  
TIAN X L. Research on coating surface defect detection system based on machine vision [D]. Beijing: Beijing Forestry University, 2022.
- [12] 骆亚微. 基于图像处理的车身漆膜缺陷识别与分类研究[D]. 长春: 吉林大学, 2016.  
LUO Y W. Recognition and classification of coating film defects on autobody based on image processing [D]. Changchun: Jilin University, 2016.

- [13] 王亦君,蒋首超. 基于计算机视觉的钢构件防腐涂层缺陷检测[J]. 建筑钢结构进展, 2023, 25(12): 85-93, 101.  
WANG Y J, JIANG SH CH. Defect Identification of anticorrosive coating of steel members based on computer vision[J]. Progress in Steel Building Structures, 2023, 25(12): 85-93, 101.
- [14] 陈儒森,吉小超,张梦清,等. 机器学习在激光熔覆涂层缺陷检测中的研究现状与进展[J]. 中国表面工程, 2024, 37(5): 112-137.  
CHEN R S, JI X CH, ZHANG M Q, et al. Progress and research status in machine learning for defect detection in laser cladding coatings[J]. China Surface Engineering, 2024, 37(5): 112-137.
- [15] 聂晋峰,金绪良,殷爱鸣,等. 基于改进 Faster-RCNN 的海上升压站涂层缺陷检测与评估[J]. 无线电工程, 2023, 53(11): 2673-2680.  
NIE J F, JIN X L, YIN A M, et al. Detection and evaluation of coating defects in offshore booster stations based on improved Faster-RCNN[J]. Radio Engineering, 2023, 53(11): 2673-2680.
- [16] 谢凌望,陈满,彭宇瑞,等. 基于 ResNet 和 DenseNet 模型的铝罐表面涂层缺陷检测方法[J]. 汕头大学学报(自然科学版), 2024, 39(4): 40-48.  
XIE L W, CHEN M, PENG Y R, et al. A surface coating defect detection method for aluminum cans based on ResNet and DenseNet models[J]. Journal of Shantou University (Natural Science), 2024, 39(4): 40-48.
- [17] 马志程,李丹,张宝龙. 基于改进 Mask R-CNN 的光学元件划痕缺陷检测研究[J]. 电子测量与仪器学报, 2023, 37(4): 231-239.  
MA ZH CH, LI D, ZHANG B L. Research on scratch defect detection of optical elements based on improved Mask R-CNN[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4): 231-239.
- [18] 刘琼,史诺. 基于改进 YOLOv5 的飞机蒙皮表面缺陷检测方法[J]. 国外电子测量技术, 2023, 42(12): 1-7.  
LIU Q, SHI N. Aircraftskinsurface defect detection based onimproved YOLOv5 [J]. Foreign Electronic Measurement Technology, 2023, 42(12): 1-7.
- [19] 汤占军,孙栋钦,李英娜,等. 基于特征融合的风机叶片表面缺陷检测模型[J]. 电子测量技术, 2022, 45(11): 161-166.  
TANG ZH J, SUN D Q, LI Y N, et al. Defect detection model of wind turbine blade based on feature fusion[J]. Electronic Measurement Technology, 2022, 45(11): 161-166.
- [20] 全卫国,仪小龙,李冰,等. 融合多尺度特征与注意力机制的风机桨叶缺陷检测方法[J]. 电子测量技术, 2022, 45(24): 166-172.  
TONG W G, YI X L, LI B, et al. Wind turbine paddle defect detection method incorporating multi-scale features and attention Mechanism [J]. Electronic Measurement Technology, 2022, 45(24): 166-172.
- [21] LIU B, CHEN D, QI X. YOLO-pdd: A novel multi-scale PCB defect detection method using deep representations with sequential images[C]. International Conference on Neural Information Processing. Singapore: Springer Nature Singapore, 2024: 297-313.
- [22] 张伟杰,唐晓旭,肖凯巍,等. 基于计算机视觉的钢结构涂层缺陷检测综述[J]. 工程质量, 2024, 42(S2): 128-131.  
ZHANG W J, TANG X X, XIAO K W, et al. Overview of application of computer vision based steel structure coating defect detection[J]. Construction Quality, 2024, 42(S2): 128-131.
- [23] 罗维平,张哲. 基于改进 YOLOv8 的织物疵点检测算法[J]. 黄河科技学院学报, 2025, 27(2): 23-30.  
LUO W P, ZHANG ZH. Fabric defect detection algorithm based on improved YOLOv8[J]. Journal of Huanghe S&T College, 2025, 27(2): 23-30.
- [24] YANG L, ZHANG R Y, LI L, et al. Simam: A simple, parameter-free attention module for convolutional neural networks [C]. The 38th International Conference on Machine Learning, 2021.
- [25] CAO Y, XU J, LIN S, et al. Gcnet: Non-local networks meet squeeze-excitation networks and beyond [C]. The 15th Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019.
- [26] ZHANG H, ZHANG S. Shape-iou: More accurate metric considering bounding box shape and scale [J]. ArXiv preprint arXiv:2312.17663, 2023.
- [27] 邢永峰. 结合注意力机制和非对称编解码器的图像语义分割方法研究[D]. 武汉: 武汉理工大学, 2023.  
XING Y F. Research on image semantic segmentation with the combination of attention mechanism and asymmetric encoder-decoder [D]. Wuhan: Wuhan University of Technology, 2023.

## 作者简介



贾琦, 2025 年于北京林业大学获得硕士学位, 主要研究方向为机器人技术、机器视觉识别与定位和工业软件开发等。

E-mail: 13691094191@163.com

Jia Qi received her M. Sc. degree from Beijing Forestry University in 2025. Her main research interests include robotics, machine vision recognition and positioning, and industrial software development.



**王国磊**, 2010 年于哈尔滨工业大学获得博士学位, 现为清华大学副研究员, 主要研究方向为机器人技术、机器人及智能化装备设计研制、复杂制造系统与制造过程的建模、规划与控制。

E-mail: wangguolei@tsinghua.edu.cn

**Wang Guolei** received his Ph. D. degree from Harbin Institute of Technology in 2010. Now he is an associate researcher in Tsinghua University. His main research interests include robotics, design and development of robotic and intelligent equipment, as well as modeling, planning and control of complex manufacturing systems and processes.



**路敦民** (通信作者), 2005 年于哈尔滨工程大学获得博士学位, 现为北京林业大学副教授, 主要研究方向为机器人技术、先进设计与智能制造技术、机器视觉与图像处理技术。

E-mail: dunminlu@163.com

**Lu Dunmin** (Corresponding author) received his Ph. D. degree from Harbin Engineering University in 2005. Now he is an associate professor in Beijing Forestry University. His main research interests include robotics, advanced design and intelligent manufacturing technology, as well as machine vision and image processing.