

基于双模态数据样本和改进YOLOv8的车漆缺陷检测研究

王一 杜艺波 程佳 苏皓

Research on automotive paint defect detection based on bimodal data samples and enhanced YOLOv8 method

WANG Yi, DU Yibo, CHENG Jia, SU Hao

引用本文:

王一, 杜艺波, 程佳, 等. 基于双模态数据样本和改进YOLOv8的车漆缺陷检测研究[J]. 应用光学, 2025, 46(6): 1418–1428. DOI: 10.5768/JAO202546.0602003

WANG Yi, DU Yibo, CHENG Jia, et al. Research on automotive paint defect detection based on bimodal data samples and enhanced YOLOv8 method[J]. Journal of Applied Optics, 2025, 46(6): 1418–1428. DOI: 10.5768/JAO202546.0602003

在线阅读 View online: <https://doi.org/10.5768/JAO202546.0602003>

您可能感兴趣的其他文章

Articles you may be interested in

基于规范化样本拆分的轴承缺陷检测

Bearing defects detection based on standardized sample split

应用光学. 2021, 42(2): 327–333 <https://doi.org/10.5768/JAO202142.0203006>

基于改进YOLOv5s的曲面光学镜片缺陷检测

Defect detection of curved optical lenses based on improved YOLOv5s

应用光学. 2024, 45(4): 781–789 <https://doi.org/10.5768/JAO202445.0403003>

改进YOLOv7的光学镜片灰尘与点状缺陷检测

Improved YOLOv7 for dust and point defects detection of optical lens

应用光学. 2025, 46(4): 868–876 <https://doi.org/10.5768/JAO202546.0403007>

基于优化残差网络的复杂纹理表面缺陷检测

Defect detection on complex texture surface based on optimized ResNet

应用光学. 2023, 44(1): 104–112 <https://doi.org/10.5768/JAO202344.0102006>

基于改进YOLO-V4的贴片二极管表面缺陷检测

Surface defect detection of patch diode based on improved YOLO-V4

应用光学. 2023, 44(3): 621–627 <https://doi.org/10.5768/JAO202344.0303007>

基于轮廓标记的球膜焊缝缺陷偏振检测方法

Polarization detection method of spherical film weld defects based on contour marking

应用光学. 2025, 46(4): 842–851 <https://doi.org/10.5768/JAO202546.0403004>



关注微信公众号，获得更多资讯信息

文章编号: 1002-2082 (2025) 06-1418-11

引用格式: 王一, 杜艺波, 程佳, 等. 基于双模态数据样本和改进 YOLOv8 的车漆缺陷检测研究 [J]. 应用光学, 2025, 46(6): 1418-1428.

WANG Yi, DU Yibo, CHENG Jia, et al. Research on automotive paint defect detection based on bimodal data samples and enhanced YOLOv8 method[J]. Journal of Applied Optics, 2025, 46(6): 1418-1428.



在线阅读

基于双模态数据样本和改进 YOLOv8 的车漆缺陷检测研究

王一^{1,2}, 杜艺波¹, 程佳¹, 苏皓^{1,2}

(1. 华北理工大学电气工程学院, 河北唐山 063210; 2. 唐山市先进测试与控制技术重点实验室, 河北唐山 063210)

摘要: 在汽车面漆缺陷检测时, 针对面漆表面因镜面反射导致缺陷特征信息丢失的问题, 利用相位测量偏折术制作双模态数据样本, 增强缺陷特征和降低背景复杂度, 以关注前景缺陷的位置。同时针对人工检测方法效率低和传统检测方法准确率低等问题, 对 YOLOv8 进行了改进: 在主干网络中引入自校正卷积和 ADown 下采样模块, 使获取的信息流丰富且有效; 用感受野注意力卷积替代原颈部的普通卷积, 可关注重要的特征; 舍去颈部原有上采样融入 DySample 模块, 在空间尺度变换时减少特征的丢失。实验结果表明: 所提方法在凹坑、碰伤和划痕等 3 种车漆缺陷检测中性能优越, 相比于 YOLOv8n 基线法, mAP50 和 mAP50-90 同时提升了 1.9%; 此外, 在东北大学 NEU-DET 和 PASCAL VOC 2012 公共数据集上, 验证了改进 YOLOv8 方法在其他不同属性的检测对象中, 同样也具备较强的适用性。

关键词: 相位测量偏折术; 双模态数据样本; YOLOv8; 漆面缺陷检测

中图分类号: TN29; O439

文献标志码: A

DOI: 10.5768/JAO202546.0602003

Research on automotive paint defect detection based on bimodal data samples and enhanced YOLOv8 method

WANG Yi^{1,2}, DU Yibo¹, CHENG Jia¹, SU Hao^{1,2}

(1. School of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China;

2. Tangshan Key Laboratory of Advanced Detection and Control Technology, Tangshan 063210, China)

Abstract: In the domain of automotive paint defect detection, to address the issue of defect feature information loss due to specular reflection on the surface, bimodal data samples were created using phase measurement deflection techniques to enhance defect features and reduce background complexity, focusing on the location of foreground defects. Additionally, to tackle the low efficiency of manual detection methods and the low accuracy of traditional detection methods, improvements were made to YOLOv8. Self-correcting convolutions and an ADown downsampling module were introduced in the backbone network to enrich and enhance the information flow. A receptive field attention convolution replaced the ordinary convolution in the original neck to focus on important features. The original neck's upsampling was replaced with the DySample module to reduce feature loss during spatial scale transformation. Experimental results reveal that the proposed method

收稿日期: 2024-09-02; 修回日期: 2024-11-04

基金项目: 河北省高等学校科学技术研究项目 (融合深度学习的工业机器人视觉测量与引导技术, ZD2022114); 唐山市应用基础研究项目 (工业机器人智能视觉感知与位姿控制关键技术, 21130212C)

第一作者: 王一, E-mail: wangyi@ncst.edu.cn

通信作者: 杜艺波, E-mail: du1525054874@outlook.com

excels in detecting three specific types of automotive paint defects: dents, bumps, and scratches. Compared to the YOLOv8n baseline model, it achieves a 1.9% improvement in both mAP50 and mAP50-90 metrics. Furthermore, the improved YOLOv8 method has been validated on the NEU-DET and PASCAL VOC 2012 public datasets, demonstrating strong applicability for detecting objects with various attributes.

Key words: phase measuring deflectometry; bimodal data sample; YOLOv8; paint defect detection

引言

在现代汽车制造业中,面漆质量直接影响着车辆的外观和市场竞争能力,不仅是保护车身免受腐蚀和环境影响的重要层次,更是消费者在购车时的重要考虑因素之一。随着消费者对汽车外观要求的日益提高,以及制造商能够及时调整生产工艺和后续工序衔接的需求,汽车面漆的缺陷检测变得愈发重要^[1]。面漆缺陷如气泡、划痕、色差等,不仅影响车辆的美观,还可能影响其耐用性和保值率。因此,准确高效的缺陷检测技术成为汽车制造商和质量控制部门的重要研究方向。

在这一背景下,传统的人工检测方法存在效率低、主观性强等问题,难以满足大规模生产的需求。随着机器视觉的发展,通过图像处理技术实时监测面漆的质量,可检测出存有缺陷,利用人工可进行缺陷类型的判别。REMEŠOVÁ M 等人^[2]在图像处理系统中,应用金相分析技术对漆面缺陷进行检测。XU J 等人^[3]针对汽车涂料的特点,提出蚁群算法,设计了一种基于 HSV 色彩空间的干扰消除算法,提高了汽车涂料缺陷的检测准确率,该方法的一个局限性是,如果图像中存在多个缺陷位置,则识别规则可能失效。CHENG P 等人^[4]采用基于形态学的图像增强方法和基于图论的图像分割方法对油漆缺陷进行定位,并采用支持向量机对油漆缺陷进行识别分类。汽车面漆表面具有光泽的表面特性和镜面反射的光学特性,对图像采集和处理都会造成影响,这些干扰因素造成了误检、漏检和检测准确性低等问题。AKHTAR S 等人^[5]开发了一种基于相位偏折术的面漆缺陷检测系统,避免了漆面表面的不利影响,通过处理面漆虚像中形变条纹的相位信息,从而检测出面漆表面的缺陷。

不同类型的缺陷具有不同的特征,如何对所有缺陷的特征全面地进行表征,并接近人工判别缺陷类型的准确程度,成为了表征工程的一大难题。随着深度学习的发展,能够自适应地特征提取,避免了传统机器学习表征困难的问题,如 AdaBoost^[6]、SVM(support vector machine)^[7]和 DPM

(deformable part model)^[8]等机器学习方法。因此,开发更加高效、准确、低成本的检测技术显得尤为重要。深度学习技术中,越来越多的卷积神经网络、特征提取模块、特征融合策略和损失函数被研发出来,以及 ViT(vision transformer)方法,都成为了集成性学习模型的重要组成部分。鉴于其强大的性能,JIANG Z L 等人^[9]将基于深度学习的方法应用在车漆缺陷检测中,并通过实验证明了深度学习具有强大的潜力,值得进一步发展。CHANG F 等人^[10]提出一种具体的深度集成学习算法 Tiny-DefectNet,检测面漆中的微小缺陷,所开发的系统已成功应用于工厂,且提高了检测工作的效率。

One-Stage 和 Two-Stage 方法的出现提高了缺陷检测的性能,其中 One-Stage 为目标检测的主流方法。KARANGWA J 等人^[11]以具有镜面特性的陶瓷马桶为研究对象,提出以 VGG16 为特征提取主干的 Faster R-CNN 的方法,对裂纹、微裂纹、针孔、污垢、凹坑和斑点等 6 种不同类型的表面缺陷进行检测,与传统方法相比准确率达到了 94%。ZHANG J 等人^[12]提出了一种改进的 MobileNet-SSD 算法,能够以 95% 以上的准确率检测出 6 种常规车身涂料缺陷。然而,该方法缺乏用于小目标预测的高级特征映射语义,导致小目标检测精度不足。SONG M 等人^[13]提出了一种将深度学习与相位偏折术相结合的方法,利用 YOLOv5 对多特征复合图像进行检测,该方法的识别率达到 90% 以上。JIANG W 等人^[14]提出了一种半监督式面漆缺陷检测框架,使用标记和未标记的样本有效降低数据标记的成本,并提出 YOLOv7-EA 方法完成汽车面漆缺陷检测的任务。

本文提出了一种深度学习与相位测量偏折术相结合的方法,对汽车面漆凹坑、碰伤、划痕等 3 种缺陷进行实验。提出了一种制作车漆缺陷双模态数据样本的方法,通过改进 YOLOv8 检测方法,在保证不引入过大参数数量和计算复杂度的同时,提高缺陷的定位精度和分类准确度。本文主要贡献分为以下 4 个方面:

1) 通过相位测量偏折术进行车漆表面缺陷信

息获取,并与白色 LED 光源照明下 CCD 所拍摄的原图合成双模态数据样本。该方法降低了背景复杂度,增强了缺陷的特征表示,以少图片多缺陷的想法构建双模态数据样本数据集,提高检测模型的准确性。

2) 针对 YOLOv8 主干网络提取缺陷特征的效率和有效性,引入自校正卷积和 Adown 下采样模块,使检测精度和计算复杂度达到平衡。

3) 将 YOLOv8 颈部的 2 个 CBS 模块替换为感受野注意力卷积模块,该模块对重要信息更加关注,能够充分提取到有效特征信息,以提高检测的精度。

4) 为了在进行空间尺度变换时减少特征信息的丢失,并将重要的信息传入 Head 部分以提高检

测的精度,故在颈部舍去原有的 UpSample 模块并融入 DySample 上采样模块。

1 方法原理

1.1 总体流程

本文所提方法主要分为 4 个阶段,第 1 阶段为利用工业 CCD 相机采集图像;第 2 阶段,采用相位测量偏折技术对图像预处理,主要针对表面存在镜面反射的问题,以避免缺陷特征信息的丢失;第 3 阶段通过改进的 YOLOv8 网络进行预测,利用该方法的目的是提高对缺陷检测的精度和准确度;第 4 阶段输出预测结果。在 4 个阶段的共同作用下,完成对车漆表面缺陷的检测任务,总体流程图如图 1 所示。




图 1 总体流程图

Fig. 1 Overall flow chart

1.2 双模态数据样本

汽车面漆表面具有光泽的表面特性和镜面反射的光学特性,用 CCD 直接采集图像,会导致 CCD 接收不到部分光线或者产生过曝区域,以及面漆表面会产生虚像等问题。这些问题会影响后期的图像处理环节,或者在深度神经网络进行特征提取时会提取到伪特征,造成错检和漏检等问题。因此,利用相位测量偏折术(phase measuring deflectometry, PMD)^[15]在垂直和水平 2 个方向上获取不同的相位信息,进行图像处理得到两张单通道调制图,再经白色 LED 光源照明下 CCD 采集的单通道原图,最后将两张调制图和原图组合为一帧复合三通道图像。由于复合图像利用两种方法获取两种不同模态的数据,故将其称为一个双模态数据样本(bimodal data samples, BDS)。BDS 的构成原理如图 2 所示。从图 2 中可以看出,CCD 拍摄到的不明显缺陷,通过调制度也可以将其明显化,增强了缺陷的特征。

图 3 为 BDS 采集平台,主要由 LED 光源、CCD 相机和被检测对象组成。




图 2 BDS 构成原理图

Fig. 2 Principle of BDS composition




图 3 BDS 采集平台示意图

Fig. 3 BDS collection platform

PMD 主要分为相位提取和相位展开两部分, 通过解算物体表面产生形变条纹的虚像, 获取物体表面信息。相位提取的过程是通过向面漆表面投射正弦条纹, 并由 CCD 接收到面漆表面所成的条纹虚像, 通过相移法^[16]解出包裹相位, 其原理如式(1)~式(3)所示, 其中 N 代表相移的步数, 步数越多误差越小, 因此本文采用十二步相移法。相位展开则应用多频外差法^[17], 其基本原理如式(4)所示。

$$I_k = A(x, y) + B(x, y) \cdot \sin(\varphi(x, y) + \Delta\varphi_k) = A(x, y) +$$

$$B(x, y) \cdot \sin(\varphi(x, y) + \frac{2k\pi}{N}), (k = 0, 1, \dots, N-1) \quad (1)$$

$$B(x, y) = \frac{2}{N} \sqrt{\left[\sum_{k=0}^{N-1} (I_k \sin(\frac{2k\pi}{N})) \right]^2 + \left[\sum_{k=0}^{N-1} (I_k \cos(\frac{2k\pi}{N})) \right]^2} \quad (2)$$

$$\varphi(x) = -\arctan \left[\frac{\sum_{k=0}^{N-1} (I_k \sin(\frac{2k\pi}{N}))}{\sum_{k=0}^{N-1} (I_k \cos(\frac{2k\pi}{N}))} \right] \quad (3)$$

$$\Phi(x, y) = \varphi(x, y) + 2\beta\pi, \quad (\beta = 0, 1, \dots, n) \quad (4)$$

式中: (x, y) 为相机所获取图像的像素坐标; I_k 为相机所获取的 N 步相移中第 k 个图像; $A(x, y)$ 为背景光强; $B(x, y)$ 为调制强度, 发挥去除背景和噪声区域的作用; $\varphi(x, y)$ 为相位主值; $\Delta\varphi_k$ 为相移值; $\Phi(x, y)$ 为展开相位。

图 4 为 PMD 与直接拍摄样本的效果图。通过利用不同的调制强度可将缺陷具体化, 且展开相位相较于直接拍摄样本, 避免了图 4(a) 中虚像和曝光的影响, 更有助于关注前景缺陷, 降低背景复杂度, 提高缺陷检测的准确率。




图 4 PMD 与直接拍摄样本的效果图

Fig. 4 Comparison of PMD and directly captured samples

1.3 改进 YOLOv8 方法的总体框架

YOLO 为单阶段检测模型的主流方法, 通过不断地更新, 使其在目标检测领域极具竞争力。根

据不同的任务需求, 可将其分为 n 、 s 、 l 、 m 、 x 等 5 种类型, 其中 n 以最少的参数量和最快的检测速度被广泛应用。YOLOv8 在骨干网络中延续了 CSP 的设计理念, 引入了 C2f 模块来取代 YOLOv5 的 C3 模块, 旨在实现模型轻量化和优化梯度流。此外, 在骨干网中利用 SPPF 模块, 有效地整合了局部和全局特征。在特征融合阶段, YOLOv8 保留了基于 PANet 和 FPN 的特征融合方法。YOLOv8 还采用了流行的解耦头策略, 将分类头与回归检测头分离。这种增强允许使用变焦损失进行分类损失^[18], 同时使用 CIOU 损失^[19]和 DFL^[20]进行回归损失。

在本研究中, 以参数量少和检测速度快为依据, 选择 YOLOv8n 方法作为改进汽车面漆缺陷检测方法的基线。改进 YOLOv8 方法的总体框架原理图如图 5 所示。

首先, 为了得到更有效的信息流, 特征提取性能的优劣起着决定性的因素。因此, 在特征提取主干中部分 C2f 替换为改进的 SCC2f, 其中原始 BottleNeck 中的第二个普通卷积改进为自校正卷积, 同时为了防止参数量和计算复杂度过度升高, 导致检测模型性能衰减, 引入 ADown 轻量型下采样模块来保持平衡。在颈部将 2 个 CBS 模块改进为感受野注意力卷积, 该卷积会更加关注有用的特征区域, 从而提高缺陷的表征能力。颈部原先的 UpSample 模块, 空间尺度的变换容易导致信息丢失, 后续的信息流产生模糊信息也会导致检测性能下降, 为了改善这些不利因素的影响, 引入了 DySample 上采样模块, 增强缺陷的表征功能。

2 YOLOv8 方法改进

2.1 自校正卷积

自校正卷积 (self-calibrated convolution, SC) 被研发自卷积神经网络 SCNet^[21], 通过 SC 的自校正操作, 自适应构建空间信息相关性, 帮助 CNN 提取到更具有帮助的特征信息。在 YOLOv8 特征提取主干的 6 层和 8 层替换为改进的 SCC2f, 其 SC 模块结构原理图如图 6 所示。

模块内部用了 3 处卷积滤波器, 且都使用了分组卷积, 特征变换过程在多个并行分支中均匀地单独进行, 每个分支的输出被连接起来作为最终输出。假设输入特征 X_i 经过式(5)得到 r 倍平均池化后的特征 T_i , 该特征获取空间小尺度的大目标




图5 改进YOLOv8的总体框架原理图

Fig. 5 Overall framework principle diagram of improved YOLOv8




图6 自校正卷积的结构原理图

Fig. 6 Structure principle diagram of self-calibrated convolution

信息,通过式(6)经双线性插值恢复到原空间尺度,并与原特征相加再激活得到的校正权重 X'_1 。最后由矫正权重与在 X_1 中提取到的特征信息进行点积运算,从而对特征内部重要信息和非重要信息进行校正得到 Y'_1 ,再通过式(8)进一步特征提取,得到该模块的输出 Y_1 。

$$T_1 = \text{AvgPool}_r(X_1) \quad (5)$$

$$X'_1 = \sigma(X_1 + \text{Up}(\text{BN}(\text{Conv2d}(T_1)))) \quad (6)$$

$$Y'_1 = \text{BN}(\text{Conv2d}(X_1)) * X'_1 \quad (7)$$

$$Y_1 = \text{BN}(\text{Conv2d}(Y'_1)) \quad (8)$$

式中: $\text{AvgPool}_r(\cdot)$ 为平均池化操作运算符; $\text{Up}(\cdot)$ 为双线性插值上采样操作运算符; $\text{BN}(\cdot)$ 为归一

化操作运算符; $\text{Conv2d}(\cdot)$ 为卷积操作运算符; $\sigma(\cdot)$ 为Sigmoid激活函数运算符。

2.2 ADown 下采样模块

通过SC的原理可以了解到,与普通卷积相比,SC具有更多的参数和计算复杂度。为了平衡SC造成的影响,在Backbone的3、5、7层引入了轻量型ADown下采样模块^[22]进行调解,其结构原理图如图7所示。由图7可以看出,中间层特征 F_A 经过平均池化后,将其通道数对半分再进入后续的CBS,此操作相当于应用了组卷积操作,大幅度减少了参数量。经Split操作之后,由最大池化操作进行多尺度特征的变换,最后将2个分支的输出Concat在一起。与原普通卷积进行下采样相

比, ADown 模块丰富了特征的信息, 提高了检测模型的性能, 降低了参数量和计算复杂度。




图 7 ADown 模块结构原理图

Fig. 7 Structure principle diagram of ADown module

2.3 感受野注意力卷积

感受野注意力卷积(receptive field attention convolution, RFA)作为一种创新的技术, 不仅仅是一种简单的卷积操作, 更是一种融合了感受野和注意力机制的强大工具, 该模块主要引入在 Neck 部分的 16、19 层。传统卷积感受野的大小, 通常由卷积核的大小和卷积层的堆叠方式决定。然而, 固定大小的感受野可能无法有效地捕捉图像中不同尺度和位置的信息, 这就会导致忽略一些重要的特征, 从而影响性能。RFA 将感受野的概念与注意力机制相结合, 其结构原理图如图 8 所示。




图 8 RFA 模块结构原理图

Fig. 8 Structure principle diagram of RFA module

在卷积过程中, 首先计算每个位置的感受野大小, 然后根据感受野内的特征信息计算注意力权重。这些注意力权重会与卷积核进行加权融合, 从而得到更加具有判别力的特征表示。感受野注意力卷积能够自适应地调整感受野的大小和注意力的分配, 从而更好地捕捉图像中的上下文信息和细微的变化。这使得模型在汽车面漆缺陷检测任务中, 能够取得更好的性能。该模块的详细原理, 可以具体参考 ZHANG X 等人^[23] 的文献。

2.4 DySample 上采样模块

DySample 是一种高效率且轻量级的动态上采样模块, 能够学习上采样去采样, 进行有效的空间

尺度变换。与反卷积上采样操作方法不同, DySample 以像素点采样为基础, 将单个像素分为 4 小部分以采样到更清楚的特征信息^[24], 其模块结构原理图如图 9 所示。为了在上采样时减少大量有效的特征信息丢失, 在 Neck 的 10、13 层引入 DySample 模块。

DySample 以动态上采样为基础, 在采样时分静态范围因子和动态范围因子两种范围因子。不管选择哪种范围因子 s 采样, 都是通过线性层生成偏移量 O , 只是生成偏移量的公式原理不同, 然后通过式 (11) 与原始网格 g 相加生成采样集 S 。若使用静态范围因子, 则以式 (9) 为依据, 反之则以

式 (10) 为依据。生成采样集以后, 通过式 (11) 将输入特征 X 通过网格采样函数, 使用 S 中的位置重新将假设的双线性插值的 X 采样到 X' 中。

$$O_s = 0.25 \cdot \text{linear}(X) \quad (9)$$

$$O_d = 0.5 \cdot \sigma(\text{linear}_1(X)) \cdot \text{linear}_2(X) \quad (10)$$

$$S = g + O \quad (11)$$

$$X' = \text{grid_sample}(X, S) \quad (12)$$

式中: $\text{linear}(\cdot)$ 为通道数变换的线性层操作运算符; O_s 为静态范围因子生成的偏移量; O_d 为动态范围因子生成的偏移量; $\text{grid_sample}(\cdot)$ 为网格采样函数运算符; X' 为输出特征; $\sigma(\cdot)$ 为 Sigmoid 激活函数运算符。




图 9 DySample 模块结构原理图

Fig. 9 Structure principle diagram of DySample module

3 实验结果与分析

3.1 实验环境与数据

本文汽车面漆缺陷数据集内部包含凹坑 (Dent)、碰伤 (Bump) 和划痕 (Scratch) 等 3 种缺陷类型, 缺陷示例如图 10 所示。由第一节数据集制作方法制作 28 张 BDS, 通过 resize、rescale、加噪、反转、旋转、平移、缩放变换、剪切、对比度变换等 9 种方法进行数据增强, 丰富了数据的多样性。数据集扩张到 252 张, 内部包含缺陷数量如表 1 所示, 总缺陷数为 2 454 个。尽管样本较少, 但缺陷

的数量已达到训练的要求, 验证集和测试集都是对检测方法性能的无偏估计, 且验证集还具有实时检测方法性能的作用, 可及时调整超参数。由于样本量较少, 故不再划分测试集, 按照 8 : 2 比例划分训练集和验证集。




图 10 汽车面漆缺陷示例图

Fig. 10 Example images of automotive paint defects

表 1 各缺陷种类的数量

Table 1 Quantity of each type of defect

Defect	Quantity
Dent	287
Bump	1 164
Scratch	1 003
All	2 454

本文实验以 Pytorch 为深度学习框架进行仿真, 所用硬件配置中 CPU 为 18 核 AMD EPYC 9754, GPU 为 24G Nvidia Geforce RTX 3090。实验训练参数 epoch 设置为 400, 初始学习率为 0.01, 优化器为随机梯度下降优化器 (SGD), batchsize 设置为 16。在训练时为提高训练的质量和增强对汽车面漆缺陷检测的泛化性能, 使用了马赛克 (Mosaic) 在线数据增强方法。

3.2 评价指标

目标检测模型的评价指标通常用精确度 (Precision, P)、召回率 (Recall, R) 和平均精度 (mAP) 等指标来衡量方法的性能。 P 为衡量检测方法的错检率, 数值越大则错误率越小; R 为衡量方法对缺陷的漏检率, 数值越大则缺陷漏检越少; mAP 为衡量检测方法的平均精度, 数值越大则模型的性能越好; 帧率 (FPS) 为一秒内检测样本的数量, 用于衡量模型的检测速度; GFLOPs 为以 G 为单位的浮点运算次数, 用于衡量模型的计算复杂度。以上各指标的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (13)$$

$$R = \frac{TP}{TP + FN} \tag{14}$$

$$AP = \int_0^1 P(R) dR \tag{15}$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP(i) \tag{16}$$

$$FPS = \frac{Number}{time} \tag{17}$$

式中: TP 是正样本被正确预测为正类的数量;

FP 是负样本被错误预测成正类的数量; FN 为原本为正样本但被检测为负类的数量; mAP 为平均精度均值; n 为检测的类别数量, AP 为 $P(R)$ 曲线下的面积。

3.3 消融实验

为了验证改进 YOLOv8 各模块的有效性, 对改进的方法做了消融实验, 其实验结果数据如表 2 所示。

表 2 消融实验

Table 2 Ablation experiment

Methods	SC	RFA	ADown	DySample	mAP50/%	mAP50-95/%	Params/MB	GFLOPs/G	FPS/Hz
a					95.3	79.9	3.0	8.1	91.84
b	√				94.4	81.4	3.4	8.5	88.30
c		√			95.3	81.2	3.0	8.1	95.27
d	√	√			97.1	82.2	3.5	8.5	87.31
e	√	√	√		95.7	80.0	3.2	8.0	89.85
f	√	√		√	96.1	81.7	3.5	8.5	88.21
Ours	√	√	√	√	97.2	81.8	3.2	8.0	92.03

表 2 中, 方法 a 为 YOLOv8n 方法, 并以此作为基线方法。从表 2 中可以分析到, 方法 b 和方法 c 在 mAP50-90 上分别增长 1.5% 和 1.3%。方法 c 相比于基线 mAP50 提升 2.4%, mAP50-90 提升 2.3%, 性能显著提升证明 SC 和 RFA 能更有效地处理和提取特征。方法 e 相比于基线提升的并不多, 但相比于方法 d 和方法 f 对参数量和 GFLOPs 进行了平衡, 参数量降低 0.3 MB, GFLOPs 降低 0.5 G, FPS 提高 1.64 Hz, 证明模型更加轻量是因为 ADown 模块起着决定性作用。方法 f 相比于基线 mAP50 提升 0.8%, mAP50-90 提升 1.8%, 证明 DySample 在上采样过程中避免了有效特征的丢失, 丰富了有效的特征信息。本文所提出的改进方法相比于基线

mAP50 提升 1.9%, mAP50 提升 1.9%, 尽管参数量略有 0.2 MB 的提升, 同时也降低了 0.1 G 的 GFLOPs, FPS 提高 0.79 Hz, 综合性能显著优于基线方法 a, 证明了本文所改进的方法在汽车面漆缺陷检测中具有一定的价值。

3.4 与已有算法对比实验

为了验证本文所提方法的优越性, 与其他方法进行了对比实验。对比算法由双阶段方法的 Faster-RCNN、单阶段方法的 SSD 与 YOLO 系列、与 Transform 相结合的 YOLO 算法和 Transform 与 DETR 相结合的 RT-DETR 方法组成, 在实验过程中 epoch 设置为 400, 其对比实验结果如表 3 所示。

表 3 与已有算法的对比实验结果

Table 3 Comparison experimental results with existing algorithms

Methods	mAP50 of each category/%			Precision/%	Recall/%	mAP50/%	Params/MB	GFLOPs/G	FPS/Hz
	Dent	Bump	Scratch						
Faster-RCNN	50.0	48.3	41.5	61.0	47.7	46.6	136.7	401.7	24.32
SSD	50.0	79.0	70.7	93.6	54.0	66.6	23.9	274.1	29.83
YOLOv3-tiny	99.5	94.7	93.5	95.0	90.1	95.9	12.1	18.9	65.84
YOLOv5s	99.5	95.6	93.2	95.8	89.7	96.1	9.1	23.8	62.58
YOLOv7	99.5	95.4	93.9	93.5	91.2	96.3	36.5	103.2	48.54
YOLOv8n	99.5	92.9	93.6	92.4	90.1	95.3	3.0	8.1	91.84
YOLOv8s	99.5	97.2	96.2	93.8	94.7	97.6	11.1	28.4	50.76
YOLOv8-SwinTransformer	99.5	89.6	82.3	88.5	84.2	90.5	30.0	79.1	32.12
RT-DETR-l	75.3	57.5	49.1	55.1	59.1	60.6	28.4	100.6	36.92
Ours	99.5	96.5	95.5	95.9	92.0	97.2	3.2	8.0	92.03

从表 3 中可以看出,在参数量、GFLOPs 和 FPS 显著优于其他算法,本文方法更轻量,计算复杂度更小,速度更快。相比于两阶段 Faster-RCNN 方法,本文方法的所有指标显著拥有优越性,降低了错检率和漏检率,且 mAP50 提升 50.6%,参数量和 GFLOPs 降低约 50 倍。相比于 SSD、YOLOv3-tiny、YOLOv5s 和 YOLOv7 等方法,各项指标都低于本文改进方法。相比于 YOLOv8s,该方法比基线 YOLOv8n 高一个量级,Recall 降低 2.7%,mAP50 降低 0.4%,但是在 Precision 上提高 2.1%,尤其是在参数量、GFLOPs 和 FPS 上,降低 7.9 MB 和 20.4 G, FPS 提升 41.27 Hz,收益远大于损失,证明了本文方法的优越性。相比于 YOLOv8-SwinTransformer 方法,不仅存在参数量大、计算复杂度高、检测速度慢的弊端,检测性能也较差。相比于 RT-DETR,该方法在目标检测领域拥有很出色的表现,但是该方法在训练时,收敛非常慢,训练的周期较长。从表 3 中可以看出,400 个 epoch 中,本文方法在各

方面指标均优于 RT-DETR,且训练时间远小于该方法。综上所述,本文所提改进的方法不仅可以经过较短的训练时长达到一个很不错的性能,而且拥有更快的检测速度和极低的参数量与 GFLOPs。

3.5 改进 YOLOv8 方法的适用性实验

为了进一步验证改进 YOLOv8 方法的优越性能,分别在东北大学 NEU-DET 钢材表面缺陷公共数据集和 PASCAL VOC 2012 公共数据集上进行适用性实验,实验结果如表 4 所示。NEU-DET 公共数据集共有 crazing、inclusion、patches、pitted_surface、rolled-in_scale、scratches 等 6 种缺陷,每种缺陷包含 300 个样本,共 1 800 个样本。PASCAL VOC 2012 公共数据集共有 20 类目标,数据集共 17 125 个样本。两种数据集都以 7:1:2 的比例划分训练集、验证集和测试集,训练参数 epoch 设置为 400, batchsize 设置为 32,优化器为随机梯度下降优化器,初始学习率为 0.01,训练过程使用马赛克数据增强。

表 4 NEU-DET 和 VOC 2012 公共数据上适用性实验结果

Table 4 Applicability experimental results on NEU-DET and VOC2012 public datasets


Datasets	Methods	Precision/%	Recall/%	mAP50/%	mAP50-95/%
NEU-DET	YOLOv8n	70.4	71.8	75.3	42.0
	Ours	73.2	72.8	76.7	42.3
PASCALVOC 2012	YOLOv8n	67.3	56.7	61.3	44.6
	Ours	69.4	56.1	62.1	44.8

由表 4 的实验结果可以看出,本文所改进的方法相比于基线,各项指标都具有明显的优势。在 NEU-DET 数据集中, Precision 提升 2.8%, Recall 提升 1%, mAP50 提升 1.4%, mAP50-90 提升 0.3, 错检率和漏检率都有所降低,并且平均精度都优于基线方法的性能。在 PASCAL VOC 2012 数据集中, Precision 提升 2.1%, mAP50 提升 0.8%, mAP50-90 提升 0.2, 尽管相比于基线 Recall 降低 0.6%, 出现漏

检的问题,但在误检率和精确率上具有更优的表现。因此,本文改进 YOLOv8 方法在不同的检测领域同时具备较强的适用性。

3.6 改进算法检测效果实验

为了更直观地看出本文方法的检测效果,将基线 YOLOv8n 方法和本文改进方法在相同的测试集上进行了效果对比实验,其效果对比图如图 11 所示。






图 11 本文改进方法与基线 YOLOv8n 方法检测效果对比图

Fig. 11 Comparison of detection results between improved method and baseline YOLOv8n method

图 11 中第 1 列为 BDS, 第 2 列为存有明显缺陷的原图, 第 3 列为 YOLOv8n 的检测效果图, 第 4 列为本文改进方法的检测效果图。通过第 1 行效果对比图可以看出, 在具有较少目标进行检测时, 置信度均高于 YOLOv8n 方法, 拥有更准确的检测性能。从第 2 行和第 3 行效果对比图可以看出, YOLOv8n 存在错检和漏检的问题, 而本文改进方法进一步完善了这个问题, 降低了错检率和漏检率。从第 4 行效果对比图可以看出, 在进行多目标检测时, 同样具有很好的检测性能, 相对于 YOLOv8n 方法更精确, 例如划痕位置的置信度更高, 并且减少了大概在图中心位置上的碰伤缺陷 (Bump) 的错检行为。因此, 本文所提方法在汽车面漆缺陷检测中有着显著优越的性能。

4 结论

本文提出了一种深度学习与 PMD 相结合的方法, 对汽车面漆凹坑、碰伤、划痕等 3 种缺陷进行实验。在经 PMD 获取车漆表面形貌信息时, 避免了镜面反射的不利因素, 双模态提高了数据集的质量, 增强了缺陷特征的表示, 更重要的是通过使用本文所提高质量小样本数据集, 并利用改进 YOLOv8 方法进行定位和分类, 其模型性能与准确度都有所提高。通过消融实验和对比实验对本文所提方法进行了评估与对比, 通过对改进 YOLOv8 方法的适用性实验对网络模型的适用性进一步研究和性能验证。实验结果表明, 消融实验证明各模块的预期效果成功实现, 检测方法对比实验证明改进方法的准确度和精度都有所提升, 适用性实验证明改进 YOLOv8 方法也具有较广泛的适用性。本文同时存在一定的不足之处, 由于部分

车漆缺陷样本无法获取, 未能将其他汽车面漆缺陷共同进行研究, 同时双模态数据样本采集耗时, 并且以 YOLOv8n 为基线改进方法, 其精度和效率还不够高, 需在下一步工作中继续研究更高效、更精确的汽车面漆缺陷检测方法。

参考文献:

- [1] KIESELBACH K K, NÖTHEN M, HEUER H. Development of a visual inspection system and the corresponding algorithm for the detection and subsequent classification of paint defects on car bodies in the automotive industry[J]. Journal of Coatings Technology and Research, 2019, 16(4): 1033-1042.
- [2] REMEŠOVÁ M, KLAČURKOVÁ L, ROČŇÁKOVÁ I, et al. Application of metallographic analysis techniques for detection and identification of spray paint defects[J]. Solid State Phenomena, 2017, 4591: 118-123.
- [3] XU J, ZHANG J, ZHANG K, et al. An APF-ACO algorithm for automatic defect detection on vehicle paint[J]. Multimedia Tools and Applications: an International Journal, 2020, 79(35/36): 25315-25333.
- [4] CHENG P, CUI A, YANG Y, et al. Recognition and classification of coating film defects on automobile body based on image processing[C]//2017 10th International congress on image and signal processing, biomedical engineering and informatics (CISP-BMEI). Shanghai: IEEE, 2017: 1-5.
- [5] AKHTAR S, TANDIYA A, MOUSSA M, et al. An efficient automotive paint defect detection system[J]. Advances in Science Technology and Engineering Systems Journal, 2019, 4(3): 171-182.

- [6] SHAN W, LI D, LIU S, et al. A random feature mapping method based on the AdaBoost algorithm and results fusion for enhancing classification performance[J]. Expert Systems with Applications, 2024, 256: 124902.
- [7] MELAM N. Foreground moving object detection using support vector machine (SVM)[J]. International Journal of Recent Technology and Engineering, 2019, 8(4): 2354-2356.
- [8] HE B, HOU Y, XIONG Y, et al. Railway fastener defects detection using Gaussian mixture deformable part model[J]. Journal of Physics: Conference Series, 2019, 1302(2): 022102.
- [9] JIANG Z L, HU X Y, WANG S X. Image classification of car paint defect detection based on convolutional neural networks[J]. Journal of Physics: Conference Series, 2023, 2456(1): 012037.
- [10] CHANG F, LIU M, DONG M, et al. A mobile vision inspection system for tiny defect detection on smooth car-body surfaces based on deep ensemble learning[J]. Measurement Science and Technology, 2019, 30(12): 125905.
- [11] KARANGWA J, KONG L, YOU T, et al. Automated surface defects detection on mirrorlike materials by using faster R-CNN[C]//2020 7th International conference on information science and control engineering (ICISCE). Changsha: IEEE, 2020: 2288-2294.
- [12] ZHANG J, XU J, ZHU L, et al. An improved MobileNet-SSD algorithm for automatic defect detection on vehicle body paint[J]. Multimedia Tools and Applications, 2020, 79: 23367-23385.
- [13] SONG M, YI J, WEI S, et al. Mirror-like defect detection technology based on YOLOv5 and phase measuring deflectometry[C]//2023 2nd International conference on robotics, artificial intelligence and intelligent control (RAIIC). Mianyang: IEEE, 2023: 199-203.
- [14] JIANG W, CHEN X, HE Y, et al. Semi-supervised method for visual detection of automotive paint defects[J]. Measurement Science and Technology, 2024, 35(8): 085902.
- [15] LI Z, WANG D, LIU L, et al. Batch specular plane flatness measurements based on phase measuring deflectometry[J]. Sensors, 2024, 24(9): 2693.
- [16] 覃云说, 朱勇建, 秦国锋, 等. 条纹反射法中新的缺陷表征质量图[J]. 应用光学, 2023, 44(3): 614-620.
- QIN Yunshuo, ZHU Yongjian, QIN Guofeng, et al. New defect characterization mass map in fringe reflection method[J]. Journal of Applied Optics, 2023, 44(3): 614-620.
- [17] 徐鹏, 刘锦涛, 王建华. 改进的双 N 步相移轮廓术[J]. 电子测量与仪器学报, 2022, 36(8): 213-222.
- XU Peng, LIU Jintao, WANG Janhua. Improved double N-step phase-shifting profilometry[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 213-222.
- [18] ZHANG H, WANG Y, DAYOUB F, et al. Varifocalnet: an iou-aware dense object detector[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021: 8510-8519.
- [19] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics, 2022, 52(8): 8574-8586.
- [20] LI X, WANG W, WU L, et al. Generalized focal loss: learning qualified and distributed bounding boxes for dense object detection[J]. Advances in Neural Information Processing Systems, 2020, 33: 21002-21012.
- [21] LIU J J, HOU Q, CHENG M M, et al. Improving convolutional networks with self-calibrated convolutions[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle: IEEE, 2020: 10096-10105.
- [22] WANG C Y, YEH I H, LIAO H Y M. Yolov9: Learning what you want to learn using programmable gradient information[EB/OL]. (2024-02-29)[2024-08-29]. <https://arxiv.org/abs/2402.13616>.
- [23] ZHANG X, LIU C, YANG D, et al. RFACnv: Innovating spatial attention and standard convolutional operation[EB/OL]. (2024-5-28)[2024-8-29]. <https://arxiv.org/abs/2304.03198>.
- [24] LIU W, LU H, FU H, et al. Learning to upsample by learning to sample[C]//Proceedings of the IEEE/CVF international conference on computer vision. Paris: IEEE, 2023: 6027-6037.