

文章编号: 1671-7449(2024)06-0668-10

燃油泵航插与锁紧保险的缺陷检测算法研究

王宇鑫¹, 陆永华^{1*}, 刘江伟², 朱 贇²

(1. 南京航空航天大学 机电学院, 江苏 南京 210016; 2. 中国航发控制系统研究所, 江苏 无锡 214000)
摘要: 燃油泵是航空发动机燃油控制系统的重要组成部分, 其表面形态复杂、缺陷种类繁多。航空插座和锁紧保险是燃油泵上广泛应用的零件, 由于工艺水平有限、工人操作不当等因素, 在工业生产中容易出现多种表面缺陷, 因此对其进行缺陷检测具有重要意义。针对传统检测方法检测精度低、效率低的问题, 提出了基于特征提取的表面缺陷检测算法和基于深度学习的小目标检测网络、旋转目标检测网络, 以满足不同场景的检测需求。实验结果显示, 改进的小目标检测网络相较于传统方法准确率提高了11.34%, 相较于原始YOLOv8s网络, mAP50、mAP50:95分别提升了6.6%、4.7%, 参数量下降34%。改进的旋转目标检测网络相较于传统方法准确率提高了10.38%, 相较于原始ShuffleNet-V2网络, mAP50、mAP50:95分别提升了4.6%、2.6%, 参数量下降17.6%。实验结果表明, 提出的缺陷检测算法具有较高的检测精度, 能够实现燃油泵航插、锁紧保险的快速准确检测。

关键词: 燃油泵表面缺陷检测; 特征提取; 小目标检测; 旋转目标检测

中图分类号: TP391

文献标识码: A

doi: 10.3969/j.issn.1671-7449.2024083

引用格式: 王宇鑫, 陆永华, 刘江伟, 等. 燃油泵航插与锁紧保险的缺陷检测算法研究[J]. 测试技术学报, 2024, 38(6): 668-677.

WANG Yuxin, LU Yonghua, LIU Jiangwei, et al. Research on defect detection algorithm for fuel pump aviation socket and locking fuse[J]. Journal of Test and Measurement Technology, 2024, 38(6): 668-677.

Research on Defect Detection Algorithm for Fuel Pump Aviation Socket and Locking Fuse

WANG Yuxin¹, LU Yonghua^{1*}, LIU Jiangwei², ZHU Yun²

(1. College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. China Aviation Engine Control System Research Institute, Wuxi 214000, China)

Abstract: The fuel pump is an important component of the aviation engine fuel control system, with complex surface morphology and a wide variety of defects. Aviation sockets and fuses are widely used parts on fuel pumps, which are prone to multiple surface defects in industrial production due to factors such as limited craftsmanship and improper operation by workers, so it is of great significance to detect defects on them. Aiming at the problems of traditional inspection methods such as low detection accuracy and low efficiency, a surface defect detection algorithm based on feature extraction, a small object detection network based on deep learning, and a rotating object detection network is proposed to meet the detection needs of different scenarios. The experimental results show that the improved small object detection network has an accuracy increase of 11.34% compared to traditional methods. Compared to the original YOLOv8s network, the mAP50 and

收稿日期: 2024-03-02

基金项目: 国家自然科学基金资助项目(51975293); 航空科学基金资助项目(2019ZD052010)

作者简介: 王宇鑫(2000-), 男, 硕士生, 主要从事图像处理、智能检测等研究。E-mail: wangyuxin@nuaa.edu.cn.

* **通信作者:** 陆永华(1977-), 男, 博士, 教授, 主要从事智能检测与控制、机器人、传感器等研究。E-mail: nuaa_lyh@nuaa.edu.cn.

mAP50:95 has increased by 6.6% and 4.7% respectively, and the number of parameters has decreased by 34%. Compared to traditional methods, the improved rotating object detection network has an accuracy increase of 10.38%. Compared to the original ShuffleNet-V2 network, the mAP50 and mAP50:95 has increased by 4.6% and 2.6% respectively, and the number of parameters has decreased by 17.6%. The experimental results indicate that the defect detection algorithm has high detection accuracy and can achieve fast and accurate detection of fuel pump aviation sockets and locking fuse.

Key words: fuel pump surface defect detection; feature extraction; rotating target detection; small target detection

0 引言

燃油泵是航空发动机燃油控制系统的重要部件,可以为发动机提供预定流量和压力的燃油,对飞机动力控制起着重要作用,其结构复杂精密、配件种类繁多,如图 1 所示。其中,航空插座用于连接控制器和传输电信号,锁紧保险用于保证各零件的可靠连接。在燃油泵的生产过程中,由于技术工艺水平有限、工人操作不当等因素,容易出现航空插座针尖断裂以及保险丝松散、断裂等问题,直接影响产品的实际功能和可靠性。




图 1 燃油泵

Fig. 1 Fuel pump

针对泵体内部的故障检测,许多学者做了相关研究。Siano 等^[1]提出了一种基于振动信号的非线性自回归模型,以描述齿轮泵的动态行为,实现了对齿轮泵空穴现象的在线故障检测。Awad^[2]提出了一种基于多项式回归和控制图的燃油泵系统异常检测方法,通过监控预测电机电流与实际电流之间的异常值,实现对燃油泵系统健康状况的持续检测。Jiao 等^[3]提出了一种基于经验模式分解(EMD)和概率神经网络(PNN)的故障诊断模型,实现了对机载燃油泵的智能故障诊断。

由于燃油泵表面复杂的几何形状和表面处理,以及表面缺陷的隐蔽性和多样性,对于燃油泵表面缺陷检测的研究相对较少,技术发展也面临较大挑战。

在传统的工业生产中,燃油泵的缺陷检测主要采用人工目视检测方法,这种方法准确率低、


效率低、受人工经验和主观因素的影响较大。近年来,机器视觉和深度学习技术快速发展,广泛应用于表面缺陷检测领域。与传统检测方法相比,基于视觉的非接触式检测技术具有安全可靠、检测速度快、检测精度高等优点。

Baygin 等^[4]针对印刷电路板孔洞缺失问题,提出了一种基于机器视觉的检测方法:首先从系统中获得参考图像,利用最大类间方差法(Otsu)阈值化和Hough变换方法对其进行特征提取,最后使用模板匹配的方法检测电路板上的缺失孔。刘泽等^[5]针对钢轨表面缺陷设计了一种动态阈值分割和缺陷区域提取算法,可以准确提取缺陷位置区域并统计缺陷特征。赵明^[6]提出一种基于SFCS-YOLO v3的轴承防尘盖表面凹坑缺陷检测算法,实现了对轴承表面缺陷的高精度检测。

本文结合国内外研究现状,以某型号燃油泵的航空插座、锁紧保险为研究对象,针对现有检测方法效率低、精度低的问题,分别提出了基于特征提取和深度学习目标检测网络的缺陷检测方法,实现了对燃油泵表面缺陷的高效、高精度检测。

1 基于机器视觉的缺陷检测算法

航空插座针尖反光现象较为明显,易于提取。锁紧保险由两根金属保险丝缠绕拧和而成,每节保险丝称为“扭辫”,如图 2 所示。



(a) 航空插座

(b) 锁紧保险

图 2 检测对象示例

Fig. 2 Example of detection object

本文针对航空插座和锁紧保险的形态特点及缺陷类型,设计了专用的缺陷检测算法,其流程如图3所示。




图3 特征提取算法流程

Fig. 3 Feature extraction algorithm process

1.1 特征提取

1.1.1 针尖特征提取

首先,设定一个灰度经验值 k_{exp} , 遍历待检测图像,计算大于该经验值像素的灰度均值 \bar{k}_1 。遍历图像后,可以得到 n_1 个有效像素位置,将计算得到的灰度均值作为全局阈值分割的阈值。这一步骤的目的是减弱图像亮度差异对灰度值的影响。其中,灰度经验值 k_{exp} 需要进行多次试验确定,以确保不同光照条件下的准确分割。上述步骤可表示为

$$k_{x,y} = \begin{cases} k_{x,y}, & k_{x,y} \geq k_{exp}, \\ 0, & k_{x,y} < k_{exp}, \end{cases} \quad (1)$$

$$thresh = \bar{k}_1 = \frac{\sum_{i=1}^{n_1} k_i}{n_1}, \quad (2)$$

式中: k_i 为第 i 个有效像素位置的灰度值; $k_{x,y}$ 为航空插座图像中坐标 (x, y) 处的灰度值。

1.1.2 扭辫特征提取

保险丝可能分布在燃油泵的各个表面,若采用固定阈值分割,特征难以提取。本文对检测图

像进行两次遍历,实现灰度值统计、筛选,将灰度图像转换为二值图像,实现保险丝的特征分割。

$k_{m,n}$ 表示锁紧保险图像中坐标 (m, n) 处的灰度值。首次遍历,统计所有灰度值不为0的像素信息,得到 n_2 个有效像素位置,其灰度值之和为 k_s ,最大有效灰度值为 k_{max} ,灰度均值 \bar{k}_2 。计算最大灰度值与灰度均值之差 k_d ,它反映了亮度最高像素位置的反光程度。

$$k_d = k_{max} - \bar{k}_2 = k_{max} - \frac{k_s}{n_2}. \quad (3)$$

第二次遍历,设当前位置灰度值与灰度均值之差为 $k'_{m,n}$,

$$k'_{m,n} = k_{m,n} - k_d. \quad (4)$$

根据 $k'_{m,n}$ 与 k_d 的比值,可以判断当前像素位置的反光程度,通过下式进行灰度值筛选。

$$k''_{m,n} = \begin{cases} 0, & \frac{k'_{m,n}}{k_d} < \delta, \\ 255, & \frac{k'_{m,n}}{k_d} \geq \delta, \end{cases} \quad (5)$$

式中: δ 为比例阈值, $0 < \delta < 1$; $k''_{m,n}$ 为灰度值筛选后坐标 (m, n) 处的灰度值,取0或255。

1.2 缺陷检测

经过形态学变换得到的二值化图像,首先提取出所有的封闭轮廓。通过筛选最小包围圆的半径得到符合要求的针尖轮廓。对于锁紧保险,通过筛选扭辫轮廓的面积过滤掉残留的细小噪声。为了避免误检尺寸大小合格的假阳性轮廓,还需要通过封闭轮廓的最小包围矩形进一步筛选。

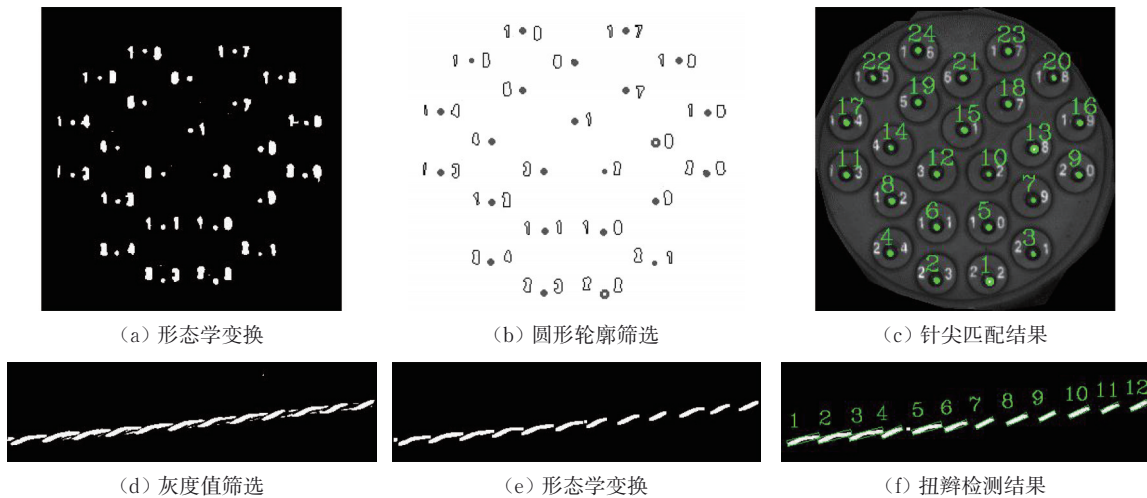


图4 缺陷检测示例

Fig. 4 Example of defect detection

筛选得到圆形轮廓后,计算圆形轮廓的数量以及圆心的坐标,并与模板图像的针尖数量和圆心坐标进行匹配,将匹配成功的针尖编号。当圆形轮廓数量小于模板针尖数量时,判定为针尖断裂,即缺针。

对于锁紧保险,通过计算当前区域内检测到的扭辫数来判断该锁紧保险是否合格。若保险丝存在断裂或松散垂荡现象,检测数量会出现异常。基于特征提取的缺陷检测示例如图 4 所示。

2 基于 YOLOv8s 的小目标检测网络

小目标样本的特征尺寸较小,可利用特征少。目前常见的目标检测网络,如 YOLO 系列、R-CNN 系列等,具有较大的下采样倍数,在网络的深层特征图中更加关注较大的物体,难以学习到小目标的有效特征信息,对小目标的检测性能较差。

航空插座的待检测针尖部分尺寸较小,尺度特征不一且缺乏细节信息。使用传统的目标检测网络效果不佳,容易造成漏检、误检等问题。本文在 YOLOv8s 目标检测网络的基础上改进,引入 SENet (Squeeze-and-Excitation Networks) 注意力机制并添加小目标检测层,使网络能够自适应调整感受野,更加关注小目标的特征信息以提升检测效果,实现对航空插座针尖的高精度检测^[7]。

2.1 数据增强处理

由于燃油泵上航空插座数量较少,可采集到的原始数据集样本不足,因此使用数据增强的方式扩充原始数据集,以提升模型的泛化能力和鲁棒性。

数据增强是通过对原始数据进行像素变换、几何变换、引入随机噪声等操作,来模拟真实场景中数据的多样性和复杂性^[8]。




图 5 图像增强示例

Fig. 5 Example of image enhancement

本文使用裁剪、平移、旋转、镜像、改变亮度、加噪声等方法,对每张原始图像增强 5 次。在裁剪、平移操作中,首先需要找到包含所有目标框的最小图像,在此基础上随机扩展,在不越界的前提下得到操作后的数据集;镜像、旋转的意义在于增加数据的多样性和复杂性,而添加噪声可以使模型更好

地适应真实场景中的噪声情况,增强模型的鲁棒性。图像增强的效果如图 5 所示。

2.2 网络改进

YOLOv8 的总体结构包括骨干网络 (Backbone)、颈部网络 (Neck)、检测头 (Head) 三部分。Backbone 部分采用的结构为 Darknet53, 包括基本卷积单元 Conv, 空间金字塔池化模块 SPPF, 增加感受野、提高特征提取能力的 C2f 模块^[9]。本文在 C2f 的瓶颈模块 (Bottleneck) 中添加 SENet 注意力机制,以提高模型对针尖特征的关注度,其结构如图 6 所示。

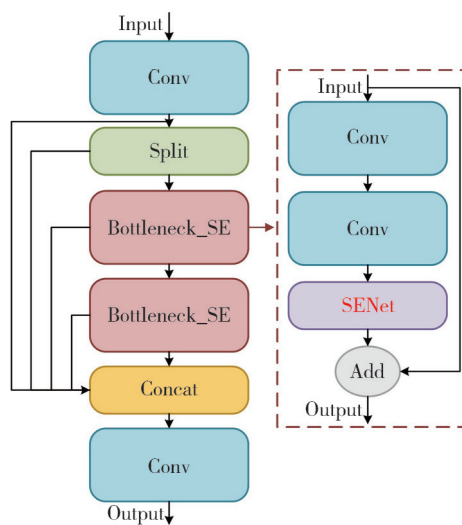


图 6 C2f 模块结构

Fig. 6 C2f module structure

网络的检测对象为航空插座针尖这类小目标,因此可以简化 Backbone 的深层卷积部分。本文将 Backbone 部分 Stage Layer4 中的卷积层和 C2f 模块去除,使得网络模型不进行过于深层次的卷积,在减少参数量、降低模型复杂度的同时提升模型对小目标的检测能力^[10]。

Neck 部分采用 PAN-FPN (Path Aggregation Network-Feature Pyramid Network) 结构,实现了多个不同尺寸特征图的融合。原始 YOLOv8s 网络下采样倍数较大,对于小目标的特征提取能力较弱,因此,本文在 Neck 部分添加了小目标检测层:将 Neck 部分 TopDown Layer1 中 C2f 模块的输出特征图 (80×80×256) 作为小目标检测层的输入,首先经过上采样层 (Upsample) 提升特征图的空间分辨率,再利用 Concat 层进行数据拼接,最终由 C2f 模块实现特征融合。为了简化模型,同时去除 Neck 部分原有的大目标检测层。

Head部分使用解耦头结构将分类和检测分离,在检测过程中还采用了Anchor-Free机制,不再依赖于预定义的边界框,目标位置和尺寸通过对目标中心点和边界框的宽度和高度进行回归来确定^[11]。解耦头模型结构如图7所示。去除大目标检测层后,Head部分得到3种尺寸的检测特征图,大小分别为:160×160、80×80、40×40,其

中160×160检测特征图用于检测4×4以上的小目标。改进后的YOLOv8模型结构如图8所示。




图7 解耦头模型结构

Fig. 7 Decoupling head model structure

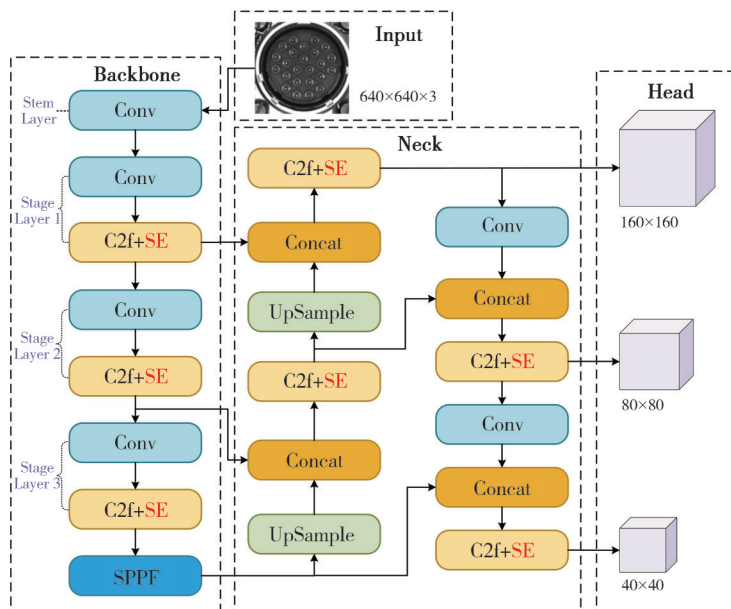



图8 改进后的YOLOv8s模型结构

Fig. 8 Improved YOLOv8s model structure

3 基于ShuffleNet-V2的旋转目标检测网络

传统目标检测算法通常使用水平框来识别和定位目标对象。然而,当目标在图像中呈现旋转或倾斜姿态时,使用水平框会包含较多的背景区域,如图9(a)所示,从而导致冗余像素增多,降低网络对目标关键特征的提取能力,最终导致分类置信度与定位精度之间存在较大偏差。



(a) 水平框

(b) 旋转框

图9 旋转框和水平框检测效果示意图

Fig. 9 Schematic diagram of detection effect for rotating and horizontal boxes

若采用旋转框,可以更加精确地拟合目标的形状,如图9(b)所示,通过降低锚框中背景区域的占比,可以有效改善特征不对齐的问题,最终提升检测精度^[12]。

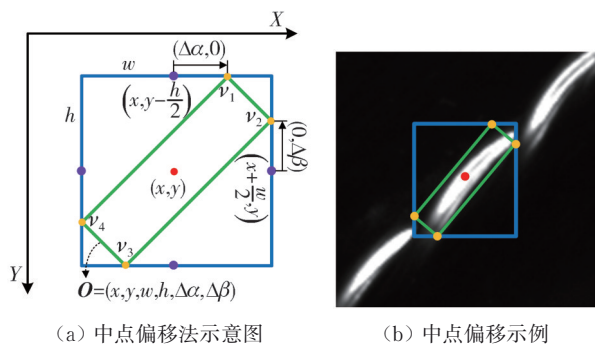
由于锁紧保险上每节扭辫的姿态、角度不一,因此使用旋转目标检测方法。在Shufflenet-V2轻量化主干网络的基础上,融合了SENet通道注意力机制,并对卷积层进行了轻量化改进,通过引入Oriented R-CNN旋转目标检测算法,实现对锁紧保险扭辫的高精度检测。

3.1 Oriented R-CNN旋转目标检测算法

Oriented R-CNN是两阶段的旋转目标检测算法,由旋转的RPN(Region Proposal Network)和旋转的RCNN检测头构成。首先,利用旋转的RPN生成高质量旋转候选框,再通过Rotated RoIAlign提取固定大小尺寸的特征,最后,将这些特征作为RCNN检测头的输入,执行分类和回归任务^[13]。


Oriented RPN扩展了RPN网络的维度,采用

中点偏移法, 通过调整回归分支的输出维度, 将每个位置的锚框从四维扩展为六维, 如图 10(a) 所示, 包括旋转候选框的中心坐标 (x, y) 、宽度 (w) 、高度 (h) , 以及外接矩形顶边和右边的偏移量 $\Delta\alpha$ 、 $\Delta\beta$ 。



(a) 中点偏移法示意图

(b) 中点偏移示例



(c) 候选框调整示意图

图 10 旋转框定义和候选框调整

Fig. 10 Rotation box definition and candidate box adjustment

旋转的 RCNN 检测头先对候选框进行调整, 将平行四边形的顶点坐标集 $V = \{v_1, v_2, v_3, v_4\}$ 转换为矩形, 并以较长的对角线作为矩形的对角线, 如图 10(c) 所示。再对调整后的旋转候选框执行旋转 RoI 对齐操作, 将得到的特征图作为旋转检测头的输入。

3.2 ShuffleNet-V2 主干特征提取网络

ShuffleNet-V2 是一种轻量级的深度神经网络架构, 在 ShuffleNet-V1 的基础上, 引入了 Channel Split 操作, 将输入通道分为两份, 分别用于残差连接和特征提取, 避免了分组卷积操作。最后将两个分支进行 Concat 融合, 并通过 Channel Shuffle 模块将堆叠的特征图通道重新排序, 实现各分组之间的特征融合^[14]。

ShuffleNet-V2 网络内部的卷积块是由一个下采样模块和多个基础模块连接构成。在基本模块中, 特征图尺寸、通道数不变; 而在下采样模块中, 特征图的长宽减半, 通道数加倍。下采样操作可以降低特征图的尺寸, 减少空间分辨率, 同时增加通道数,

从而有效地捕捉和学习更高级别的特征。

在下采样模块和基础模块的特征提取分支 (Branch2) 中, DW (Depthwise) 卷积前后都进行了 1×1 卷积。实际上这个分支只是为了融合 DW 卷积的通道间信息, 没有降维的需求, 因此, 本文只在 DW 卷积前进行 1×1 卷积, 实现 ShuffleNet-V2-LiteConv 版本。本文在特征提取操作中添加 SENet 注意力机制, 通过自适应学习不同特征通道的权重, 突出有用特征, 抑制无关特征, 提升网络的性能和泛化能力, 其结构如图 11 所示。改进后 ShuffleNet-V2 网络的基础模块和下采样模块结构如图 12 所示。


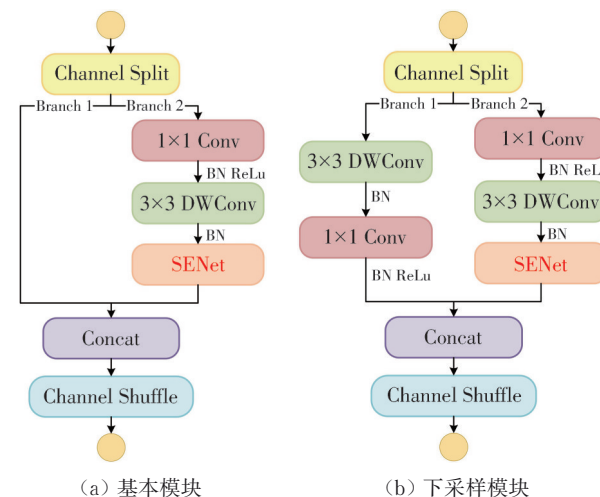


图 11 SENet 注意力机制

Fig. 11 SENet attention



(a) 基本模块

(b) 下采样模块

图 12 改进后 ShuffleNet V2 的两个模块

Fig. 12 The two modules of ShuffleNet V2 after improvement

4 实验

软件环境为 Windows 10, Python 3.8, CUDA 11.3, Pytorch 1.12.1, MMRotate 0.3.4。内存为 16.0 GB, GPU 型号为 NVIDIA RTX3060。航空插座和锁紧保险的训练数据集分别包含 540 张和 600 张图片, 训练集、验证集、测试集的划分比例为 5:3:2。

4.1 评价指标

本文使用准确率 (Precision)、召回率 (Recall)、mAP50、mAP50:95、参数量、GFLOPs

作为评价标准。mAP50表示IOU阈值等于0.5时的平均检测精度。mAP50:95表示步长为0.05,计算IOU阈值从0.5~0.95的所有IOU阈值下的检测精度的平均值。计算公式分别为

$$Precision = \frac{TP}{TP + FP} \times 100\%, \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \times 100\%, \quad (7)$$

$$mAP = \frac{\sum_{i=1}^K AP_i}{K}, \quad (8)$$

式中: TP 为正确分类的阳性样本数量; FP 为错误分类的阴性样本数量; FN 为错误分类的阳性样本数量。

4.2 消融实验

为了验证本文提出的每种改进模块的有效性,设计消融实验,实验结果如表1、表2所示。首先,在YOLOv8s模型中添加SENet注意力机制, Precision和Recall略有增加,参数量和算法复杂度基本一致, mAP50、mAP50:95分别只提升了0.8%、0.5%,表明仅添加注意力机制对小目标检测的性能提升有限。改进后的YOLOv8s-

SE-SODL模型通过删除大目标检测层,加入小目标检测层(SODL),在参数量下降34%的情况下, Precision、Recall、mAP50、mAP50:95相较于YOLOv8s分别提升了6.4%、5.5%、6.6%、4.7%,算法复杂度下降24.8%。这表明本文构建的小目标检测网络能够在降低模型复杂度的同时,显著提升小目标检测的平均精度。

对于旋转目标检测网络,首先在ShuffleNet-V2中添加SENet注意力机制, mAP50、mAP50:95分别提升了5.1%、3.2%, Recall下降了1.4%。这表明注意力机制对于旋转目标检测的精度具有较大提升,同时也可能导致网络在处理小目标或低对比度目标时过度关注全局信息,从而影响了对局部细节的感知,导致Recall下降。对卷积层进行轻量化处理后,检测精度略微下降,但是参数量和算法复杂度分别下降20.6%和22.2%;与此同时,轻量化处理有助于模型学习更具代表性的特征,从而导致Recall上升。改进后的ShuffleNet-V2-SE-LiteConv模型,参数量和模型复杂度相较于原始网络分别下降了17.6%和11.1%, mAP50和mAP50:95分别提升了4.6%和2.6%,表明改进后的网络在降低复杂度的同时,检测精度得到了一定的提升。

表1 小目标检测网络消融试验结果对比

Tab. 1 Comparison of results of small object detection network ablation experiments

网络模型	$P/\%$	$R/\%$	mAP50/%	mAP50:95/%	参数量/M	GFLOPs
YOLOv8s	80.9	83.2	73.9	43.8	11.2	28.6
YOLOv8s-SE	82.1	83.4	74.7	44.3	11.3	29.9
YOLOv8s-SODL	85.8	87.5	79.6	47.1	7.4	21.3
YOLOv8s-SE-SODL	87.3	88.7	80.5	48.5	7.4	21.5

表2 旋转目标检测网络消融试验结果对比

Tab. 2 Comparison of ablation test results for rotating object detection network

网络模型	$P/\%$	$R/\%$	mAP50/%	mAP50:95/%	参数量/M	GFLOPs
ShuffleNet-V2	81.9	84.9	76.3	42.1	3.4	6.3
ShuffleNet-V2-SE	86.1	83.5	81.4	45.3	3.6	7.5
ShuffleNet-V2-LiteConv	81.3	86.4	75.7	41.9	2.7	4.9
ShuffleNet-V2-SE-LiteConv	84.7	85.6	80.9	44.7	2.8	5.6

4.3 对比实验

本文中的小目标检测算法、旋转目标检测算法分别是基于YOLOv8s、ShuffleNet-V2模型改进的,为验证其检测性能,将其与主流的目标检测算法进行对比,实验结果如表3、表4所示。

YOLOv8s-SE-SODL对比双阶段检测算法Faster-RCNN, mAP50提升10.2%;对比以

ResNet作为特征提取网络的SSD算法, mAP50提升13.3%;对比CornerNet检测算法, mAP50提升11.4%。同时, YOLOv8s-SE-SODL的精度高于YOLOv5s、YOLOv7。ShuffleNet-V2-SE-LiteConv对比双阶段旋转目标检测算法Yolov5s_obb, mAP50提升7.3%;对比DRBox算法, mAP50提升10.0%;且YOLOv8s-SE-SODL的精度高于R-CenterNet、Yolov8_obb。

表 3 本文方法其他小目标检测算法对比

Tab. 3 Comparison of other small object detection algorithms in this article's method

小目标检测	mAP50/%	mAP50:95/%	参数量/M
Faster-RCNN	70.3	—	40
SSD	67.2	—	26.3
Corner Net	69.1	38.9	16.7
YOLOv5s	72.4	40.3	7.2
YOLOv6s	74.1	42.7	18.5
本文	80.5	48.5	7.4

表 4 本文方法与其他旋转目标检测方法对比

Tab. 4 Comparison of this method with other rotating object detection methods

旋转目标检测	mAP50/%	mAP50:95/%	参数量/M
DRBox	70.9	39.6	11.6
Yolov5s_obb	73.6	41.1	7.5
R-CenterNet	69.4	38.7	14.9
Yolov8_obb	77.8	43.9	11.4
本文	80.9	44.7	2.8

此外,为了验证旋转目标检测算法的有效性,将其与常见的非旋转目标检测算法进行对比

实验,结果如表 5 所示。

表 5 本文方法与非旋转目标检测方法对比


Tab. 5 Comparison between the method proposed in this article and non-rotating object detection methods

检测方法	mAP50/%	mAP50:95/%	参数量/M
Yolov5s	65.7	35.4	7.2
Yolov8s	69.6	36.8	11.2
ShuffleNet-V2	76.3	42.1	3.4
本文	80.9	44.7	2.8


以上对比实验表明,本文所提出的算法在小目标检测、旋转目标检测方面精度较高,具有良好的检测性能。

4.4 检测结果对比

为检验本文构建的深度学习目标检测网络对航空插座针尖、锁紧保险扭辫的检测效果,将原始网络和改进后的网络进行对比测试,实际检测效果如图 13 所示。




(a) YOLOv8s 检测效果



(b) YOLOv8s-SE-SODL 检测效果



(c) ShuffleNet-V2 检测效果



(d) ShuffleNet-V2-SE-LiteConv 检测效果

图 13 航空插座、锁紧保险检测效果

Fig. 13 Inspection effect of aviation sockets and locking fuses

从检测结果可以看出,原始 YOLOv8s 对于航空插座针尖的检测性能较差,容易产生漏检、重

复检测等情况。当添加了注意力机制和小目标检测层后,检测性能显著提升,且对于亮度变化较

大、倾斜视角拍摄的图像也有极好的检测效果。对于锁紧保险的检测,原始 ShuffleNet-V2 对于扭辫的特征识别能力较差,旋转矩形框的拟合精度较低,改进后的网络误检、漏检率大大降低,检测精度显著提升。

此外,为了验证本文提出的缺陷检测算法的准确性与可靠性,现将传统缺陷检测算法和基于深度学习的目标检测算法进行对比实验,其结果

如表 6 所示。可以发现,深度学习方法在检测准确率和检测效率方面均优于传统缺陷检测方法。尤其是对于视角倾斜、光照较亮或较暗等复杂条件下拍摄的图像,航空插座针尖、锁紧保险扭辫的检测准确率分别提高了 19.76%、23.74%。这表明深度学习方法对于复杂场景的泛化能力更强,能够有效适应视角倾斜、亮度变化等复杂条件,从而提高检测精度和算法的鲁棒性。

表 6 实验结果对比

Tab. 6 Comparison of experimental results

检测方法	针尖数/扭辫数 (正常条件拍摄)	正确检测数量	准确率/%	针尖数/扭辫数(复 杂条件拍摄)	正确检测数量	准确率/%	平均检测耗 时/s
航空插座缺陷检测算法	432	356	82.41	324	218	67.28	0.219
小目标检测算法	432	405	93.75	324	282	87.04	0.107
锁紧保险缺陷检测算法	684	553	80.85	396	257	64.90	0.246
旋转目标检测算法	684	624	91.23	396	351	88.64	0.085

5 结 论

由于缺陷的隐蔽性和复杂性,以燃油泵为研究对象的表面缺陷检测研究相对较少,因此本文分别从传统图像处理和深度学习目标检测网络两个方面进行了系统研究。首先提出了基于特征提取的传统缺陷检测方法,并通过改进 YOLOv8s、ShuffleNet-V2,提出了小目标检测网络、旋转目标检测网络。

传统缺陷检测方法具有可解释性强、计算成本低等优点,但这种方法的泛化能力较弱,检测精度一般,适用于对检测精度要求不高的场景。基于深度学习的目标检测方法,计算成本较高,研发周期较长,但具有泛化能力强、检测精度高等优点,能够适应复杂场景的检测需求。

常见的目标检测网络对小目标、旋转目标的检测能力较弱,容易造成漏检、误检等问题。通过对原始网络添加注意力机制、替换目标检测层,改进后的 YOLOv8s 网络 mAP50 和 mAP50:95 分别提升了 6.6%、4.7%,参数量下降 34%,改进后的 ShuffleNet-V2 网络 mAP50 和 mAP50:95 分别提升了 4.6%、2.6%,参数量下降 17.6%,满足实际的检测需求。

参考文献:

[1] SIANO D, PANZA M A. Diagnostic method by using vibration analysis for pump fault detection [J]. Energy Procedia, 2018, 148: 10-17.
[2] AWAD M. Fault detection of fuel systems using poly-

nomial regression profile monitoring [J]. Quality and Reliability Engineering International, 2017, 33 (4): 905-920.

[3] JIAO X, JING B, HUANG Y, et al. Research on fault diagnosis of airborne fuel pump based on EMD and probabilistic neural networks [J]. Microelectronics Reliability, 2017, 75: 296-308.
[4] 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 (IDAP), 2017: 1-5.
[5] 刘泽,王崑,王平. 钢轨表面缺陷检测机器视觉系统的设计 [J]. 电子测量与仪器学报, 2010, 24(11): 1012-1017.
LIU Ze, WANG Wei, WANG Ping. Design of machine vision system for inspection of rail surface defects [J]. Journal of Electronic Measurement and Instrument, 2010, 24(11): 1012-1017. (in Chinese)
[6] 赵明. 基于机器视觉的轴承表面缺陷检测系统研究 [D]. 太原: 中北大学, 2022.
[7] TAHERKHANI A, COSMA G, MCGINNITY T M. A deep convolutional neural network for time series classification with intermediate targets [J]. SN Computer Science, 2023, 4(6): 832.
[8] 高友文,周本君,胡晓飞. 基于数据增强的卷积神经网络图像识别研究 [J]. 计算机技术与发展, 2018, 28 (8): 62-65.
GAO Youwen, ZHOU Benjun, HU Xiaofei. Research on image recognition of convolution neural network based on data enhancement [J]. Computer Technology and Development, 2018, 28(8): 62-65.

(in Chinese)

- [9] WANG X, GAO H, JIA Z, et al. BL-YOLOv8: an improved road defect detection model based on YOLOv8[J]. *Sensors*, 2023, 23(20): 8361.
- [10] LI W, ZHANG H, WANG G, et al. Deep learning based online metallic surface defect detection method for wire and arc additive manufacturing [J]. *Robotics and Computer-Integrated Manufacturing*, 2023, 80: 102470.
- [11] KONG D, WANG J, ZHANG Q, et al. Research on fruit spatial coordinate positioning by combining improved YOLOv8s and adaptive multi-resolution model [J/OL]. *Agronomy*, 2023. [2024-01-22]. DOI:10.3390/agronomy13082122.
- [12] 仲伟峰, 郭峰, 向世明, 等. 旋转矩形区域的遥感图像舰船目标检测模型[J]. *计算机辅助设计与图形学学报*, 2019, 31(11): 1935-1945.
- ZHONG Weifeng, GUO Feng, XIANG Shiming, et al. Ship detection in remote sensing based with rotated rectangular region [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2019, 31(11): 1935-1945. (in Chinese)
- [13] XIE X, CHENG G, WANG J, et al. Oriented R-CNN for object detection[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), 2021: 3500-3509.
- [14] 辛文斌, 郝惠敏, 卜明龙, 等. 基于 ShuffleNetv2-YOLOv3 模型的静态手势实时识别方法[J]. *浙江大学学报(工学版)*, 2021, 55(10): 1815-1824.
- XIN Wenbin, HAO Huimin, BU Minglong, et al. Static gesture real-time recognition method based on ShuffleNetv2-YOLOv3 model[J]. *Journal of Zhejiang University (Engineering Science)*, 2021, 55(10): 1815-1824. (in Chinese)

(上接第 667 页)

- [3] LIU S, WANG Z, DONG Y. A compact filtering patch antenna with high suppression level and its CP application[J]. *IEEE Antennas and Wireless Propagation Letters*, 2023, 22(4): 769-773.
- [4] LIMA A M, CUNHA N H O, DA SILVA J P. Electromagnetic band gap based in Peano fractal geometry for harmonic suppression [J]. *Microwave and Optical Technology Letters*, 2021, 63(5): 1360-1365.
- [5] ACIKAYA F C, YILDIRIM B S. A dual-band microstrip patch antenna for 2.45/5-GHz WLAN applications[J]. *AEU-International Journal of Electronics and Communications*, 2021, 141: 153957.
- [6] LI K, WANG F W, REN Y H, et al. Dual-band circularly polarized antenna with harmonic suppression performance [J]. *International Journal of RF and Microwave Computer-Aided Engineering*, 2019, 29(8): e21797.
- [7] MOHD NOOR F S, ZAKARIA Z, LAGO H, et al. Dual-band aperture-coupled rectenna for radio frequency energy harvesting [J]. *International Journal of RF and Microwave Computer-Aided Engineering*, 2019, 29(1): e21651.
- [8] ZHANG Y M, ZHANG S, YE Q C, et al. Cosynthesis of a filtering antenna with harmonic suppression [J]. *IEEE Antennas and Wireless Propagation Letters*, 2020, 19(10): 1729-1733.
- [9] ZANG Y, ZHAI H, XI L, et al. A compact microstrip antenna with enhanced bandwidth and ultra-wideband harmonic suppression [J]. *IEEE Transactions on Antennas and Propagation*, 2019, 67(3): 1969-1974.
- [10] CHEN C C, HUANG S Y, ZHANG X Y, et al. Microstrip-fed circular ring-slot antennas with very wideband harmonic suppression [J]. *IEEE Antennas and Wireless Propagation Letters*, 2020, 19(12): 2295-2299.
- [11] SUN J Q, ZHANG L, LUO C W, et al. A filtering antenna with wide out-of-band suppression based on open-stubs resonator [J]. *International Journal of RF and Microwave Computer-Aided Engineering*, 2022, 32(4): e23042.
- [12] REN J, XIONG Z Y, DENG J Y, et al. A compact single-layer filtering patch antenna with wide harmonic suppression and enhanced bandwidth [J]. *AEU-International Journal of Electronics and Communications*, 2022, 145: 154083.
- [13] CHU C, WANG M, WANG J, et al. A new design of filtering patch antennas with enhanced bandwidth and harmonic suppression [J]. *IEEE Transactions on Antennas and Propagation*, 2023, 71(7): 6120-6125.