

基于深度学习的航空发动机滑油磨粒检测研究

侯媛媛¹, 李江红², 薛军印³

(1. 西安航空学院 计算机学院, 西安 710077;

2. 西北工业大学 动力与能源学院, 西安 710072;

3. 杭州海康威视数字技术股份有限公司 智能算法部, 杭州 310051)

摘要: 针对滑油中磨粒形状复杂且尺寸大小不一, 传统滑油磨粒检测方法存在时效性差、检测尺度小、精度低、非铁磁性磨粒不能检测等缺点; 设计了一种基于深度学习的航空发动机滑油磨粒检测方法; 基于连续流微流控芯片的滑油图像采样方法, 构建滑油图像采样系统; 设计图像增强方法, 进行图像数据增强消融试验研究, 针对 YOLOv3 模型和 Faster RCNN 模型进行精度测试, 结果表明消融试验后的 YOLOv3 模型检测能力明显优于 Faster RCNN 模型; 为减少消融后 YOLOv3 模型的误检率, 提出 SER 算法以优化该模型的推理置信度阈值; 研究结果表明滑油磨粒检测方法可解决传统测试中存在的问题, 且在 0.35 的置信度阈值下, YOLOv3 模型的检测结果能够达到 94.2% 的召回率和 95.9% 的精确度。

关键词: 航空发动机; 滑油磨粒检测; 深度学习; YOLOv3 模型; SER 算法

Research on Abrasive Detection of Aero-engine Lubricating Oil Based on Deep Learning

HOU Yuanyuan¹, LI Jianghong², XUE Junyin³

(1. School of Computer Science, Xi'an Aeronautical University, Xi'an 710077, China;

2. School of Power and Energy, Northwestern Polytechnical University, Xi'an 710072, China;

3. Intelligent Algorithm Department, Hangzhou Hikvision Digital Technology Co., Ltd.,

Hangzhou 310051, China)

Abstract: In view of the complex shapes and different sizes of abrasive grains in lubricating oil, traditional lubricating oil abrasive grain detection methods have disadvantages of poor timeliness, small detection scale, low accuracy, and the non-ferromagnetic abrasive grains which cannot be detected. An abrasive grain detection method for aero-engine lubricating oil is designed based on the deep learning. Based on the continuous flow microfluidic chip-based lubricant image sampling method, the lubricant image sampling system is constructed; The image enhancement method is designed, and the image data enhancement ablation experiment is carried out, the test accuracy was compared for the YOLOv3 model and the Faster RCNN model. The results show the detection ability of the YOLOv3 model is significantly better than the Faster RCNN model after the ablation test. In order to reduce the false detection rate of the YOLOv3 model after the ablation, the SER algorithm is proposed to optimize the model's inference confidence threshold. The research results show that the lubricating oil abrasive grain detection method can solve the problems in the traditional test, and under the confidence threshold of 0.35, the detection result of the YOLOv3 model can achieve 94.2% of the recall rate and 95.9% of the accuracy.

Keywords: aero engines; lubricating oil abrasive detection; deep learning; YOLOv3 model; SER algorithm

0 引言

航空润滑油主要完成航空发动机轴承和齿轮的润滑, 保障航空发动机的正常运转。如果轴承得不到充足的润滑, 机械间的摩擦会加大, 温度升高, 摩擦热量会使摩擦面上出现变形和摩擦显微焊合、乃至局部融化等状况, 这些焊

点随之又会在旋转作用下被撕裂。轴承部件之间粘着一撕裂一粘着的状态持续到最后, 会导致轴承丧失旋转能力, 最终卡死抱轴, 发动机停车^[1]。

目前, 航空发动机滑油磨粒检测方法主要分为离线和在线检测。离线检测的过程为先采集样本, 然后对其分类,

收稿日期: 2021-09-24; 修回日期: 2021-11-09。

基金项目: 校级科研立项项目(2020KY0204)。

作者简介: 侯媛媛(1986-), 女, 山西晋中人, 博士, 讲师, 主要从事人工智能深度学习领域方向的研究。

李江红(1970-), 男, 甘肃天水人, 硕士, 副教授, 主要从事图像处理、嵌入式领域方向的研究。

引用格式: 侯媛媛, 李江红, 薛军印. 基于深度学习的航空发动机滑油磨粒检测研究[J]. 计算机测量与控制, 2022, 30(4): 14-22, 127.

最后用一些传统的方法如扫描电镜^[2]、铁谱分析^[3]对样本进行分析。这种方式检测精度高,但耗时长,只能对发动机当前状态进行评估,不能及时对故障进行排查和预防。

在线检测方法较多,国外主要集中在声、光、电、能量等方面。相对于国外国内起步较晚,主要是一些方法的创新和加工工艺的研究。近年来随着深度学习在模式识别领域的应用与发展,相关人员也逐渐对神经网络在滑油磨粒检测过程中的应用进行探索和研究。申江江等人^[4]利用RBF神经网络,提取滑油磨粒光谱检测数据的状态特征,根据滑油中各金属元素浓度的变化趋势,分析发动机的磨损状态,实现了发动机磨损故障及故障部位的诊断分类。鲜倪军等人^[5]提出了一种基于ABC-BP神经网络的发动机磨损故障诊断模型,提取滑油磨屑特征参数和铁谱数据的状态特征,该模型收敛速度快,诊断精度高,可有效识别发动机磨损类别。陈庆贵等人^[6]将BP神经网络和RBF神经网络应用于发动机滑油金属元素含量的预测中,取得了较好的预测效果。刘加卫等人^[7]将极限学习机应用于滑油铁谱磨粒图像的分类识别中,识别5种磨粒的彩色图像特征,诊断准确率高达96%。王涛等人^[8]提出基于深度学习的ECT滑油检测技术,其设计的滑油状态诊断模型可自动提取滑油检测数据的状态特征。在线检测方式速度较快^[9],但检测设备相对复杂,存在由设备导致检测精度偏低的现象^[10],且局限性较强,对一些非铁磁性磨粒无法检测。

本文通过计算机视觉进行图像采集和深度学习的方法对磨粒进行测试,属于在线检测的一种。检测设备和检测方法上均有所突破,整个设备小巧便携,通过图像采集能够对大部分磨粒进行检测。采用YOLOv3^[11]模型对磨粒进行测试加快了测试速度,使用图像增强和消融试验优化方法提升了其测试精度。最后针对模型误检率偏高的问题,设计SER算法来优化模型的推理置信度阈值,提升了磨粒检测的召回率和精准度。

1 滑油图像数据采集与标定

相对于传统计算机视觉算法,深度学习模型在数据量充分且标记精确的数据集下,模型具有更高的精度和泛化性。因此基于航空发动机磨损机理^[12],从发动机工时和飞机批次两个角度对滑油样品联合采样;针对传统检测方法检测尺度小、无法对非铁磁性磨粒检测等缺点,对油料加注组件和成像元件选型,通过对流动速度和压力分布云图仿真^[13],提出连续流微流控芯片滑油图像采样方法,搭建滑油图像采集系统;采取分层采样方法抽取2 000张4 608×3 288像素滑油图像,最后基于数据初次标注和数据回滚标注,构造滑油磨粒数据集。

1.1 滑油样品联合采样

航空发动机不同工作时间内,滑油磨粒数量和形状均不同。本实验采集的滑油样品来自XX发动机。前50小时即前期磨损阶段,磨损率较高,发动机工作50小时后,旧滑油被新滑油替代,发动机工作50~500小时期间,发动机磨损进入平稳期,磨损率处于较低水平,随着时间推移磨

损率逐渐升高。对于相同型号的发动机,即使在相同时间段,因服役的飞机型号、飞行方式以及地点等一些因素的影响,滑油磨粒的浓度、尺寸和形态均存在差异^[14]。为了保证采样的滑油样品具有泛化性和代表性,从发动机运行工时和飞机批次两个角度对XX发动机滑油联合采样。

同一批次飞机发动机运行工时通常分布在某一时间段,因此对于多个批次的飞机进行采样能够满足发动机不同运行工时的要求。本实验共收集了6种飞机批次的滑油样品,分别记作为60、61、62、63、64和65,采样的滑油样品在不同工时段和不同批次的瓶数分布如表1所示。

表1 联合采样收集到的滑油样本分布

	60	61	62	63	64	65
0~50 h	0	8	7	8	13	3
50~250 h	6	22	8	4	15	21
250~500 h	25	16	1	0	1	27

1.2 滑油图像数据采集系统

滑油磨粒图像采样系统主要包括油料加注组件、成像元件、连续流微流控芯片3个部分,如图1所示。连续流微流控芯片主要保证滑油采样区域的流动稳定性和连续性。滑油图像采样系统采用的相机为维数数字图像技术有限公司的MV-EM1400C相机,为小尺寸以太网的1 400万像素工业相机镜头,相机采集到4 608×3 288像素滑油图像,高分辨率的滑油图像保证了采集到的滑油图像有更多的磨粒信息,同时1.4 μm的像元保证了实际物理距离够小,小尺度磨粒有更多的像素面积。相机7FPS的采样帧率,保证了较快的成像,磨粒的流动阴影较少,且能在短时间内采集到较多的滑油图像。相机采用大型数据包传输和更加稳定和通用的千兆以太网络进行传输,减少对中断的处理,保证了稳定的数据传输,加快了传输速度,满足峰值传输速度315 MB/s。相机和镜头提供足够大的放大倍数和更少的光畸变,保证能够清晰分辨5 μm以上的磨粒。

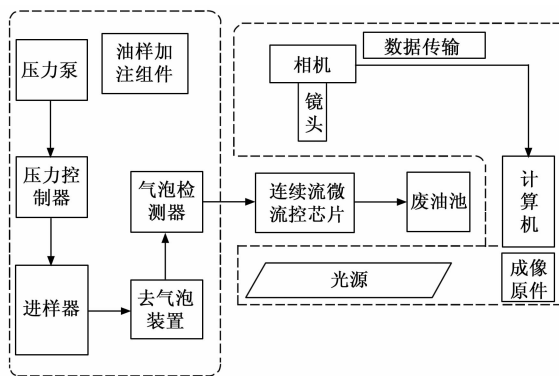


图1 滑油图像采集系统

基于以上采样方法,搭建滑油图像采集系统。图2为采集系统采到的滑油样例局部放大图,其中图(a)~(d)分别为较充足的光照下,对不同滑油样品采集后的滑油图像样例局部图。由图可知基于工时以及飞机批次联合采样

的滑油样品，通过本系统的采集，滑油图像光照、背景、磨粒尺寸和形态信息均比较充分，能够反映滑油油液的微观表现，搭建的采样系统解决了 5 μm 以上的磨粒采集问题。




图 2 未标记滑油图像数据库样例

1.3 滑油磨粒数据集构造

基于滑油图像数据采集系统，对滑油样品进行采样，每瓶样本采样 30~40 张图像，一共收集 5 358 张未标记的滑油图像。在深度学习目标检测领域，PASCAL VOC 数据集和 MS-COCO 数据集为最常用的两个数据集，标注格式分别为 VOC 和 COCO。

VOC 格式生成 XML 文件，文件采用树状结构记录数据，占用空间较多，结构复杂，但可扩展性强且方便查看。COCO 格式生成 JSON 文件，文件存储了标注数据结构，占用空间少，相同信息能够复用，方便机器识别和读取，同时数据结构简明，记录方式简单。因此在滑油图像标注阶段，数据集标注采用 VOC 格式，标注完后，转为 COCO 格式进行训练。

针对于滑油磨粒数据集，统计磨粒的标注信息，数据集共有 23.8 万个磨粒目标框，平均每张滑油图像存在 119 个标注。随机选择标定后的 2 000 张图像作为滑油磨粒数据集，采用 8 : 2 比例从滑油磨粒数据集中抽取 1 600 张图像作为滑油磨粒训练集，剩余 400 张作为滑油磨粒测试集。

2 基准模型训练研究

由于一阶段网络和二阶段网络特征提取方法不同，为了在滑油磨粒数据集上表现出优异的卷积神经网络模型，选则一阶段 YOLOv3 模型^[15]和二阶段 Faster RCNN 模型^[16]作为滑油磨粒检测基准模型。分别对一阶段 YOLOv3 模型和二阶段 Faster RCNN 模型进行训练研究。

2.1 基准模型训练

通过 BP 算法^[17]对网络参数进行优化，使模型在滑油磨粒训练集上具有滑油磨粒检测能力。对于定义好的网络结构 $f(\theta)$ ，损失函数 L ，学习率 l_r ，滑油磨粒训练数据集 $X\{x_1,$

$x_2, \dots, x_n\}$ 及其对应的滑油磨粒标记 $Y\{y_1, y_2, \dots, y_n\}$ 进行训练，流程如图 3 所示。主要包括 5 个步骤：

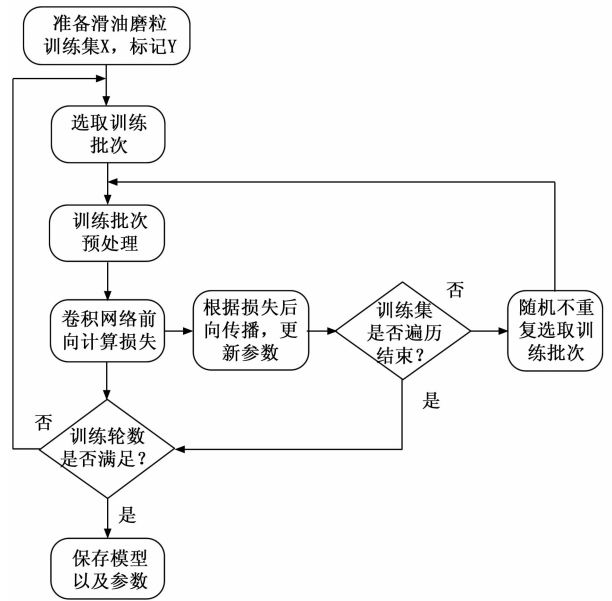


图 3 滑油磨粒检测任务的训练过程

1) 随机不重复从滑油磨粒训练集 X 中选取一个训练批次 $X_1\{x_a, \dots, x_b\}$ 以及对应标记 $Y_1\{y_a, \dots, y_b\}$ 。

2) 对训练批次 $X_1\{x_a, \dots, x_b\}$ 和对应标记 $Y_1\{y_a, \dots, y_b\}$ 进行归一化预处理操作。

为了使模型的寻优过程平缓，更容易收敛到最优解空间，需要对训练批次进行归一化^[18]。对于训练批次每张滑油图像的每个 RGB 像素值进行如式 (1) 的归一化操作：

$$\begin{aligned} r' &= \frac{r - \mu_r}{\sqrt{\sigma_r}} \\ g' &= \frac{g - \mu_g}{\sqrt{\sigma_g}} \\ b' &= \frac{b - \mu_b}{\sqrt{\sigma_b}} \end{aligned} \quad (1)$$

式中， μ_r, μ_g, μ_b 为设定的归一化 RGB 均值； $\sigma_r, \sigma_g, \sigma_b$ 为设定的归一化 RGB 方差； r, g, b 为未归一化前的 RGB 像素值； r', g', b' 为归一化后的 RGB 像素值。

3) 根据训练批次的输入 X_1 ，经过卷积神经网络计算得到 \tilde{Y}_1 ，如式 (2)，与其对应标记 Y_1 。通过损失函数 L 计算损失 l_1 ，如式 (3)：

$$\tilde{Y}_1 = f(\theta, X_1) \quad (2)$$

$$l_1 = L(Y_1, \tilde{Y}_1) \quad (3)$$

YOLOv3 模型的损失函数如式 (4) 所示：

$$\begin{aligned} L_{YOLOv3} &= \lambda_{box} \sum_{i=0}^{N_x \times N_y} \sum_{j=0}^3 1_{ij}^{obj} [(t_x - t'_x)^2 + (t_y - t'_y)^2] + \\ &\lambda_{box} \sum_{i=0}^{N_x \times N_y} \sum_{j=0}^3 1_{ij}^{obj} [(t_w - t'_w)^2 + (t_h - t'_h)^2] - \\ &\lambda_{obj} \sum_{i=0}^{N_x \times N_y} \sum_{j=0}^3 1_{ij}^{obj} \log(c_{ij}) - \lambda_{nobj} \sum_{i=0}^{N_x \times N_y} \sum_{j=0}^3 1_{ij}^{nobj} \log(1 - c_{ij}) - \end{aligned}$$

$$\sum_{c \in \text{classes}} [\lambda_{\text{class}} \sum_{i=0}^{N_i \times N_i} \sum_{j=0}^3 1_{ij}^{obj} \log(p'_{ij}(c)) + (1 - p'_{ij}(c)) \log(1 - p_{ij}(c))] \quad (4)$$

式中, t_x, t_y, t_w, t_h 分别为磨粒标记目标框与锚点的偏移值; t'_x, t'_y, t'_w, t'_h 分别为预测的磨粒目标框与锚点的偏移值; $\lambda_{\text{box}}, \lambda_{\text{obj}}, \lambda_{\text{noobj}}, \lambda_{\text{class}}$ 分别为目标框、正类、负类、分类损失权重; 1_{ij}^{obj} 为正类输出 1, 负类输出 0; 1_{ij}^{noobj} 为负类输出 1, 正类输出 0; $p_{ij}(c), p'_{ij}(c)$ 分别为标注、预测的磨粒类别概率。

Faster RCNN 模型的损失函数如式 (5) 所示:

$$L_{\text{FasterRCNN}} = \frac{1}{N_{\text{cls}}} \sum_i \text{softmax}(p_i, p'_i) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p'_i \text{Smoothl1}(t_i, t'_i) \quad (5)$$

式中, t_i, t'_i 分别为 t_x, t_y, t_w, t_h 和 t'_x, t'_y, t'_w, t'_h 的集合; $N_{\text{cls}}, N_{\text{reg}}$ 分别为正样本和负样本预测框的数量; λ 为平衡正样本损失和负样本损失的权重; $\text{softmax}, \text{smoothl1}$ —— $\text{softmax}, \text{smoothl1}$ 的损失函数。

为使损失函数小目标磨粒损失占比更多, 对小目标磨粒进行优化, t_x, t_y, t_w, t_h 和 t'_x, t'_y, t'_w, t'_h 分别采用式 (6)、(7) 来优化真实的磨粒目标框、预测磨粒目标框相对于锚点的偏移量。

$$\begin{aligned} t_x &= \frac{(x - x_a)}{w_a} \\ t_y &= \frac{(y - y_a)}{h_a} \\ t_w &= \log\left(\frac{w}{w_a}\right) \\ t_h &= \log\left(\frac{h}{h_a}\right) \end{aligned} \quad (6)$$

式中, x, y, w, h 分别为真实磨粒框的中心横纵坐标、宽度、高度; x_a, y_a, w_a, h_a 分别为锚点的中心横纵坐标、宽度、高度;

$$\begin{aligned} t'_x &= \frac{(x' - x_a)}{w_a} \\ t'_y &= \frac{(y' - y_a)}{h_a} \\ t'_w &= \log\left(\frac{w'}{w_a}\right) \\ t'_h &= \log\left(\frac{h'}{h_a}\right) \end{aligned} \quad (7)$$

式中, x', y', w', h' 分别为预测磨粒框的中心横纵坐标、宽度、高度。

4) 依据 l_1 进行网络的反向传播, 更新卷积神经网络参数 θ , 如式 (8) 所示:

$$\theta' = \theta - lr \times \nabla g(l_1) \quad (8)$$

5) 判断滑油磨粒训练集是否遍历结束, 若训练集未遍历结束, 重复前 3 步, 若训练集遍历结束, 则判断训练轮数是否达到设定值。

6) 训练轮数若未达到设定值, 开始新一轮训练, 重复前 4 步, 若达到设定值, 则保存模型以及参数, 结束模型训练。

2.2 基准模型训练试验

基于以上训练流程, 兼顾测试精度和测试速度性能指标, 搭建滑油磨粒训练环境。测试中使用 4 张 11 GB 内存的 2080Ti 显卡和 AMD 3960X CPU, 多 GPU 高内存吞吐和多核性能保证模型的训练时间。64 GB 的内存保证图像数据预处理阶段有足够的空间缓存中间结果, 不会因为空间不足导致线程堵塞。

软件环境如表 2 所示。模型训练的软件环境为 Ubuntu、Python、Pytorch、MMDetection 等。MMDetection 作为 Python 编译器和 Pytorch 库目标检测模型训练框架, 集成了很多目标检测模型, 提供丰富 API 接口, 方便对模型进行改进训练。因此选用 MMDetection 作为 YOLOv3 模型和 Faster RCNN 模型的训练框架, 根据 API 接口完成骨干网络、输入数据格式、训练参数设置和数据增强方法的调试和代码编写。

表 2 模型训练软件环境

软件	版本
系统	Ubuntu 16.04
编程语言	Python 3.6
模型训练框架	Pytorch 1.5
目标检测框架	MMDetection 2.5.0

Faster RCNN、YOLOv3 模型训练相关参数如表 3 所示。为了保证 Faster RCNN 和 YOLOv3 模型的精度和速度, 骨干网络分别采用了 ResNet50 和 DarkNet53。为加速模型的收敛速度且保证模型不陷入局部最优解, 两个基准模型的优化器均选用 SGDM。为了使初始训练梯度保持稳定且网络更容易收敛, 两模型均采用带学习率预热的阶梯学习率策略, 预热后初始学习率分别为 0.002 和 0.02。由于一阶段的卷积神经网络需要更多轮数的训练, 所以 YOLOv3 模型的训练轮数设置为 300 轮, Faster RCNN 模型的训练轮数为 20 轮。

表 3 模型训练相关参数

	Faster RCNN	YOLOv3
骨干网络	ResNet50	DarkNet53
锚点	3 个	9 个
数据集格式	COCO	COCO
Batchsize	16	32
翻转	True	True
训练轮数	20	300
优化器	SGDM	SGDM
学习率	0.02	0.002

训练结束后, 分别对 Faster RCNN 和 YOLOv3 模型进行损失分析。图 4 为两种模型的损失随迭代次数的变化关系。随着迭代次数的递增, 两个模型的损失呈下降趋势,

且在学习率下调的时候, 损失下降最大。在训练迭代次数最后, 损失在横向振荡, 证明两个模型均已训练完成。

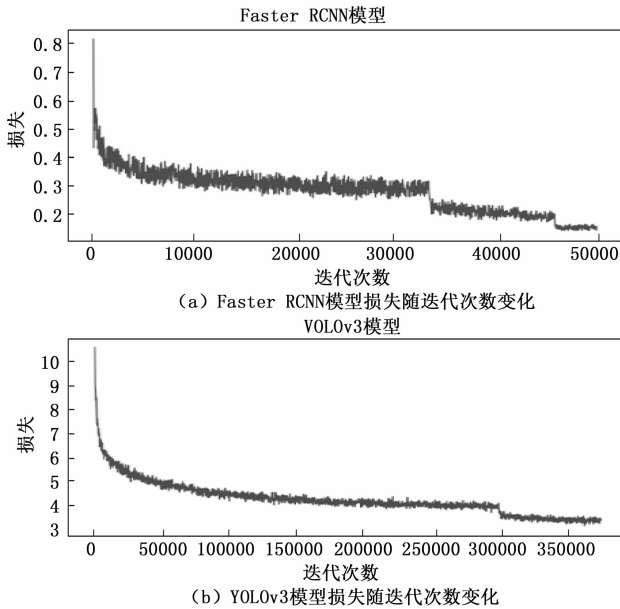


图 4 模型损失随迭代次数变化趋势图

3 基准模型测试研究

3.1 基准模型测试

经过模型训练得到优化卷积神经网络模型, 需要对卷积神经网络进行测试以验证模型效果, 使用的评价指标有: 交并比 (IOU, intersection over union)、召回率 (recall) 和精确率 (precision)、均值平均精度 (mAP, mean average precision,) 和每秒帧数 (FPS, frames per second)。

对于以上指标, 若模型均达标, 则模型训练验证完成, 若未达到预计的性能, 则对卷积神经网络模型结构及参数进行调整, 重新进行训练。滑油磨粒检测任务的测试流程如图 5 所示。

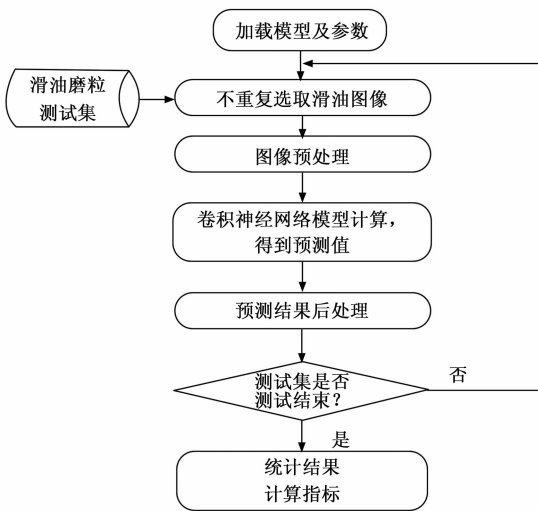


图 5 滑油磨粒检测任务的测试流程

具体步骤如下:

- 1) 加载训练后的卷积神经网络模型及参数。
- 2) 从滑油磨粒测试集 T 中不重复选取滑油图像, 进行归一化预处理操作。
- 3) 预处理结束的滑油图像数据送入到训练后的卷积神经网络中, 得到初步预测结果。
- 4) 为去掉大量的误检磨粒框, 采用 0.05 的置信度进行过滤。对于过滤后的预测结果采用 NMS 方法去除同一磨粒的低置信度磨粒框, 得到 NMS 之后的处理结果, 即为最终的预测结果。
- 5) 判断测试集是否测试结束, 若未结束, 重复步骤 2) ~4), 若结束, 统计测试集的结果, 并计算相关指标。

3.2 基准模型测试结果

Faster RCNN、YOLOv3 基准模型在滑油磨粒测试集上的结果如表所示。Faster RCNN、YOLOv3 测试集上表现较好, 两者 mAP 相差不大, 均在大滑油磨粒的检测上较为优秀, 其中大滑油磨粒的平均精度用 APL 表示, 分别达到了 90.5% 和 89.9%; 在小滑油磨粒的检测上有改进空间, 小滑油磨粒的平均精度用 APS 表示, 分别为 72.1% 和 69.3%; 中等大小物体检测相对较好, 中等滑油磨粒的平均精度用 APM 表示, 分别为 85.2% 和 83.5%。在 IOU 判定阈值为 0.75, YOLOv3 模型的 AP75 (表示判定阈值为 0.75 的平均精度) 比 Faster RCNN 模型差 1.2%; 在 IOU 判定阈值为 0.5 时, YOLOv3 较 Faster RCNN 模型的 AP50 表现差距较小, 相差 0.9%, 试验结果表明在基准模型测试中, 两模型都达到了较好的效果, Faster RCNN 模型的精度高于 YOLOv3 模型。但 YOLOv3 的推理速度比 Faster RCNN 的推理速度高 5.9 FPS。在测试速度上, YOLOv3 模型占绝对优势。因此, 下文重点采用一些优化算法来保证测试速度的基础上提升模型的测试精度。

表 4 基准模型测试结果

	Faster RCNN	YOLOv3
mAP/%	83.3	81.9
AP50/%	91.3	90.4
AP75/%	85.5	84.3
APS/%	72.1	69.3
APM/%	85.2	83.5
APL/%	90.5	89.8
FPS(800×800)	19.4	25.3

4 滑油磨粒检测优化方法

4.1 滑油图像增强方法

在滑油磨粒检测基准模型训练阶段, 两模型均使用了基础数据增强方法, 即翻转和多尺度。为了提升模型整体性能, 对于滑油磨粒数据集, 除了翻转和多尺度外, 还可采用旋转、Mixup、CutMix 和 Mosaic 方法进行测试。

旋转: 转动滑油图像, 进行数据扩增。本实验数据集不包含掩码标记, 只存在目标框, 所以不可能实现任意角

度的旋转, 因此旋转角度为有限角度, 分别为 0° 、 90° 、 180° 和 270° 。

从图 6 中可以看出仅通过简单的旋转, 一个原始滑油图像可以生成 3 个新的滑油图像。




图 6 旋转增强后图片

Mixup^[19]: 使用线性插值方法得到新样本, 从滑油磨粒训练集中随机抽取两个样本进行简单随机加权求和, 同时滑油磨粒标签也对应加权求和, 然后预测结果与加权求和之后的标签求损失, 再反向求导更新网络参数。该方法可以降低模型对已损坏标签的记忆, 增强模型对抗样本的鲁棒性和训练生成对抗网络的稳定性。

CutMix^[20]: 随机选取两个滑油图像, 如图 7 (a) 与图 7 (b), 对于图 (a) 随机生成一个裁剪框, 裁剪图 (a) 相应位置, 然后用图 (b) 片相应大小区域放到图 (a) 中被裁剪的区域构成新的滑油图像, 计算损失, 同样采用加权求和的方式进行求解。




图 7 Mixup 操作生成的新图片

图 8 为图 7 中 (a) 与 (b) 经过 CutMix 操作生成的新图片。图 8 中 (a) 图的一部分区域被裁剪, 使用图 (b) 的对应区域进行填充。由于两个图片背景信息不同, 导致 CutMix 在融合之后, 会出现局部背景突变情况。不同背景磨粒在扩充数据集的基础上, 可以使深度学习模型学到更多组合信息, 改善模型的泛化性能。

Mosaic: 融合 4 张不同滑油训练图像数据。Mosaic 增




图 8 CutMix 操作生成的新图片

强方法使得检测模型可以检测到上下文之外的对象, 同时 BN 计算了 4 个不同滑油图像激活之后的统计量, 缓解了小批次下 BN 对检测精度的影响。

图 9 为 4 张滑油图像进行 Mosaic 增强操作生成的新图片, 新图保留原始图片的局部信息。相较于 Mixup 与 CutMix, Mosaic 增强操作生成的滑油图像更加多样化, 拥有更复杂的样本组合, 同时减少了 BN 归一化计算的偏差。Mosaic 方法使得深度学习模型能够学到更多的样本信息, 提高模型了的泛化能力。




图 9 Mosaic 操作生成的图片

4.2 滑油图像数据增强消融试验

通过组合以上 4 种方法, 得到 7 种不同方案, 分别为旋转、Mixup、CutMix、Mosaic、旋转+Mixup+Mosaic、旋转+CutMix+Mosaic、旋转+Mixup+CutMix+Mosaic。前 4 种为单图像数据增强方案, 后 3 种为多图像数据增强融合方案。

单图像数据增强方案具体步骤如下:

- 1) 从滑油磨粒训练集中加载滑油图像。
- 2) 依据 $0 \sim 1$ 区间分布随机概率值 P 。

3) 判断 P 是否大于 0.5, 若 $P > 0.5$, 则进行单数据增强操作。若为第 1 种方案, 则以 0° 、 90° 、 180° 、 270° 等概率随机旋转滑油图像; 若为第 2 种方案, 则进行 Mixup 操作; 若为第 3 种方案, 则进行 CutMix 操作, 若为第 4 种方案, 则进行 Mosaic 操作。

4) 若 P 小于等于 0.5 或完成单数据增强操作, 直接输出结果。

第 5 种 (第 6、7 种方法一致) 数据增强融合方案具体步骤如下:

- 1) 从滑油磨粒训练集中加载滑油图像。

2) 依据 $0 \sim 1$ 区间分布随机概率值 P_1 。判断 P_1 是否大于 0.5, 若 $P_1 > 0.5$, 则以 0° 、 90° 、 180° 、 270° 等概率随机旋转滑油图像。

- 3) 若 $P_1 \leq 0.5$ 或旋转增强结束, 依据 $0 \sim 1$ 区间分布

随机概率值 P_2 。判断 P_2 是否大于 0.5, 若 $P_2 > 0.5$, 则对滑油图像进行 Mixup 操作。

(4) 若 $P_2 \leq 0.5$ 或 Mixup 增强结束, 依据 0~1 区间分布随机概率值 P_3 。判断 P_3 是否大于 0.5, 若 $P_3 > 0.5$, 则对滑油图像进行 Mosaic 操作。

(5) 若 $P_3 \leq 0.5$ 或 Mosaic 增强结束, 输出增强后的滑油图像。

对于上述两个基准模型, 分别进行了 7 个滑油图像数据增强消融试验。从 mAP 损失、召回率及精确率 3 个方面, 对比滑油图像数据增强试验前后的差异。

表 5 Faster RCNN 数据增强消融试验

	mAP/%	AP _s /%	AP _M /%	AP _L /%
基准	83.3	72.1	85.2	90.5
增强 1	84.0	73.0	86.0	90.6
增强 2	83.8	72.8	85.8	90.7
增强 3	83.2	72.0	85.2	90.4
增强 4	84.0	73.0	85.9	90.7
增强 5	84.3	73.5	86.2	91.0
增强 6	84.1	73.2	86.1	90.9
增强 7	84.3	73.4	86.2	91.0

表 6 YOLOv3 数据增强消融试验

	mAP/%	AP _s /%	AP _M /%	AP _L /%
基准	81.9	69.3	83.5	89.8
增强 1	82.6	71.4	84.2	90.2
增强 2	82.5	71.2	84.1	90.2
增强 3	82.2	69.8	83.9	90.0
增强 4	83.3	72.3	84.7	90.6
增强 5	84.4	73.8	85.6	91.1
增强 6	84.3	73.7	85.5	91.1
增强 7	84.8	74.4	86.1	91.3

相较于 Faster RCNN 基准模型测试结果, 对于单个数据增强方法, 旋转和 Mosaic 提升最大, mAP 提升了 0.7%; Mixup 提升次之; CutMix 没有提升; 对于图像数据增强组合方案, 第 5、7 种组合方案提升最大, mAP 达到了 84.3%, 提升 1.0%; 第 6 种组合方案较第 5 种、第 7 种提升较少。因此对于 Faster RCNN 模型, 最佳的数据增强方案为第 5 种, 即旋转+Mixup+Mosaic 组合方案。

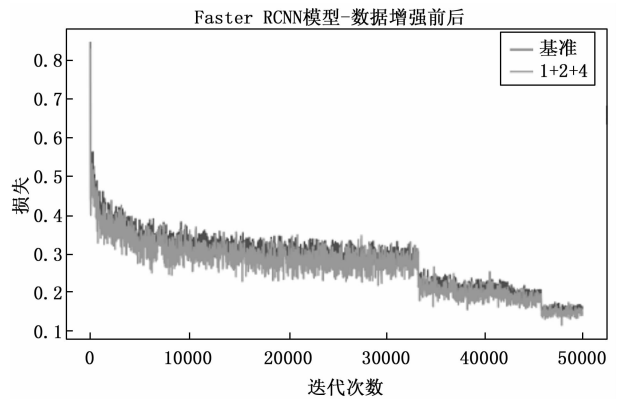
相较于 YOLOv3 基准模型的测试结果, 单个图像数据增强方法均取得了正向收益, 其中 Mosaic 提升最大, mAP 提升 1.4%, 旋转、Mixup、CutMix 增强方法提升依次降低, 分别是 0.7%、0.6%和 0.3%。对于图像数据增强组合方案, 第 5 种、第 6 种组合方案提升几乎一致, mAP 指标分别提升 2.5%和 2.4%; 第 7 套方案提升最高, mAP 提升 2.9%。因此对于 YOLOv3 模型, 旋转+Mixup+CutMix+Mosaic 图像数据增强方案提升最高。

相较于一阶段 YOLOv3 模型, 因为二阶段 Faster RCNN 模型存在 RPN 层以及采样机制, Faster RCNN 基准模型已经取得了较好的泛化效果。因此二阶段模型 Faster RC-

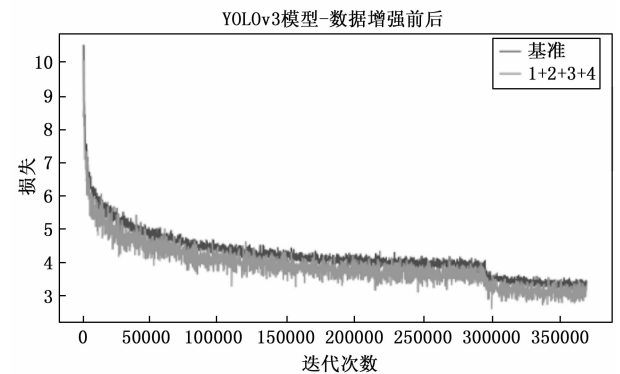
NN 模型在最佳图像数据组合方案上仅获得 1.0%的 mAP 提升, 而一阶段 YOLOv3 在最佳图像数据组合方案可获得 2.9%的 mAP 的提升。

结果表明通过上述 7 种滑油图像增强组合方案, 有效地扩增了滑油磨粒数据集, 提高了模型的泛化能力, 扩大模型的表征能力, 使其能够识别更多不同状况下的滑油磨粒; 且经过最佳图像数据组合方案后的 YOLOv3 模型精度高于 Faster RCNN 模型。

数据增强前后两模型随迭代次数模型损失对比图如图 10 所示。由图可知, 最佳图像数据增强后的两个模型损失均比基准模型的损失低, 且收敛于更低的损失值, 收敛性更佳。



(a) 数据增强前后的Faster RCNN模型损失



(b) 数据增强前后的YOLOv3模型损失

图 10 数据增强前后模型损失对比图

通过滑油磨粒测试集计算得到两个模型在不同 IOU 判定阈值下的召回率 (Recall) 以及精确率 (Precision), 如表 7 所示。

表 7 两模型数据增强后的召回率及精确率

模型	召回率/%	精确率/%
Faster RCNN(IOU 0.5)	91.5	53.2
YOLOv3(IOU 0.5)	93.2	46.7
Faster RCNN(IOU 0.3)	94.7	70.1
YOLOv3(IOU 0.3)	96.5	64.8

无论 IOU 阈值为 0.3 或 0.5, YOLOv3 模型的召回率均高于 Faster RCNN 模型, 但 Faster RCNN 模型的精确率

高于 YOLOv3 模型。在 IOU 阈值为 0.3 时, YOLOv3 模型的召回率和精确率明显提高, 分别达到 96.5% 和 64.8%。YOLOv3 的召回率已经满足工程上的标准, 对于较大部分的磨粒框已经可以正确检测。但是两模型的精确率均较低, 分别为 70.1% 和 64.8%, 均产生了过多的误检磨粒框, 因此需要进一步对误检磨粒框进行剔除, 才能达到工程实用的标准。

4.3 SER 算法

通过以上实验可知, 最佳图像数据组合方案后的 YOLOv3 模型精度和速度都优于 Faster RCNN 模型。但数据增强后的 YOLOv3 模型, 在 0.05 置信度阈值下, 模型的召回率和精确率分别为 96.5% 和 64.8%。64.8% 的精确率过低, 不能满足工程应用, 存在大量的误检磨粒框。基于此本文提出用综合错误比例 (SER, synthesize error ratio) 算法来优化 YOLOv3 模型的推理置信度, 目的是保留较多正确磨粒框的同时滤掉更多的误检磨粒框。

图 11 为滑油图像在 0.05 置信度阈值情况下预测样例图, 由图可知存在磨粒误检现象。因此要优化滑油磨粒检测模型召回率和精确率, 保证在模型推理阶段, 降低滑油磨粒检测模型误检的同时保留更多正确的磨粒目标框。




图 11 置信度阈值为 0.05 时的滑油图像预测样例

不同置信度下 YOLOv3 模型的召回率与精确率关系变化如图 12 所示。由图 12 可知, 随着置信度的降低, 召回率升高, 精确率降低, 反之亦然。滑油磨粒检测模型的置信度降低, 引入了较多的误检磨粒目标框, 使得精确率降低, 但同时扩大了预测框的置信度范围, 较低置信度下预测正

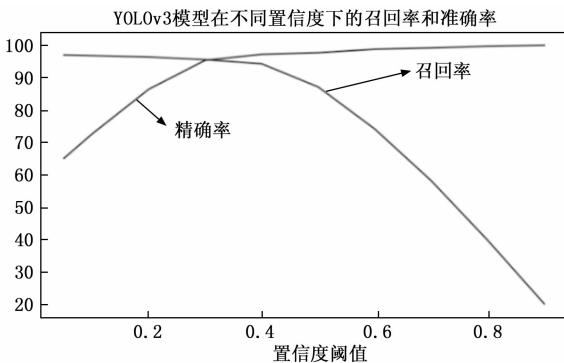


图 12 YOLOv3 模型不同置信度下的召回率和精确率

确的磨粒目标框被计入, 提高了召回率。因此在滑油磨粒检测任务阶段, 需要寻找一个合理的置信度阈值, 以优化召回率和精确率, 得到一个权衡的数值用于推理。

本文提出了 SER 算法, 以优化模型推理时的召回率和精确率, 如表 8 所示。对于滑油磨粒测试集 $T(t_1, t_2, \dots, t_m)$, 存在 N 个已标定的磨粒目标框 $B_T(b_1, b_2, \dots, b_n)$, 依次对滑油磨粒测试集使用 YOLOv3 模型进行推理, 汇总推理后的目标框, 将滑油磨粒测试集的所有磨粒预测框随置信度倒序排列, 记为集合 $\bar{B}_T(b_1, b_2, \dots, b_n)$, 每个预测框对应的置信度标记为 $\bar{C}_T(c_1, c_2, \dots, c_n)$ 。

表 8 SER 算法

算法: Synthesize error ratio
输入: 测试集 $T(t_1, t_2, \dots, t_m)$, 置信度倒序排列目标框集合为 $\bar{B}_T(b_1, b_2, \dots, b_n)$ 及置信度 $\bar{C}_T(c_1, c_2, \dots, c_n), i = 0$
输出: 最小 SER 值对应的置信度 C_{er}
步骤 1: 生成长度为 n 的空列表 $\bar{R}_T(r_1, r_2, \dots, r_n)$ 和 $SER(SER_1, SER_2, \dots, SER_n)$;
步骤 2: 对 \bar{B}_T 和 \bar{C}_T 从开始到结尾进行遍历, 选取 b_i 和 c_i ;
步骤 3: 根据目标框与预测框的 IOU 判别是否预测正确 如果预测正确: = 1 如果预测错误: = 0
步骤 4: 根据下式分别计算当前的召回率 $Recall_i$ 以及精确度 $Precision_i$:
$Recall_i = \frac{\sum(\bar{R}_T)}{N}$
$Precision_i = \frac{\sum(\bar{R}_T)}{i}$
步骤 5: 根据下式计算当前的 SER_i :
$SER_i = \frac{((1 - Recall_i) \times N + (1 - Precision_i) \times n)}{N}$
步骤 6: 判断是否遍历结束, 若未结束, $i++$, 重复步骤 2~5 直至结束。
步骤 7: 寻找 SER 序列的最低值的索引: $Min_index = find_index(SER, min(SER))$
步骤 8: 查找 Min_index 对应的置信度阈值: $C_{er} = \bar{C}_T[Min_index]$

对于滑油磨粒测试集, 采用 SER 算法, 寻找各个置信度下的 SER 值, 最小 SER 值对应置信度即为经模型召回率和精确率优化后的最佳的置信度阈值。

对 SER_i 的计算公式进行分解, 如式 (9) 所示, $1 - Recall_i$ 的实际意义为置信度为 c_i 时, 模型漏检的磨粒目标框占真实目标框的比率, $(1 - Precision_i) \times \frac{i}{N}$ 的实际意义为置信度为 c_i 时, 模型误检的磨粒目标框占真实目标框的比率。联立式 (9) 和式 (10), 消去参数 i 和 N , 结果如式 (11) 所示。由式 (11) 可知, 确定一个置信度后, 进而得到召回率和精确率, 即可得到当前置信度下的 SER 值。求得不同置信度下的 SER 值后, 寻找最小的 SER 值, 即为漏

检和误检磨粒目标框占真实磨粒目标框的最小比率。越小的 SER 值, 说明模型产生漏检和误检磨粒目标框越少, 模型效果越好。通过最小 SER 值的索引查找到置信度 C_{ser} , 即当置信度为 C_{ser} 时, YOLOv3 模型漏检和误检磨粒目标框占真实磨粒目标框比率最小, 模型的召回率与精确率最为权衡。

$$SER_i = (1 - Recall_i) + (1 - Precision_i) \times \frac{i}{N} \quad (9)$$

$$Recall_i \times N = Precision_i \times i = \text{sum}(\bar{R}_T) \quad (10)$$

$$SER_i = \frac{Recall_i + Precision_i - 2 \times Precision_i \times Recall_i}{Precision_i} \quad (11)$$

统计 YOLOv3 模型在滑油磨粒测试集上的预测结果, 基于 SER 算法计算不同置信度下 SER 的数值, 且求出最小值。YOLOv3 模型在不同置信度下的 SER 值如图 13 所示, 横坐标 $1-conf$ 为 1-置信度, 纵坐标为 SER 值。随着置信度降低, SER 值先降低后升高, 点 (0.644 5, 0.086 8) 为最佳的 SER 点, 置信度为 0.355 5。

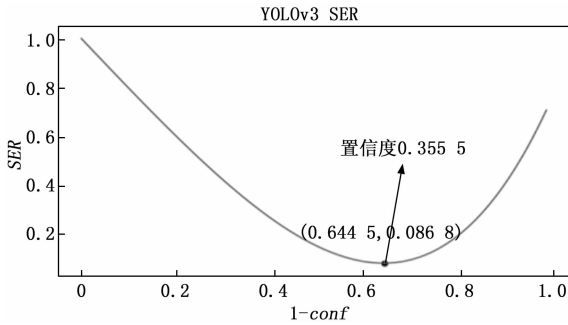


图 13 YOLOv3 模型在不同置信度下 SER 值

当 YOLOv3 模型在置信度为 0.355 5 时, 取得最小的 SER 值 0.086 8, 求得当前置信度下的召回率为 94.2%, 精确度为 95.9%, 误检和漏检的磨粒目标框占真实磨粒目标框的比率为 8.68%。

对滑油磨粒测试集随机抽取局部图像, 进行 SER 算法校验。图 14 为待预测的滑油图像和不同置信度阈值下预测的滑油磨粒图像, 其中 (a) 图为从滑油磨粒测试集抽取的待预测局部滑油图像, (b) 图为置信度为 0.001 时的磨粒预测图像, (c) 图为置信度为 0.05 时的磨粒预测图像, (d) 图为使用 SER 算法的 0.355 5 的置信度的磨粒预测图像。从图中可以看出使用 SER 算法求得置信度之后, YOLOv3 模型有效地去除了低置信度的误检磨粒目标框, 防止采用过高的置信度滤掉预测正确的磨粒目标框。可见 SER 算法有效地优化了 YOLOv3 模型的召回率和精确率。

5 结束语

论文提出了基于深度学习的航空发动机滑油磨粒检测方法, 构造了泛化性能优秀的高质量滑油磨粒数据集, 通过对滑油磨粒基准训练和测试训练, 研究了滑油磨粒检测算法, 基于此算法提出图像增强方法, 进行消融实验, 设




图 14 待预测滑油图像和不同置信度阈值下的预测磨粒图像

计 SER 优化算法有效地保证了 YOLOv3 模型在合理的置信度阈值下, 具有较高的召回率和精确率。本文进行的滑油磨粒在线检测实验局限于实验室环境中, 未能进行现场测试, 今后研究工作的重点是在实际应用环境下测试本文工作的有效性以提高其实用性。此外本实验是通过在 GPU 上部署 YOLOv3 模型对磨粒进行测试的, 由于滑油磨粒在线检测系统需要小功率、小体积的检测设备, 后续可以考虑将模型移植到 AI 芯片上。

参考文献:

- [1] 谷亚南, 陈 岷. 飞机维修时航空发动机滑油系统污染防控措施探析 [J]. 内燃机与配件, 2019 (10): 131-132.
- [2] 姜旭峰, 费逸伟, 李华强, 等. 航空发动机滑油综合检测技术研究 [J]. 润滑与密封, 2005 (2): 110-112.
- [3] 张 鄂. 铁谱技术及其工业应用 [M]. 西安: 西安交通大学出版社, 2001.
- [4] 申江江, 孙中华, 齐银鹏. 基于 RBF 神经网络的发动机磨粒故障分析 [J]. 人工智能及识别技术, 2016, 12 (33): 177-179.
- [5] 鲜倪军. 基于 ABC-BP 神经网络的航空发动机故障诊断方法 [J]. 装备制造技术, 2018 (5): 173-178.
- [6] 陈庆贵, 于光辉, 谢 静, 等. 基于神经网络的航空发动机金属含量预测 [J]. 兵器工程学报, 2019, 40 (12): 150-152.
- [7] 刘加卫, 刘晓卫, 王 崑, 等. 基于极限学习机的铁谱磨粒模式识别 [J]. 润滑与密封, 2019, 44 (6): 72-77.
- [8] 王 涛. 基于深度学习的 ECT 滑油检测技术研究 [D]. 天津: 中国民航大学, 2020.
- [9] 许 琢. 航空发动机滑油金属磨屑在线检测技术研究 [D]. 沈阳: 沈阳航空航天大学, 2016.
- [10] 朱守全. 感应式船舶滑油污染物在线分析技术和装置的研究 [D]. 大连: 大连海事大学, 2017.

(下转第 127 页)