

基于深度学习的油液磨粒智能检测与分割*

任松, 涂歆玥, 朱倩雯, 李眉慷

(重庆大学煤矿灾害动力学与控制国家重点实验室 重庆, 400044)

摘要 针对机械系统磨损状态监测与故障诊断中油液磨粒识别难度大、时间与人力成本高等问题,提出了基于深度学习的油液磨粒智能检测与分割方法。首先,基于滤膜谱片技术制备油液磨粒谱片并采集图像,构建了含6类不同金属磨粒的优质数据集;其次,根据数据集特点与算法优缺点,搭建单阶段实例分割模型YOLACT与两阶段实例分割模型Mask-RCNN对磨粒进行智能检测与分割。实验结果表明:Mask-RCNN模型平均检测精确率为93.8%,召回率为92.7%,适用于磨损颗粒智能分析的精准检测;YOLACT模型平均检测精确率为84.7%,召回率为83.3%,检测速度快,边缘分割精细,适用于磨损颗粒快速检测与智能分割;两种模型均有效提高了油液磨粒的检测效率。

关键词 深度学习;卷积神经网络;分割模型;油液磨粒分析;金属磨粒检测

中图分类号 TH17;TP389.1

引言

在机器设备服役期间,通过设备性能参数的异常掌握设备的故障信息,对保障人员安全和保证生产效益有重大意义^[1]。工程实践表明,油液信号受环境因素干扰小、灵敏度高,在故障形成初期先于振动信号、温度信号被捕捉,能有效识别机器设备的早期磨损工况,为预测设备的未来磨损趋势提供数据基础,因此油液分析技术成为设备磨损监测与诊断的常用手段^[2]。

油液磨粒分析技术^[3-5]是油液分析技术的主要研究方向,通过分析润滑油中携带磨粒的大小、组成、形态特征和密度分布等指标,实现机器设备磨损工况的监测。目前,铁谱分析技术成为研究热点。Hargis等^[6]对一批在正常服役期内的双桨船发动机润滑油样进行直读铁谱分析,以验证油液铁谱分析技术在海洋柴油发动机磨损工况监测中的可行性。吴振峰等^[7]基于磨粒分析技术研制的铁谱分析系统解决了油液润滑零部件的磨损故障诊断与预测问题,并将其应用在航空发动机状态监控和故障诊断中。但是,铁谱分析技术仍存在分析流程复杂耗时、易产生异常磨粒沉积链以及依赖专业人员的经验等问题。任松等^[8]提出了一种基于滤膜谱片技术的油液分析方法,减少了磨粒沉积链的分布,为获取高离

散度的磨粒样本提供了技术支持。

为实现油液磨粒的智能识别与检测,研究人员提出了一系列磨粒智能识别算法。早期磨粒智能识别算法主要通过手动选择磨粒特征编码来区分不同类别磨粒,如基于粒度特征^[9]、颜色、表面纹理与形状属性^[10]等磨粒特征编码,引入模糊神经网络^[11-12]、支持向量机^[13]、BP神经网络^[14]及K-Means聚类^[15]等机器学习算法作为识别工具,以提高模型精度。Peng等^[16]基于多级支持向量数据描述、K-Means聚类算法和支持向量机建立智能识别模型,可在线识别磨损颗粒。Peerawatt^[17]采用颜色聚类技术,使用机器学习算法作为决策工具,将颗粒颜色作为分类标准,以准确区分加热的金属、钢颗粒、深色和红色氧化物以及铜合金。由于传统算法存在较多人工干预和鲁棒性差,其识别精度水平仍然较低。

随着深度学习技术的发展^[18-19],磨粒智能识别从手动选择磨粒特征转变为应用卷积神经网络(convolutional neural network,简称CNN)自动提取磨粒特征,识别精度得到了大幅提升,识别任务也从分类向定位、分割等方向发展。樊红卫等^[20]通过堆栈降噪自编码网络实现磨粒铁谱图像的识别分类,实现了设备磨损工况智能识别,并达到了较高的精准率。杨智宏等^[21]基于Mask R-CNN网络对铁谱磨粒图像进行学习训练,可实现不同种类磨粒的精

* 国家自然科学基金资助项目(52074048,51774057)

收稿日期:2022-04-07;修回日期:2022-09-07

确识别和实例分割,并计算出磨粒的真实尺寸,但由于异常磨粒沉积链的影响,其识别平均精准率只能维持在38.2%,并影响磨粒面积和形状轮廓的提取效果。Peng等^[22]针对离线铁谱图像中疲劳磨粒、氧化物及球形磨粒等3类磨粒之间可能存在的重叠问题,将CNN应用到磨粒的自动识别中,并修正了Inception-v3卷积网络模型,提升了磨粒智能识别的可靠性,但并未拓展到多种类磨粒识别领域。

目前,主流的铁谱分析技术易产生异常磨粒沉积链,对算法模型识别效果有较大影响。此外,油液磨粒类别众多,缺少能对多种油液磨粒实现精确识别与分割的算法。针对以上问题,笔者基于滤膜谱片技术制备油液磨粒谱片,获得离散的油液磨粒样本,构建了包含金属氧化物、球形磨粒等6种常见磨粒的高质量磨损颗粒数据集,并搭建实例分割算法YOLACT与Mask-RCNN,在确保速度与精度的前提下实现磨粒的智能检测与分割。

1 金属磨粒数据集制备

1.1 图像采集

本研究主要基于滤膜谱片技术制备油液磨粒谱片。滤膜谱片技术将油液中的悬浮颗粒沉积于滤膜上,通过显微镜获取油液磨粒的定性与定量信息。为了保证后期获取磨粒信息的准确性,制备过程中对油样采集、密封存储以及制作试样谱片等流程需要严格操作。与传统铁谱技术相比,该技术极大减少了视场中磨粒沉积链分布,保证了视场中分布颗粒的离散程度,避免油液中异常磨粒沉积链对模型检测效果的影响。

滤膜谱片技术制备磨损颗粒全谱片的主要流程如下:首先,将实验油样水浴加热和机械振荡,保证油液中的杂质颗粒呈均匀悬浮状态;其次,取0.5 ml试样用四氯乙烯溶液稀释,将混合液注入滤膜过滤器中来过滤溶液,获取沉积磨损颗粒的滤膜,将滤膜置于干燥清洁的载玻片上,放入烘干箱内烘干;然后,另取一干净的载玻片,通过二甲基甲酰胺溶液将滤膜溶解于该载玻片;最后,烘干载玻片,固定磨损颗粒,获得全谱片。采用该方法制备的谱片,油液中所有悬浮的颗粒均会沉积,包括各类金属磨粒、油液氧化变质产物以及机械系统使用过程中从外界混入的其余污染物,谱片视场中磨粒分布的实际离散程

度主要受油液单位体积内悬浮颗粒的数量影响。

利用双光源显微镜获取磨损颗粒的特征信息,完成金属磨粒图像的采集。笔者根据油液磨粒的常见种类与磨损机理,将金属氧化物、球形磨粒、切削磨粒、滚滑复合磨粒、疲劳磨粒和严重滑动磨粒等6种常见磨粒作为主要研究对象,针对不同光源下磨损图谱的特征,在显微镜视野下按照不同尺寸逐个提取金属磨粒图像。典型金属磨粒的形貌特征及产生原因如表1所示。磨粒样本图像如图1所示。

表1 典型金属磨粒的形貌特征及产生原因

Tab.1 Morphological characteristics and causes of typical metal wear debris

磨粒类型	磨损机理	磨粒形态特征
金属氧化物	腐蚀磨损	粒状、扁平片状,边缘轮廓粗糙,多呈红褐色堆积分布
球形磨粒	滚动疲劳磨损	圆形,表面光滑,边界暗淡,中心处高亮
切削磨粒	磨料磨损	多为长且窄的条状、月牙状
严重滑动磨粒	黏着磨损	块状体,边缘轮廓清晰且平直,表面粗糙,有平行滑痕、开裂迹象
滚滑复合磨粒	黏着-疲劳磨损	较厚块状体,形状不规则,表面严重拉毛且有清晰擦痕
疲劳磨粒	滚动疲劳磨损	块状或片状,形状不规则,表面粗糙,带有坑孔、褶皱等缺陷

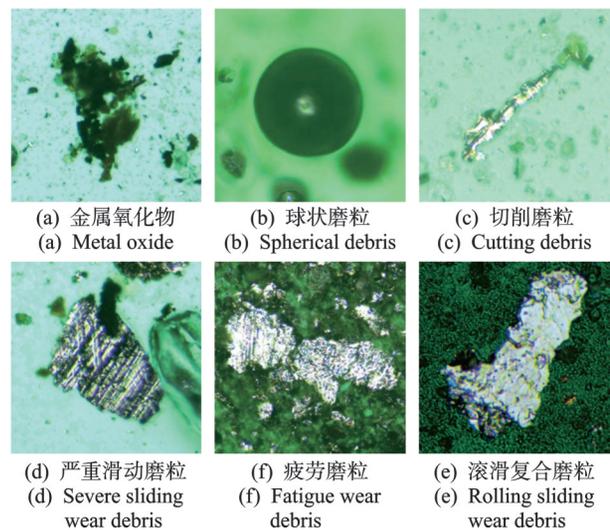


图1 磨粒样本图像

Fig.1 Sample of wear debris image

1.2 数据集构建

深度学习模型需要大量的图像数据进行学习,构建数据集是开展目标检测的关键任务。笔者通过对原始采集图像进行筛选裁剪、数据增强,共获得941张数据样本。基于计算机算力,硬件数据样本经裁剪压缩为 256×256 分辨率。搭建的数据集使用开源标注软件Labelme进行标注,软件界面如图2所示。采集的数据样本经过人工标注,转换生成成为模型可输入的json数据格式。为验证模型识别效果,按9:1比例划分训练集与测试集。磨粒数据集分布情况如表2所示。

表2 磨粒数据集分布情况

Tab.2 Distribution of typical metal wear debris

集合类型	金属氧化物	球状磨粒	切削磨粒	严重滑动磨粒	滚滑复合磨粒	疲劳磨粒
训练集	110	80	150	144	156	181
测试集	11	7	12	23	26	17

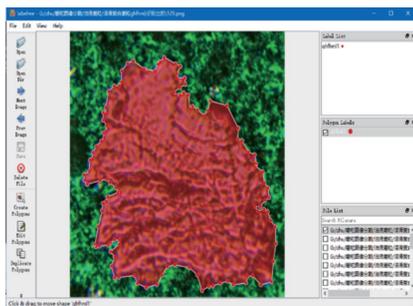
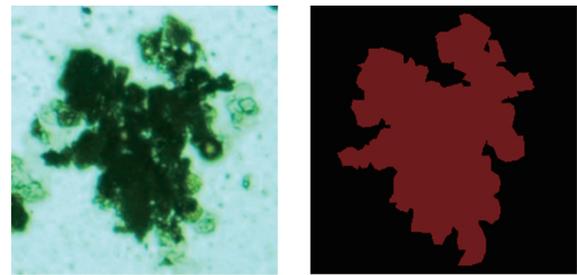


图2 Labelme软件界面

Fig.2 Interface of Labelme

单阶段实例分割模型YOLOCT按照微软语义分割基本数据集(common objects in context,简称COCO)格式构建磨损颗粒数据集,annotations文件夹中存放训练集与验证集的json文件,文件内容为原始图像打乱后的序号、图像名称、图像大小、磨粒种类及磨粒位置信息等。images文件夹中包含train和val两个文件夹,分别存放测试集、验证集对应的图片文件。

两阶段实例分割模型Mask-RCNN的数据集分为4个文件夹:imgs文件夹中存放原始图像;label_viz文件夹中存放标注后的图像;mask文件夹中存放目标磨粒的掩码;yaml文件夹中存放每张图片所含类别的yaml文件。标注图像示例见图3,分别为原始图像及目标磨粒的掩码图像。



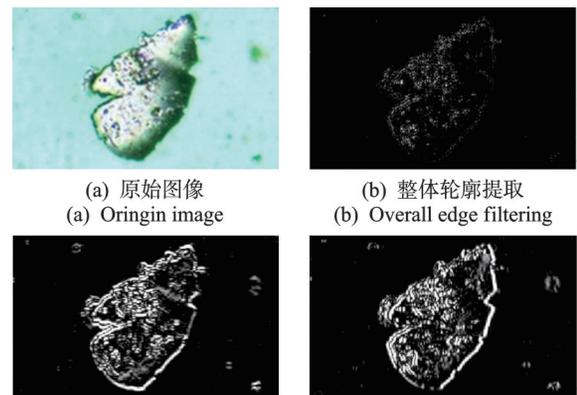
(a) 原始图像
(a) Origin image
(b) 掩码图像
(b) Mask image

图3 标注图像示例

Fig.3 Annotated image example

2 基于CNN的实例分割模型

CNN是一种基于卷积操作的深层监督学习网络。在二维图像处理上,卷积操作具有强大的特征提取能力,如边缘检测、颜色识别、轮廓提取等。通过多个卷积层堆叠,网络可自主提取图像特征,在图像分类、目标定位及像素级语义分割任务上表现出良好的鲁棒性与计算效率。图4为卷积示例。



(a) 原始图像
(a) Origin image
(b) 整体轮廓提取
(b) Overall edge filtering
(c) 纵向轮廓提取
(c) Vertical edge filtering
(d) 纵向轮廓提取
(d) Vertical edge filtering

图4 卷积示例

Fig.4 Example of convolutional operation

基于深度学习的分割技术可对目标物体进行精确的分割。笔者利用实例分割模型对磨粒进行识别与提取,主要包括:①检测出图片中所有的磨粒,并对目标磨粒进行类别判断与定位;②将目标磨粒沿轮廓与背景分割开来,获取磨粒所含的像素信息。

2.1 YOLOCT模型

YOLOCT网络^[23]是一种基于预选框的单阶段实例分割模型,其特点是能实现图像的快速实时分割。基于YOLOCT的油液磨粒检测方案如图5所示。

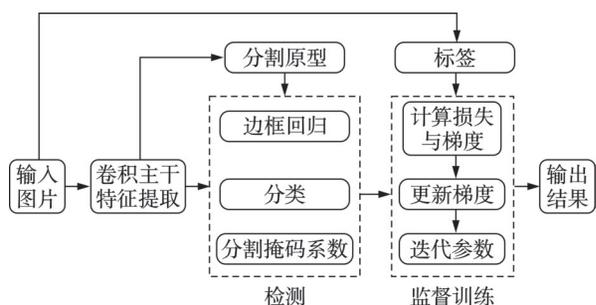


图5 基于YOLOACT的油液磨粒检测方案

Fig.5 Detection scheme of oil wear debris based on YOLOACT

YOLOACT模型主要分为2个并行分支:①掩码分支生成原型掩码;②预测分支输出各个预选框(region of interest,简称ROI)的类别分数、定位参数以及掩码系数。网络通过原型掩码和掩码系数相乘生成最终的分割掩码。此外,YOLOACT网络基于传统的非极大值抑制(non maximum suppression,简称NMS)算法提出了Fast-NMS算法,极大地提升了计算效率。YOLOACT模型结构如图6所示。

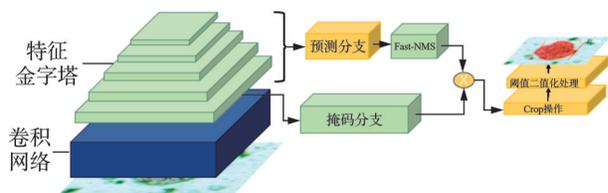


图6 YOLOACT模型结构

Fig.6 YOLOACT model structure

在机器视觉检测中,NMS算法常用于去除重复的ROI。为进一步提升检测速度, Fast-NMS算法将预测分支生成的ROI剔除重复部分,主要步骤为:首先,对于 c 个类别的ROI,选取每个类别置信度最高的 n 个ROI,按置信度进行排序,并计算其交并比(intersection over union,简称IOU)矩阵 X ,其大小为 $c \times n \times n$;其次,将矩阵 X 的对角线和下三角元素均设置为0, $X_{kj}=0, \forall k, j, i, i \geq j$, 剔除其对称重复部分;然后,取每列最大值,得到矩阵 $K_{kj} = \max(X_{kij}), \forall k, j$;最后,利用阈值 $t(K < t)$ 来处理矩阵,保留交并比小于阈值 t 的ROI,即为每个类别最优的ROI。Fast-NMS算法相比NMS算法而言,对重复框的剔除更为严格,删除了更多的ROI,显著提升了计算效率,但对模型的精度仅有轻微的影响。

2.2 Mask-RCNN网络

Mask-RCNN网络是一种两阶段实例分割模型。基于Mask-RCNN的油液磨粒检测方案如图7所示。

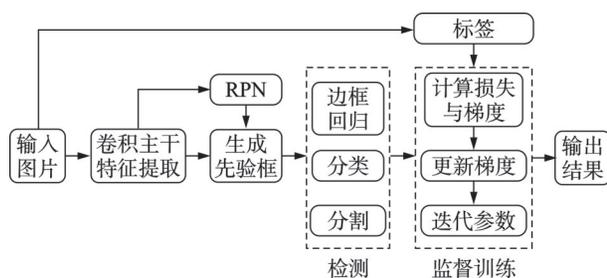


图7 基于Mask-RCNN的油液磨粒检测方案

Fig.7 Detection scheme of oil wear debris based on Mask-RCNN

Mask-RCNN网络基于目标检测框架与分割框架进行改进,包括主干和任务分支两个部分。主干部分通过卷积网络生成特征图,并利用区域推荐网络(region proposal network,简称RPN)代替搜索型算法,对预选框进行前背景分类与定位,生成ROI。目标检测分支分别对每一个候选窗口进行目标分类与定位,分割分支对每一个候选窗口进行分割,判断每个像素点的类别,得到精确的分割掩码。Mask-RCNN模型结构如图8所示。

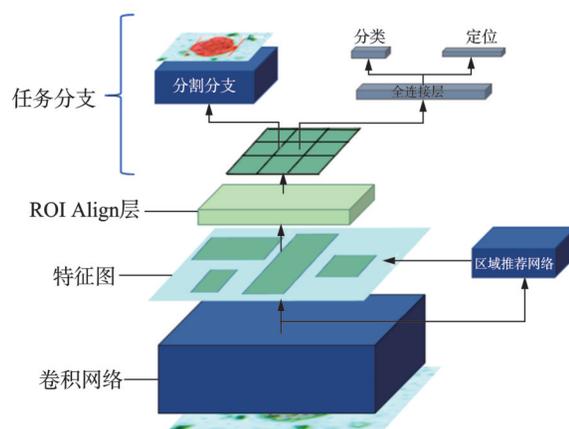


图8 Mask-RCNN模型结构

Fig.8 Model structure of Mask-RCNN

为解决CNN层数加深造成的梯度爆炸与梯度消失问题,He等^[24]提出Resnet模型,通过使用残差模块连接深层与浅层特征,提升了模型效果。笔者采用101层的深层卷积网络Resnet101作为Mask-RCNN模型的卷积主干。

Resnet101中使用的残差模块如图9所示。该模块先用 1×1 卷积核对输入图进行降维,中间 3×3 卷积核的维度不受上下层网络影响,然后通过最后一层 1×1 的卷积核进行维度恢复,并通过残差边将低层特征与高层特征进行连接。使用该结构大大减少了模型的参数数目,节省了计算时间。

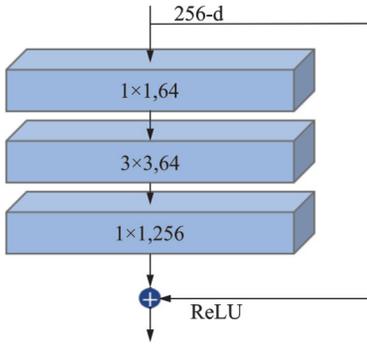


图9 残差模块
Fig.9 Residual block

3 实验结果分析

3.1 模型训练

本实验基于 Windows 操作系统,处理器型号为 Intel i7 7700,8核,内存为 8 GB,显卡为 NVIDIA Quadro P4000,基于 Python 语言和 tensorflow 框架进行搭建实现,选用 VScode 作为集成开发环境 (IDE),并采用 Anaconda 作为解释器,安装项目所需的依赖包,完成模型的训练、验证和测试工作。模型基于 COCO 数据集预训练权重进行迁移学习。

YOLOACT 模型的学习率调整采用多阶段渐收的方式。为加快模型收敛,第 1 阶段将初始学习率设置为 0.005;迭代到 30 000 次时进入第 2 阶段,稍微放慢收敛速度,寻找最小区域,学习率衰减为 0.000 5;训练到 40 000 次时进入第 3 阶段,学习率衰减为 0.000 05,使用较小的学习率来精确定位损失最小值。训练迭代次数设置为 60 000 次,每批次数量设为 4,优化器为 SGD 优化器,预测分支激活函数为 Sigmoid,掩码分支激活函数为 ReLU。

在 YOLOACT 模型中,总损失函数 L_{loss} 由 4 部分组成,分别为分类损失函数 L_{cls} 、定位损失函数 L_{bbox} 、分割损失 L_{mask} 和语义分割损失 L_{seg} 。在计算网络总损失时,根据这几部分的损失,加上相应的权重值计算,即

$$L_{\text{loss}} = L_{\text{cls}} + 1.5L_{\text{bbox}} + 6.125L_{\text{mask}} + L_{\text{seg}} \quad (1)$$

L_{cls} 使用的是多类置信度下的交叉熵损失函数,即

$$L_{\text{cls}}(x, c) = - \sum_{i \in \text{Pos}} x_{ij}^p \log(\hat{c}_i^p) - \sum_{i \in \text{Neg}} \log(\hat{c}_i^0) \quad (2)$$

$$\hat{c}_i^p = \frac{\exp(c_i^p)}{\sum_p \exp(c_i^p)} \quad (3)$$

其中: i 为预测框编号; j 为标签框编号; P 为类别; $x_{ij}^p = \{0, 1\}$ 为第 i 个预测框与 j 个真实框是否类别匹

配的判断标准; c_i^p 为预测框属于 P 类的概率; c_i^0 为预测框属于背景的概率。

L_{bbox} 使用预测框 l 和实际框 g 的位置参数 $\{cx, cy, w, h\}$,即中心坐标、宽和高之间的光滑损失函数 L_1 (Smooth L_1)。该函数增强了对离群点和异常点的鲁棒性,既可有效避免当期望值和误差值的误差较大时出现梯度爆炸的现象,也可在期望值和预测值差距较小时有效收敛到局部最小值,即

$$\text{Smooth}L_1(x) = \begin{cases} 0.5x^2 & (|x| < 1) \\ |x| - 0.5 & (\text{其他}) \end{cases} \quad (4)$$

$$L_{\text{bbox}}(x, l, g) = \sum_{i \in \text{Pos}} \sum_{m \in \{cx, cy, w, h\}} x_{ij}^k \text{Smooth}L_1(l_i^m - g_i^m) \quad (5)$$

L_{mask} 使用平均二分类交叉熵函数 (binary cross entropy, 简称 BCE) 计算,针对目标所属的类别通道进行二值分类,即

$$L_{\text{mask}} = - \frac{1}{M} \sum_{i=1}^M [y \log(P_i) + (1 - y) \log(1 - P_i)] \quad (6)$$

其中: M 为像素点数量; P_i 为模型预测的像素点类别概率; $y = \{0, 1\}$ 为像素点实际类别,1 表示目标,0 表示背景。

通过观察损失值的变化趋势可判断模型的收敛情况。YOLOACT 模型损失值变化曲线如图 10 所示。可以看出:模型损失在第 1 阶段与第 2 阶段迅速下降,总损失值在 2.7 左右上下浮动;在第 3 阶段,模型逐渐收敛,总损失值最终稳定于 2.5 左右。

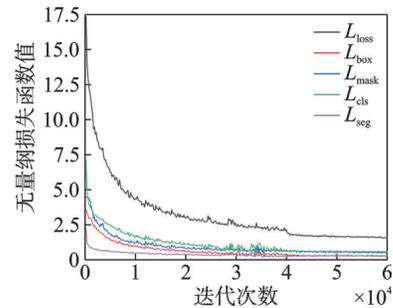


图10 YOLOACT 模型损失值变化曲线

Fig.10 YOLOACT loss curve

本研究将 Mask-RCNN 的初始学习率设置为 0.000 5,优化器为 Adam 优化器,每批次数量设为 4,激活函数采用 ReLU。Mask-RCNN 网络总损失函数 L_{loss} 包括边界框的分类损失 L_{cls} 、定位损失 L_{bbox} 、分割损失 L_{mask} 以及 RPN 的前背景分类损失 $L_{\text{rpn_cls}}$ 和定位损失 $L_{\text{rpn_bbox}}$,即

$$L_{\text{loss}} = L_{\text{cls}} + L_{\text{bbox}} + L_{\text{mask}} + L_{\text{rpn_cls}} + L_{\text{rpn_bbox}} \quad (7)$$

其中: L_{cls} , L_{rpn_cls} 损失函数使用的是交叉熵函数; L_{bbox} , L_{rpn_bbox} 损失函数使用的是Smooth L_1 函数; L_{mask} 损失函数为平均BCE函数。

Mask-RCNN模型损失值变化曲线如图11所示。可以看出:Mask-RCNN模型的损失值在训练开始后迅速降低,之后一直维持在较低水平,在训练前半期总损失值在0.075左右上下浮动,在后半期模型逐渐收敛,最终稳定于0.03左右;RPN网络分类损失、定位损失、目标检测分支分类损失函数及定位损失函数在训练后下降迅速,收敛时稳定在0.0002左右;分割分支损失函数最终稳定于0.03左右。

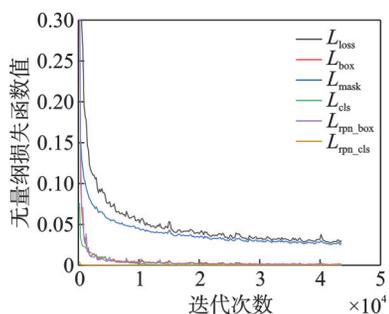


图11 Mask-RCNN模型损失值变化曲线

Fig.11 Mask-RCNN loss curve

3.2 评价指标

笔者采用平均精确率(average precision,简称AP)、平均精确率均值(mean average precision,简称MAP)及平均召回率(average recall,简称AR)作为评价指标,评估模型检测与分割的精确性。

精确率 P 指对于某一类别检测正确的样例数量

占有预测为该类别样例数量的比值, P 越大,则误检率越小。召回率 R 指某一类别检测正确的样例数量占该类别真实样例数量的比值, R 越大,则漏检数量越少。IOU表示预测结果与实际结果间的重叠度,本研究使用的IOU为分割掩码IOU,即模型根据图像预测的磨粒分割掩码与原标注掩码之间的交并比,可用来衡量分割掩码的质量。

评估模型时,需要将IOU与精确率 P 、召回率 R 相结合,以确定模型的好坏。AR表示交并比阈值设置为0.5时模型在测试集上检测的平均召回率。AP值表示特定IOU阈值下的 P - R 曲线面积,以0.05为公差,取0.5~0.95间10个IOU阈值下的AP,求其平均则为MAP值。首先,计算AP值,在设定的IOU阈值下,按置信度降序排列预测框信息,包括目标磨粒序号、置信度、目标是否正确检测等信息;其次,设置一组置信度阈值 $[0, 0.1, 0.2, \dots, 1]$,取不同于阈值的置信度时,会得到一组召回率和精确率,对于相同的召回率,只保留精确率最大的一组,以召回率为 x 轴、精确率为 y 轴,作出 P - R 曲线,计算 P - R 曲线与坐标轴下的面积,即为该IOU下的AP值;然后,根据上述计算方法,再取IOU为0.55, 0.60, 0.65, \dots , 0.95,在不同IOU下计算得到不同的AP值;最后,将得到的10个平均精确率求均值,即为预测模型的MAP值。

3.3 识别效果分析

在所述环境下,利用测试集对YOLACT模型和Mask-RCNN模型的识别效果及性能表现进行测试。检测结果对比如表3所示。

表3 检测结果对比

Tab.3 Comparison of test result

模型	AP ₅₀	AP ₇₅	AP ₉₅	AR	MAP	模型加载时间/s	测试时间/s
Mask-RCNN	0.938	0.918	0.030	0.927	0.779	8.135	0.144
YOLACT	0.847	0.815	0.208	0.833	0.742	2.460	0.058

结果表明,Mask-RCNN模型与YOLACT模型对油液磨粒样本检测的MAP值均非常高,Mask-RCNN模型MAP值为77.9%,较YOLACT模型提升了4个百分点。此外,2个模型在AR和不同IOU阈值下的AP有较大差异。

在平均召回率AR方面,Mask-RCNN模型的召回率均达到92.7%以上,仅有少量磨粒被漏检,而YOLACT模型召回率仅为83.3%,漏检情况更为严重。

在平均精确率AP方面,当IOU阈值取0.5时,

Mask-RCNN模型的AP₅₀值为0.938,达到了较高水平,而YOLACT模型AP₅₀值仅为0.847。当IOU阈值取0.75时,Mask-RCNN模型相比YOLACT模型,仍保持了较高的检测精确率。这是由于采用了Resnet模型,更深的网络结构使得模型对磨粒特征的学习更为全面,对检测到的磨粒可进行正确分类与精准分割。

当IOU阈值取0.95时,YOLACT模型的AP₅₀值高于Mask-RCNN模型,这说明YOLACT模型分割的完整性以及边界精细处理效果要优于

Mask-RCNN模型。这是因为Mask-RCNN模型以实例分类置信度为分割掩码的质量分数,而分割掩码的质量却与实例分类的置信度无太大的相关性。此外,两阶段模型在很大程度上依赖于特征定位来生成分割掩码,但经过区域特征聚集会导致分割质量损失,因此Mask-RCNN模型分割完整性较差。YOLOACT在未经过区域特征聚集的特征图上生成了更大尺寸的分割掩码,可得到更高质量的分割结果。

由于Mask-RCNN模型比较复杂,上百层的网络结构使得模型加载时间延长,为8.135 s,测试每张图需要0.144 s。YOLOACT模型的网络结构轻便简洁,模型加载时间较短,仅为2.460 s,测试图片的速度较快,平均每张图仅需0.058 s,检测效率为Mask-RCNN模型的2倍左右。

图12为部分测试图片识别效果图。可以看出:2种模型对于大部分磨粒都能正确识别类别和位置,但Mask-RCNN模型的实例分类置信度明显高于YOLOACT模型;YOLOACT模型对磨粒的分割更为完整,轮廓处理更为细致。综合分析得出:Mask-RCNN模型在召回率和 AP_{50} 值方面远远高于YOLOACT模型,能准确识别大部分的磨粒,泛化性能较好,适用于油液磨粒样本的精确检测;而YOLOACT模型的检测速度快、准确率较高及分割区域完整,因此更适用于实时快速检测以及对分割要求较高的检测。2种模型均能够有效减轻人工工作量,提高工作效率。

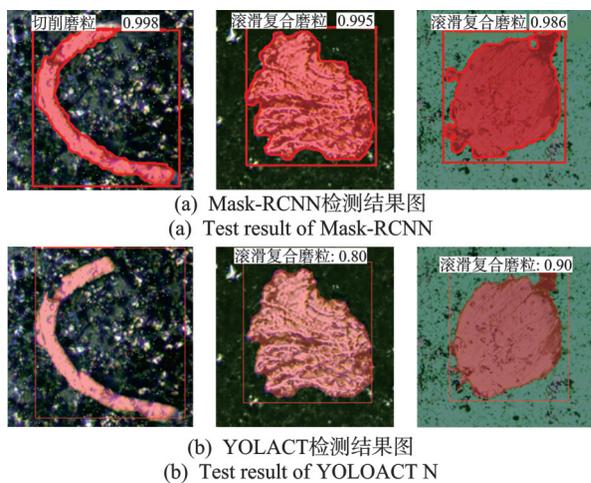


图12 部分测试图片识别效果图

Fig.12 Recognition results of partial test images

4 结论

1) 基于滤膜谱片技术制备了油液磨粒谱片,采集图像样本941张,构建了含金属氧化物、球状磨

粒、切削磨粒、滚滑复合磨粒、疲劳磨粒和严重滑动磨粒等6种常见磨粒的高质量数据集。

2) 结合油液磨粒研究对象实现了油液磨粒单阶段实例分割算法YOLOACT,结果表明,模型平均识别精确率 AP_{50} 为84.7%,平均召回率AR为83.3%,MAP值为74%,检测速度快,分割完整性高。

3) 基于检测精度需求搭建了两阶段实例分割算法Mask-RCNN模型,结果表明,模型平均识别精确率 AP_{50} 为93.8%,平均召回率AR为92.7%,MAP值为73%,检测精度高,但在检测速度方面略有欠缺。

4) 综合分析,YOLOACT模型检测速度快,边缘分割精细,适用于磨损颗粒快速检测与智能分割;Mask-RCNN模型检测精度高,漏检少,适用于磨损颗粒智能分析的精准检测。

参 考 文 献

- [1] 林丽, 邓春, 经昊达, 等. 基于油液在线监测的齿轮箱磨损趋势分析与研究[J]. 材料导报, 2018, 32(18): 3230-3234.
LIN Li, DENG Chun, JING Haoda, et al. Analysis and research for wear trend of gear box based on on-line monitoring of oil[J]. Materials Review, 2018, 32(18): 3230-3234. (in Chinese)
- [2] 都玉辉. 基于油液分析的齿轮磨损状态识别及故障预测[D]. 太原: 太原理工大学, 2018.
- [3] 龚卿青, 白文斌, 李凯, 等. 油液磨粒检测技术研究现状与发展趋势[J]. 中北大学学报(自然科学版), 2021, 42(6): 564-576.
GONG Qingqing, BAI Wenbin, LI Kai, et al. Research status and development trend of oil abrasive detection technology[J]. Journal of North University of China (Natural Science Edition), 2021, 42(6): 564-576. (in Chinese)
- [4] COSSETTE J P, OLIVER R, CRIME J P. Evaluation of hydraulic oil filters by particle counting and ferrographic analysis[J]. Lubrication Engineering, 1998, 44(6): 617-621.
- [5] 杨其明. 油液监测分析现场实用技术[M]. 北京: 机械工业出版社, 2006: 7-8.
- [6] HARGIS S C, TAYLOR H F, GOZZO J S. Condition monitoring of marine diesel engines through ferrographic oil analysis[J]. Wear, 1983, 90(2): 225-238.
- [7] 吴振锋, 左洪福, 孙有朝. 磨粒分析技术及其在发动机故障诊断中的应用[J]. 航空动力学报, 2001, 16(4): 316-322.

- WU Zhenfeng, ZUO Hongfu, SUN Youchao. Debris analysis technology and its application to aeroengine fault diagnosis field [J]. *Journal of Aerospace Power*, 2001, 16(4): 316-322. (in Chinese)
- [8] 任松, 姜德义, 杨春和, 等. 一种设备故障诊断油液分析方法: 中国, CN201010143921.5[P]. 2010-04-09.
- [9] 周新聪, 萧汉梁, 严新平, 等. 一种新的磨粒图像特征参数[J]. *摩擦学学报*, 2002, 22(2): 138-141. ZHOU Xincong, XIAO Hanliang, YAN Xiping, et al. A new comprehensive feature parameter for wear particle image analysis[J]. *Tribology*, 2002, 22(2): 138-141. (in Chinese)
- [10] 王伟华, 殷勇辉, 王成焘. 基于径向基函数神经网络的磨粒识别系统[J]. *摩擦学学报*, 2003, 23(4): 340-343. WANG Weihua, YIN Yonghui, WANG Chengtao. Wear debris recognition system based on radius basis function network [J]. *Tribology*, 2003, 23(4): 340-343. (in Chinese)
- [11] 梁华, 杨明忠. 基于神经网络的磨粒识别专家系统 [C]//中国机械工程学会'94全国铁谱技术会议. 北京: 中国机械工程学会摩擦学分会, 1994: 192-195.
- [12] 严志军, 程东, 朱新河, 等. 基于自适应支持向量机的磨粒识别技术研究[J]. *中国设备工程*, 2002(6): 40-42. YAN Zhijun, CHENG Dong, ZHU Xinhe, et al. Wear particle recognition expert system based on fuzzy nervous network [J]. *China Plant Engineering*, 2002(6): 40-42. (in Chinese)
- [13] 石宏, 张帅, 李昂. 基于自适应支持向量机的磨粒识别技术研究[J]. *科学技术与工程*, 2012, 12(32): 8543-8546, 8552. SHI Hong, ZHANG Shuai, LI Ang. Research on wear particle recognition based on self-adapting support vector machine [J]. *Science Technology and Engineering*, 2012, 12(32): 8543-8546, 8552. (in Chinese)
- [14] 崔海, 康剑莉. 基于片相似各项异性扩散的BP神经网络的磨粒识别研究[J]. *浙江水利水电学院学报*, 2016, 28(3): 77-80. CUI Hai, KANG Jianli. Research on wear debris recognition algorithm based on IFNN [J]. *Journal of Zhejiang Water Conservancy and Hydropower College*, 2016, 28(3): 77-80. (in Chinese)
- [15] 孔祥兴, 邵涛. 基于颜色特征提取的磨粒材质识别 [J]. *润滑与密封*, 2020, 45(5): 79-85. KONG Xiangxing, SHAO Tao. Wear debris material recognition based on color feature extraction [J]. *Lubrication Engineering*, 2020, 45(5): 79-85. (in Chinese)
- [16] PENG Y P, WU T H, CAO G Z, et al. A hybrid search-tree discriminant technique for multivariate wear debris classification [J]. *Wear*, 2017(392/393): 152-158.
- [17] PEERAWATT N. Comparative study on wear particle colour classifications using various machine learning algorithms [J]. *Applied Mechanics and Materials*, 2014, 619: 347-351.
- [18] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [19] CANZIANI A, PASZKE A, CULURCIELLO E. An analysis of deep neural network models for practical applications [DB/OL]. (2016-05-24) [2021-11-16]. <https://www.semanticscholar.org/paper/An-Analysis-of-Deep-Neural-Network-Models-for-Canziani-Paszke/9a786d1ecf77dfba3459a83cd3fa0f1781bbcb4>.
- [20] 樊红卫, 马宁阁, 张旭辉, 等. 基于堆栈降噪自编码网络的机械设备磨损状态识别 [J]. *工矿自动化*, 2020, 46(11): 6-11. FAN Hongwei, MA Ningge, ZHANG Xuhui, et al. Wear state recognition of mechanical equipment based on stacked denoised auto-encoding network [J]. *Industry and Mine Automation*, 2020, 46(11): 6-11. (in Chinese)
- [21] 杨智宏, 贺石中, 冯伟. 基于Mask R-CNN网络的磨损颗粒智能识别与应用 [J]. *摩擦学学报*, 2021, 41(1): 105-114. YANG Zhihong, HE Shizhong, FENG Wei. Intelligent recognition and application of wear particles based on Mask R-CNN network [J]. *Tribology*, 2021, 41(1): 105-114. (in Chinese)
- [22] PENG P, WANG J G. Wear particle classification considering particle overlapping [J]. *Wear*, 2019(422/423): 119-127.
- [23] TAO Y, ZONGYANG Z, JUN Z, et al. Low-altitude small-sized object detection using lightweight feature-enhanced convolutional neural network [J]. *Journal of Systems Engineering and Electronics*, 2021, 32(4): 841-853.
- [24] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770-778.



第一作者简介:任松,男,1975年6月生,博士、教授。主要研究方向为机械设备油液分析、故障诊断与智能维护。曾发表《旋挖钻机设备油液智能分析与健康监测》(《振动、测试与诊断》2020年第40卷第3期)等论文。
E-mail: 909965586@qq.com