

摩擦学学报

Tribology

ISSN 1004-0595, CN 62-1095/O4

《摩擦学学报》网络首发论文

题目: 1 种新的磨粒序列图像逐层递进式识别算法
作者: 刘信良, 陶俊, 王静秋, 王晓雷
收稿日期: 2024-12-23
网络首发日期: 2025-04-09
引用格式: 刘信良, 陶俊, 王静秋, 王晓雷. 1 种新的磨粒序列图像逐层递进式识别算法 [J/OL]. 摩擦学学报. <https://link.cnki.net/urlid/62.1095.O4.20250408.1717.008>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式 (包括网络呈现版式) 排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊 (光盘版)》电子杂志社有限公司签约, 在《中国学术期刊 (网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊 (网络版)》是国家新闻出版广电总局批准的网络连续型出版物 (ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

1 种新的磨粒序列图像逐层 递进式识别算法

刘信良，陶俊，王静秋*，王晓雷

(南京航空航天大学 直升机动力学全国重点实验室，江苏 南京 210016)

摘 要：由于不同类型磨损颗粒的尺寸形貌差异大，受限于显微镜小景深，厚薄不同的磨粒在 1 幅图像上可能会离焦模糊，导致磨粒的误检与漏检，针对此问题，本文中提出了磨粒序列图像逐层递进式识别算法。首先，通过引入空间与通道注意力模块(Convolutional block attention module, CBAM)、变差级联头部结构与融合深/浅层特征的分割分支，构建单幅磨粒图像实例分割模型 WearIS，以识别图像中的清晰磨粒；其次，依据相邻两帧图像间磨粒重叠交并比和置信度等指标设计磨粒逐层递进式识别算法，对识别结果进行逐帧关联修正，最终识别图像中所有磨粒。对比试验结果表明，该算法在磨粒序列图像测试集上的检测和分割精度均值(AP50)分别为 82.67%和 80.92%，平均交并比(mIoU)为 75.64%，平均运行时间为每帧 1.07 s，相较单幅磨粒图像分析方法，该算法取得了更好的磨粒识别效果，提升了识别结果的置信度，且有效降低了异常磨粒漏检与误检的概率。

关键词：故障诊断；铁谱分析；实例分割；磨粒逐层识别；磨粒序列图像

中图分类号：TP391.4; TH117.1 **文献标识码：**A

A Novel Layer by Layer Progressive Recognition Algorithm for Wear Particle Sequence Images

LIU Xinliang, TAO Jun, WANG Jingqiu*, WANG Xiaolei

(National Key Laboratory of Helicopter Aeromechanics,

Nanjing University of Aeronautics and Astronautics, Jiangsu Nanjing 210016, China)

Abstract: Due to the significant variations in size and morphology among different types of wear particles, and the limited depth of field of microscopes, particles of varying thickness may appear defocused and blurred within a single ferrograph image. To address the challenges of omission and

* Received 23 December 2024, revised 12 March 2025, accepted 14 March 2025.

*Corresponding author. E-mail: meeqwang@nuaa.edu.cn, Tel: +86-25-84893630

This project was supported by the National Key Laboratory of Science and Technology on Helicopter Transmission (HTL-A-21G03) 直升机传动技术重点实验室基金项目(HTL-A-21G03)资助.

misidentification caused by defocused particles in single-image analysis, a progressive layer-by-layer recognition algorithm for wear particles in ferrograph sequence images was proposed. First, an instance segmentation model, termed WearIS, was developed for a single ferrograph image. This model incorporated the Convolutional Block Attention Module (CBAM), a variance-cascaded head network, and a segmentation branch fusing deep and shallow features to accurately identify clear wear particles in the images. Second, a progressive layer-by-layer recognition algorithm was designed to iteratively refine the recognition results across sequence images, which utilized metrics such as the intersection-over-union (IoU) of overlapping particles between consecutive frames and confidence scores. This algorithm performed frame-by-frame association and correction, ultimately ensuring comprehensive identification of all wear particles within the sequence. Comparative experimental results demonstrated that the proposed algorithm achieved detection and segmentation AP50 values of 82.67% and 80.92%, respectively, and a mean IoU of 75.64% on the ferrograph sequence image test set, with an average processing time of 1.07 seconds per frame. Compared to single-image ferrograph analysis methods, the proposed approach significantly enhanced wear particle recognition accuracy while effectively reducing the probability of omission or misidentification of anomalous particles.

Keywords: fault diagnosis; ferrography; instance segmentation model; progressive layer by layer recognition; ferrograph sequence image

铁谱分析是航空、石化和煤炭等设备磨损监测与故障诊断的重要手段，通过对润滑系统中磨损颗粒(简称磨粒)的定性分析和定量计算，可以获取故障部位和磨损类型等信息，从而帮助技术人员做出正确维护决策，减少因设备故障导致的安全风险与经济损失。

基于数字图像处理和浅层机器学习的铁谱图像分析，将图像中的磨粒与背景分割^[1-4]，堆积磨粒分离^[5-8]，从而识别每个磨粒的类别^[9-12]，判断设备的磨损状态。此类方法在一定程度上提升了铁谱分析的自动化水平，然而，仍存在以下 4 个问题：磨粒分割结果易受光照、噪声影响；磨粒识别准确率依赖人工设计特征；单向线性的多阶段分析流程会造成误差累计与传递；人工采集图像费时费力且样本之间偏差大。因此，其准确率和智能化水平有待提高。

近年来，深度学习技术因具有“端到端”处理、自动提取特征及自学习等优点^[13]，被

引入铁谱图像分析中，并相继在磨粒图像分类^[14-18]、磨粒检测^[19-22]和铁谱图像语义分割^[23-24]任务中展现出优异性能；此外，一些学者致力于铁谱图像的自动化采集，例如，刘信良等^[25]提出了磨粒自动对焦算法，以获取反映磨粒形貌的铁谱序列图像。上述研究提升了铁谱图像分析的准确率与智能化程度，然而，上述分析方法只能对磨粒的部分参数进行定性或定量分析，例如，磨粒图像分类任务只能获取磨粒类别而无法获取定量信息，磨粒检测任务能够得到磨粒的数量及大致尺寸但无法获取浓度信息，铁谱图像语义分割任务能够得到各类别磨粒的浓度但无法区分同类别的不同磨粒个体。

铁谱图像实例分割可以自动检测图像中每个磨粒并获取其对应掩膜信息，其本质上是图像分类、目标检测与语义分割的结合，不仅可以获取磨粒的类型、数量和位置信息，还能进一步计算其尺寸、形状和浓度等参数。安超等^[26]直接将实例分割模型 Mask R-CNN^[27]应用于铁谱图像分析中，并使用迁移学习的方式对其进行微调，实现了对形貌相似度高的疲劳、严重滑动和层状磨粒的实例分割。鉴于 Mask R-CNN 模型的优异性能，后续研究多是在此基础改进的，Sun 等^[28]重点改进了分割分支，使用空洞反卷积操作提升掩膜的分辨率，从而获取更精细的分割结果；Wang 等^[29]通过重新设计 Mask R-CNN 中 anchor 的尺寸与比例，引入增强池化操作和构建新的包围框损失函数，实现了磨粒检测与分割准确率的提升。

然而对于单幅铁谱图像，由于受显微镜小景深影响，不同厚度的磨粒无法同时清晰呈现在 1 幅图像上^[30]，因此，仅对单幅铁谱图像分析会导致对离焦模糊磨粒的漏检与误检。图 1 所示为显微镜平台沿垂直方向移动时采集的 3 幅序列图像，可以看出，磨粒区域 1 和磨粒区域 2 分别在图 1(a)和(b)中最清晰；值得注意的是，磨粒区域 3 在图 1(a)和(b)非常模糊，而其在图 1(c)中比较清晰，可以看出此区域包含有球形磨粒。因此如果依靠图 1(a)和(b)，磨粒区域 3 会因离焦模糊而容易被识别为氧化物磨粒的一部分。




Fig. 1 An example of 3 frames of ferrograph images captured by moving the microscope platform in the vertical direction

图 1 显微镜平台沿垂直方向移动采集的 3 帧铁谱图像示例

针对上述问题，本文中结合计算机断层扫描技术设计了磨粒逐层递进式识别算法，将显微镜平台沿磨粒厚度方向运动时采集的铁谱序列图像看作磨粒断层切片，对其进行逐帧

递进式磨粒识别。

1 磨粒序列图像逐层递进式识别算法总体流程

磨粒序列图像逐层递进式识别算法分为两部分：首先，构建融合空间和通道注意力机制的级联磨粒实例分割模型 WearIS，实现对单幅复杂铁谱图像的实例分割；然后，提出磨粒逐层递进式识别算法，即通过关联序列图像中前一帧磨粒识别结果，依据重叠交并比、置信度和类别等信息对当前帧磨粒识别结果进行修正。对铁谱序列图像中每帧依次执行上述两步，最终得到完备的磨粒识别结果，其流程如图 2 所示。相较单幅铁谱图像分析方法，本文中算法能够针对序列图像，通过融合磨粒的三维形貌信息有效降低因离焦失真导致的异常磨粒误检的概率。




Fig. 2 Layer by layer identification diagram of wear particles
图 2 磨粒逐层递进式识别示意图

2 融合空间与通道注意力机制的变差级联磨粒实例分割模型

磨粒产生的机理复杂，同类别磨粒的形貌也会有较大差异，同时，磨粒在制谱过程中不可避免地出现粘连和重叠情况。为解决因上述原因导致的误检和漏检问题，本文中设计了铁谱图像实例分割模型 WearIS，该模型通过融合卷积块注意力模块 (Convolutional Block Attention Module, CBAM)、构建变差级联头部网络与掩膜分割网络，对实例分割模型 Cascade RCNN^[31]进行了改进，其结构如图 3 所示。WearIS 模型包含多尺度特征提取网络、候选区域提取网络 RPN 和变差级联头部网络 3 个部分。首先，输入图像经过特征提取网络获取不同分辨率下磨粒的深层特征；然后，该特征以预先设计的锚框(Anchor)为基准，经过区域生成网络 (Region Proposal Network, RPN) 生成候选框；最后，头部网络对候选框精修，输出磨粒的类别、包围框坐标和掩膜位置。相较于原模型，WearIS 模型重点进行了 3

点改进：(1) 在多尺度特征提取网络中引入空间与通道注意力机制 CBAM 模块，使网络能够自动学出图像中需要注意的地方，而不是将注意力平均分配给图像中的所有像素；(2) 构建变差级联检测网络，用于生成高质量的候选框，提升磨粒检测的准确率；(3) 改进掩膜分割网络，用于获取精细的磨粒掩膜结果，提升磨粒分割的准确率。




Fig. 3 The overall structure of WearIS

图 3 WearIS 模型总体结构

2.1 空间与通道注意力机制

特征提取是磨粒识别的关键步骤，其结果的好坏影响磨粒类别、包围框和掩膜的准确度，因此，应重点考虑如何让模型准确地关注到磨粒区域。本文中采用残差网络 ResNet-50^[32]与特征金字塔网络(Feature Pyramid Network, FPN)^[33]作为多尺度特征提取的主干网络，通过残差结构解决网络深度不断增加导致的信息冗余及梯度弥散问题；在残差单元中加入 CBAM 模块，设计融合空间与通道注意力机制的残差块 CS-ResBlock I和II单元，如图 4(a)和(b)所示，使模型将特征提取的重点集中于磨粒区域。CBAM 的总体结构如图 4(c)所示，输入特征为 F ，依次经过通道注意力模块 CAM 和空间注意力模块 SAM，分别得到权重 M_c 和 M_s ，则最终融合后的特征 F'' 如下式表示：

$$F' = M_c(F) \otimes F \quad (1)$$

$$F'' = M_s(F') \otimes F' \quad (2)$$

其中， $\otimes$ 表示元素相乘。

通道注意力模块 CAM 聚焦于图像的语义特征。对于铁谱图像，磨粒有意义，而背景和杂质无意义。CAM 的结构如图 4(d)所示，首先，输入特征 F 经过全局平均和最大池化操作，分别得到特征 F_a^c 和 F_m^c ；然后，将两特征送入共享的 3 层神经网络，分别得到整合特征 F_{a1}^c 和 F_{m2}^c ；最后，将上述特征逐元素相加并经过 sigmoid 函数后得到通道注意力权重 M_c ，其计算过程如下式表示：

$$M_c = \sigma(F_{a1}^c + F_{m1}^c) \quad (3)$$

$$F_{a1}^c = \text{MLP}(F_a^c) = \text{MLP}(\text{avgPool}(F)) \quad (4)$$

$$F_{m1}^c = \text{MLP}(F_m^c) = \text{MLP}(\text{maxPool}(F)) \quad (5)$$

$$\text{MLP}(x) = W_1(\sigma(W_0(x))) \quad (6)$$

其中， σ 代表 sigmoid 函数， W_0 和 W_1 为共享神经网络的参数， MLP 为 3 层全连接神经网络， avgPool 与 maxPool 分别为平均值与最大值池化操作。

在 CAM 确定要关注的信息后，空间注意力机制 SAM 进一步定位所关注信息的位置，即哪里是应该关注的信息。在铁谱图像中，磨粒区域是需要关注的信息。SAM 的总体结构如图 4(e)所示，首先对特征 F 沿通道分别取平局和最大池化操作，并将结果按通道拼接得到特征 F^s ；再通过 7×7 的卷积和 sigmoid 函数后，得到空间注意力权重 M_s ，其计算过程如下所示。

$$M_s = \sigma(f([\text{avgPool}(F'); \text{maxPool}(F')])) \quad (7)$$

其中， σ 代表 sigmoid 函数， f 为 7×7 的卷积操作， $[\cdot]$ 表示特征按通道拼接。




Fig. 4 The structure diagrams of Residual unit and CBAM

图 4 残差单元与 CBAM 结构图

2.2 变差级联头部网络

对于单阈值头部网络，较低的交并比阈值 (Intersection over Union, IoU) 不利于磨粒的精准检测；而直接提高 IoU 阈值会使正样本数量减少，导致漏检和误检问题。对此，本文中引入级联头部网络^[30]，通过逐步提高检测分支的 IoU 阈值，实现目标的精准定位。该网络其结构如图 5 所示，包含 3 个彼此级联的单阈值检测分支，假设 x 为输入的特征， b 为包围框集合，则最终的包围框由下式计算。

$$f(x, b) = f_T \circ f_{T-1} \circ \dots \circ f_1(x, b) \quad (8)$$

其中， T 为级联检测分支的数量， f_T 代表包围框回归映射函数， $\circ$ 代表不同分支之间的级联运算。本文中基于 softmax 计算置信度，故最终类别置信度可由下式计算。

$$C_F = (C_1 + C_2 + C_3)/3 \quad (9)$$

$$C_a = \max[\text{softmax}(z^a)] = \max \frac{e^{z_i^a}}{\sum_{i=1}^K e^{z_i^a}} \quad a = 1, 2, 3 \quad (10)$$

其中, $C_a (a=1, 2, 3)$ 为每个检测分支输出的类别得分, C_F 为最终类别得分, $\mathbf{z}=[z_0, z_1, \dots, z_K]$, 是分类分支的输出, K 为类别总数。

然而, 原级联头部网络存在 2 个问题: (1) 浅层检测分支相较深层检测分支的可信度低, 相同权重可能引起前者的错误结果干扰最终识别结果, 导致误分类; (2) 随着 IoU 阈值提升, 正样本数量呈现曲线下降, 且越靠近高阈值正样本数量下降越快, 等差增长的 IoU 阈值 (0.5, 0.6, 0.7) 会引起前一阶段检测头无法为后一阶段生成足够多高质量的候选框, 导致检测结果下降。针对问题(1), 使用加权法计算最终类别得分, 其计算如下:

$$C_F = w_1 \cdot C_1 + w_2 \cdot C_2 + w_3 \cdot C_3 \quad (11)$$

其中, w_1 、 w_2 和 w_3 为得分权重, 通常将其设为相同权重^[30], 即 1:1:1, 但容易引起低 IoU 阈值检测分支输出的低置信度分类结果影响其他分支的高置信度分类结果, 导致误分类问题; 本文中将其设为加权重, 目的是使深层检测分支输出的置信度占更高比重, 以提升分类的准确性, 经后续试验验证, 权重系数分别设为 0.2、0.3 和 0.5 时分类准确率最高。针对问题(2), 提出变差增长的 IoU 阈值。检测分支的 IoU 阈值分别设为 0.50、0.58 和 0.70, 其阈值之间的差值分别为 0.08 和 0.12, 这能保证前一分支在略低阈值时生成较多候选框, 供后一阶段使用, 以保证各阶段正样本的均衡。




Fig. 5 Variable cascade header network and improved mask segmentation network structure

图 5 变差级联头部网络与改进掩膜分割网络结构

2.3 改进掩膜分割网络

为了获取更加精细的掩膜分割结果, 本文中构建了融合深层和浅层信息的分割网络,

其结构如图 5 所示。该网络以级联检测分支获取的包围框特征图作为输入，经过感兴趣区域对齐操作(ROIAlign)将特征尺寸固定为 $14 \times 14 \times 256$ ，再经过 4 组 3×3 的卷积层和步长为 2 的 3×3 反卷积层(DeConv)得到掩膜的深层特征；同时，ROIAlign 后的特征直接进行 2 倍上采样得到掩膜的浅层特征，将两个特征按通道拼接送入 2 组 3×3 卷积层，得到最终目标掩膜。

3 WearIS 模型的训练与结果分析

3.1 磨粒实例分割数据集的构建

本文中依据磨损机理和磨粒形貌等因素，将磨粒分为链状磨粒(chain)、块状磨粒(block)、切削磨粒(cutting)、球形磨粒(sphere)以及氧化物磨粒(oxide)等 5 个类别。考虑到单幅铁谱图像上可能存在较多离焦模糊的磨粒区域，若只标注清晰磨粒，可能导致模型的漏检问题；相反，若强行给难以分辨的离焦磨粒分配标签则会导致严重的误检问题。针对此问题，本研究在原有 5 个磨粒类别的基础上设定了“模糊类”(blur)，用以模拟显微镜平台运动时铁谱序列图像中磨粒离焦模糊的过程。该类别包含单幅铁谱图像中模糊失真、难以辨别形貌特征的磨粒或杂质，以减少因漏标注和误标注导致的误检和漏检问题。

数据集的图像来源自两部分，静态拍摄的厚度相近的磨粒图像和动态采集的厚度差异大的磨粒序列图像，分别用于模型预训练和微调。其中包含静态图像 424 张，选取 59 组序列图像中的 1 019 帧，并将其分别划分为训练集 1 178 张、验证集 116 张和测试集 149 张。

3.2 试验参数设置

WearIS 模型训练过程的超参数设置如下：批次(batch size)大小为 2；初始学习率为 0.001，采用阶梯下降策略；优化算法采用动量梯度算法，动量参数为 0.9；模型先用静态拍摄的图像进行预训练，共进行 10 000 次迭代；再用动态采集的序列图像微调，共进行 30 000 次迭代。

3.3 试验结果与分析

图 6 所示为静态拍摄的磨粒图像及其对应的预测结果。从图 6 中可以看出，WearIS 模型的表现较好，可以准确地预测出各磨粒的类别和包围框的坐标，同时获取较为精细的磨粒掩膜，例如，对于图 6(a)中这类磨粒分布分散且尺寸差异大的情形，以及图 6(b)和(c)中这类长宽比过大且旋转角度不定链状磨粒图像。然而，WearIS 模型仍然存在少量误检现象，例如图 6(c)中的块状磨粒漏检，且此处 2 个面积不同的重叠包围框指向同一个链状磨粒。




Fig. 6 The test results of WearIS on 3 groups of static images

图 6 WearIS 模型在 3 组静态拍摄图像上的测试结果

图 7 所示为动态采集铁谱序列图像中的 3 帧及其对应的预测结果。可以看出，第 6 帧除了右侧的链状磨粒清晰，其他磨粒因失焦模糊而被预测为 **Blur** 类；第 20 帧中间偏左的磨粒清晰，WearIS 模型可以准确地区分链状和块状磨粒粘连堆叠的部分，并获取磨粒掩膜；值得注意的是，第 20 帧中最左侧的球形磨粒并不清晰，故将其作为链状磨粒的一部分，而其在第 28 帧中逐渐清晰，WearIS 模型可以将其与粘连的链状磨粒区分，并准确地检测与分割。然而，该模型仍存在部分漏检现象，例如图 7(c)左侧的模糊磨粒漏检。




Fig. 7 The test results of WearIS on a set of sequence images

图 7 WearIS 模型在 1 组序列图像上的测试结果

本文中采用精度均值(Average precision, AP)、单幅图像处理速度及模型大小 3 个指标，对 WearIS 模型的性能进行量化评定，并将其与 7 种主流实例分割模型对比，试验结果列于表 1 中。可以看出，WearIS 模型虽然在模型大小和运行速度指标上逊色于 SOLOv2 和 BlendMask 模型，但其检测和分割性能相较其他一阶段及二阶段模型分别提升 7.07%和

6.20%及 3.86%和 2.67%以上(AP50 指标下, 即 IoU 阈值为 0.50 时的精度均值), 具有最优性能。

表 1 不同实例分割模型在测试集上的结果

Table 1 Results of different instance segmentation models on the test set

Segmentation models		Bbox			Segm			Inference time/s	Model size/Mb
		AP	AP50	AP75	AP	AP50	AP75		
Two-stage	Mask RCNN	54.43	74.47	53.81	54.10	74.62	53.76	0.158	242
	PANet	55.27	74.89	54.51	54.57	75.02	54.13	0.253	559
	Cascade RCNN	57.99	77.72	63.34	57.40	77.40	62.45	0.171	346
	WearIS	62.75	81.58	69.16	61.64	80.07	67.25	0.178	365
One-stage	SOLOv2	—	—	—	52.78	73.53	52.92	0.096	251
	PolarMask	—	—	—	46.73	61.85	54.16	0.138	264
	BlendMask	54.20	74.51	61.14	56.52	73.87	60.76	0.127	144

Note: AP is the average precision value calculated under different IoU settings (ranging from 0.50 to 0.95 with a step size of 0.05);

AP50 and AP75 are the average precision values when the IoU is set to 0.50 and 0.75, respectively

通过以上试验可知, WearIS 模型达到较高的检测和分割准确率, 且泛化性较好, 能够用于对铁谱序列图像逐层分析。

4 磨粒逐层递进式识别算法设计

利用前文中建立的 WearIS 模型, 对输入的铁谱序列图像进行逐帧实例分割, 得到清晰磨粒的识别结果(即屏蔽 Blur 类)。同时结合前一帧的识别结果, 依据 IoU 和置信度等指标, 修正当前帧的识别结果, 按上述流程最终得到该序列图像中所有清晰磨粒的结果。为了准确判定磨粒之间的重叠关系, 本文中在 IoU 的基础上提出了 IoM (intersection of minimum area)指标, 用于判定小目标对大目标的重叠程度, 如图 8 所示, 其定义如下:

$$\text{IoM}(S_a, S_b) = \frac{\text{intersection}(S_a, S_b)}{\min(S_a, S_b)} \quad (12)$$

其中, S_a 与 S_b 为 2 个目标, $\text{intersection}(\bullet)$ 为两目标相交部分的面积, $\min(\bullet)$ 为两目标中较小的面积。




Fig. 8 Categories of overlapping situation

图 8 重叠情况分类

通过上述指标，可以将所有前后帧磨粒之间的关系分为 3 种情形，如图 9 所示。设黑线所围区域为铁谱序列图像 n 上的任一识别结果 ins_n^i (其中保存磨粒的包围框、掩膜、置信度及类别信息)；红线所围区域为铁谱序列图像 $n+1$ 上的任一识别结果 ins_{n+1}^j ； $thre1$ 和 $thre2$ 分别为 IoU 和 IoM 的阈值，当 $thre1=0.7$ ， $thre2=0.8$ 时效果最好：

Case1: $IoU \geq thre1$ ，代表两结果之间重合度较高，可以看作同一磨粒在相邻两帧上的识别结果，通过比较两者的置信度确定需要保留的结果；

Case2: $IoU < thre1$ ，且 $IoM < thre2$ ，代表两结果之间重合度低或不相交，故两者分别为不同磨粒的识别结果；

Case3: $IoU < thre1$ ，且 $IoM \geq thre2$ ，代表相邻两帧的识别结果存在覆盖关系，还需判断此时相机焦平面是否为接近磨粒对焦平面的过程。若 $Area(ins_n^i) \geq Area(ins_{n+1}^j)$ ，代表相机焦平面接近磨粒对焦平面，为防止 WearIS 模型误检导致的错判，还需判断 $n+2$ 中是否有与 ins_{n+1}^j 对应的实例，若有则表明此区域存在磨粒堆叠，并将 ins_{n+1}^j 从覆盖区域 ins_n^i 中分离，否则为 WearIS 模型的误检结果并丢弃；若 $Area(ins_n^i) < Area(ins_{n+1}^j)$ ，为相机焦平面远离磨粒的过程，堆叠区域呈现“清晰→模糊”的过程，故保留 ins_n^i 、丢弃 ins_{n+1}^j 。




Fig. 9 Position relation diagram of wear particles

图 9 磨粒位置关系示意图

磨粒逐层递进式识别算法的流程如图 10 所示。铁谱图像 n 输入 WearIS 模型，识别结果 I_n ，并通过孤立区域去除算法，去除每个识别结果掩膜中可能存在的孤立区域，只保留磨粒掩膜，得到 I_n' 。再进行堆叠区域分离算法，遍历 I_n' 中的每个结果 ins_n^i ，查找 I_{n-1}' 中被 $ins_{n-2}^{l,k}$ 区域覆盖的结果 $\{ins_{n-1}^{l,h}, ins_{n-1}^{l,g}, \dots\}$ 是否仍出现在 I_n' 中；若仍存在，则此区域判定为磨粒堆叠区域，将 $\{ins_{n-1}^{l,h}, ins_{n-1}^{l,g}, \dots\}$ 加入 I_{n-1} ；否则，为 WearIS 模型误识别，此区域为 1 个整体，不存在磨粒堆叠，故删除 $\{ins_{n-1}^{l,h}, ins_{n-1}^{l,g}, \dots\}$ ，最终得到结果 I_{n-1}' 。然后，进行磨粒识别结果整合算法，遍历 I_{n-1}' 和 I_n' 的每个结果 ins_{n+1}^j 和 ins_n^i ，依据 IoU 和 IoM 指标，判定两结果之间的位置关系，并更新识别结果为 I_n'' ；若 ins_{n+1}^j 所在区域 j 覆盖 ins_n^i ，则将两者加入集合 I_n 中。最后，针对 I_n'' 内部可能存在的掩膜重叠问题，通过后处理算法决定重叠区域的归属，得到最终精细的识别结果 I_n''' 。需要说明的是，当 $n=1$ 时，只执行孤立区域去除算法；当 $n=2$ 时，不执行堆叠区域分离算法。




Fig. 10 Flow chart of progressive layer by layer recognition algorithm for wear particles

图 10 磨粒逐层递进式识别算法流程图

5 实验结果与分析

图 11 所示为 1 组序列图像逐层识别过程，图 12 所示为最终识别结果图。以图 11 中红色虚线框处的磨粒区域 1 为例：该区域在第 13 帧被识别为块状磨粒，置信度为 97%；而在第 14 帧中被识别为堆积的块状和链状磨粒，置信度分别为 98%和 92%，依据堆叠区域分离算法，仍需依据下一帧的识别结果来判定是否为堆叠磨粒，故当前帧中该区域仍作为块状磨粒；在第 15 帧该区域再次被识别为堆叠磨粒，因此，依据识别结果修正算法对该区域进行分离，其左侧为块状磨粒，右侧为链状磨粒。同理，依据该算法能够进一步从磨粒区域 1 中识别出堆叠的球形磨粒、块状磨粒和链状磨粒。此外，当磨粒因离焦逐渐模糊时，通过对比上一帧的识别结果依然能够保留已识别出的磨粒，如第 24~26 帧所示。




Fig. 11 Schematic diagram of the process of progressive layer by layer recognition of wear particles


图 11 磨粒逐层递进式分割部分过程示意图



Fig. 12 Final recognition result

图 12 最终识别结果

图 13 所示为测试集中 6 组不同磨粒分布、光照和噪声条件下铁谱序列图像的识别结果，可以看出，本文中设计的算法总体表现较好，能够准确地识别出序列图像中的各种磨粒，包括较难检测的小磨粒，如图 13(f)所示，尤其是隐藏在磨粒链中的异常磨粒，如图 13(a)、(b)和(e)中的球形磨粒、切削磨粒和块状磨粒等。对于面积较大的磨粒区域，能够准确地判定此区域是否存在堆叠磨粒，并将其分离，例如图 13(a)上方存在链状磨粒、块状磨粒和球形磨粒堆积，该算法可以准确地判定并将其分离；同时，对于左侧的链状磨粒，由于不存在不同类型磨粒的堆积，故认定其为 1 个整体。然而，该算法仍存在少量漏检、误检和欠分割现象，例如，图 13(a)中上方链状与块状磨粒之间存在细微欠分割；图 13(c) 中右下方单个链状磨粒被误检为 2 个堆叠的链状磨粒；图 13(d)中出现了球形磨粒的漏检。



(a)



(b)




Fig. 13 The identification results of six groups of wear particles obtained layer by layer

图 13 六组磨粒逐层递进式识别结果

磨粒逐层递进式识别算法的检测(Bbox)和分割(Segm)性能的量化评定结果列于表 2 和表 3 中, 其中测试集数量为 107 组。可以看出, 本文中设计的磨粒逐层递进式识别算法在 AP50 指标下, 分别取得了 82.67%和 80.92%的检测和分割结果, 且在其余各 AP 指标下也取得了较好的效果, 表明该算法具有较好的检测和分割性能; 同时, 其平均交并比结果(mean Intersection over Union, mIoU)为 75.64%, 表明该算法可以达到较为精细的分割效果。然而, 由于磨粒逐层递进式识别算法中包含多组循环遍历的过程, 导致其速度较慢, 达到 1.07 s/帧, 可能影响实际使用效率, 今后会在底层算法中进行改进。

表 2 磨粒逐层递进式识别算法在测试集上的结果

Table 2 The results of the progressive layer by layer recognition algorithm on the test set

Metric	AP	AP50	AP75	APs	APm	APl	mIoU	Time
Bbox	63.49	82.67	70.79	57.71	69.53	60.23	—	1.07 s
Segm	62.33	80.92	69.51	56.95	68.86	59.18	75.64	

磨粒逐层递进式识别算法对单一类别磨粒的测试结果列于表 3 中。可以看出, 该算法的整体检测效果较好, 尤其对异常磨粒, 如球形磨粒、氧化物磨粒和块状磨粒的检测和分割效果较好。然而, 由于 WearIS 模型对切削磨粒识别准确率低, 导致此类磨粒的最终检测和分割结果较差; 同时, 由堆叠区域分离算法可能导致少量链状磨粒出现过分割现象, 导致链状磨粒的识别准确率较低。

表 3 磨粒逐层递进式识别算法对单一类别磨粒的结果

Table 3 The results of the progressive layer by layer identification algorithm for a single class of wear particles

Metric	Block	Chain	Cutting	Sphere	Oxide
Bbox AP50	86.48	77.25	74.71	90.55	84.36
Segm AP50	84.69	74.42	72.88	89.68	82.93
mIoU	79.72	66.16	68.58	86.48	77.26

6 结论

本文中针对铁谱序列图像磨粒智能化识别进行研究，并结合计算机断层扫描技术提出了 1 种序列图像磨粒逐层递进式识别算法。可以得到以下结论：

a. 在 Cascade R-CNN 的基础上，通过引入 CBAM 注意力机制、设计变差级联检测器和改进分割分支结构，构建了单幅磨粒图像实例分割模型 WearIS。单幅铁谱图像测试集上的结果表明，其检测和分割的 AP50 值分别为 85.11%和 83.54%，优于当前主流单阶段和二阶段实例分割模型；

b. 提出了磨粒逐层递进式识别算法，在对当前铁谱图像进行实例分割的同时结合序列图像中前一帧的磨粒识别结果，依据 IoU 和置信度等信息修正当前帧的结果，从而最终识别铁谱图像所有磨粒。

c. 铁谱序列图像测试集上结果表明，在 AP50 指标下，其检测和分割的准确率为 82.67%和 80.92%，mIoU 为 75.64%；同时，随着图像逐渐清晰，磨粒识别的置信度和准确率也逐步提高。因此，本文中提出的磨粒逐层递进式识别算法有效降低了异常磨粒漏检和误检的概率。

参考文献

- [1] Qiu Lijuan, Xuan Zhengnan, Zhang Xingfang. Debris color image segmentaion by K-means clustering and ostu method[J]. Lubrication Engineering, 2014, 39(12): 101–104, 109(in Chinese) [邱丽娟, 宣征南, 张兴芳. 基于 K-means 聚类与最大类间方差的磨粒彩色图像分割[J]. 润滑与密封, 2014, 39(12): 101–104, 109]. doi:10.3969/j.issn.0254-0150.2014.12.021.
- [2] Chen Guo, Zuo Hongfu. 2-D maximum entropy method of image segmentation based on genetic algorithm[J]. Journal of Computer-Aided Design & Computer Graphics, 2002, 14(6): 530–534(in Chinese) [陈果, 左洪福. 图像分割的二维最大熵遗传算法[J]. 计算机辅助设计与图形学学报, 2002, 14(6): 530–534]. doi:10.3321/j.issn:1003-9775.2002.06.009.
- [3] Fu Jianping, Liao Zhenqiang, Zhang Peilin, et al. The segmenting method of ferrographic wear particle image based on two-dimension entropy threshold value[J]. Computer Engineering and Applications, 2005, 41(18): 204–206(in Chinese) [傅建平, 廖振强, 张培林, 等. 基于 2D 熵阈值的铁谱磨粒图像分割方法[J]. 计算机工程与应用, 2005, 41(18): 204–206]. doi:10.3321/j.issn:1002-8331.2005.18.061.
- [4] Jiang Liangzhou, Chen Guiming, Long Feng. Auto-threshold confirming segmentation for wear particles in ferrographic image[C]//2008 International Symposium on Computational Intelligence and Design. 2008, Wuhan, IEEE, 2008: 61–64. doi:10.1109/ISCID.2008.107.

- [5] Wang Jingqiu, Zhang Long, Wang Xiaolei. Ferrographic image segmentation by the method combining k-means clustering and watershed algorithm[J]. Journal of China University of Mining & Technology, 2013, 42(5): 866–872(in Chinese) [王静秋, 张龙, 王晓雷. 融合颜色聚类 and 分水岭算法的铁谱图像分割[J]. 中国矿业大学学报, 2013, 42(5): 866–872].
- [6] Wu Tonghai, Wu Hongkun, Du Ying, et al. Imaged wear debris separation for on-line monitoring using gray level and integrated morphological features[J]. Wear, 2014, 316(1–2): 19–29. doi:10.1016/j.wear.2014.04.014.
- [7] Wu Hongkun, Wu Tonghai, Peng Yeping, et al. Watershed-based morphological separation of wear debris chains for on-line ferrograph analysis[J]. Tribology Letters, 2014, 53(2): 411–420. doi:10.1007/s11249-013-0280-1.
- [8] Wang Jingqiu, Yao Panpan, Liu Wanlong, et al. A hybrid method for the segmentation of a ferrograph image using marker-controlled watershed and grey clustering[J]. Tribology Transactions, 2016, 59(3): 513–521. doi:10.1080/10402004.2015.1091534.
- [9] Wang Weihua, Yin Yonghui, Wang Chengtao. Feature extraction of wear debris shape and its identification with ANN[J]. Journal of China University of Mining & Technology, 2003, 32(2): 200–203(in Chinese) [王伟华, 殷勇辉, 王成焘. 磨粒形状特征提取及神经网络识别[J]. 中国矿业大学学报, 2003, 32(2): 200–203]. doi:10.3321/j.issn:1000-1964.2003.02.025.
- [10] Gu Daqiang, Zhou Lixia, Wang Jing. Ferrography wear particle pattern recognition based on support vector machine[J]. China Mechanical Engineering, 2006, 17(13): 1391–1394(in Chinese) [顾大强, 周利霞, 王静. 基于支持向量机的铁谱磨粒模式识别[J]. 中国机械工程, 2006, 17(13): 1391–1394]. doi:10.3321/j.issn:1004-132X.2006.13.017.
- [11] Li Shaocheng, Zuo Hongfu, Zhang Yanbin. Wear debris recognition for oil on-line monitoring system[J]. Optics and Precision Engineering, 2009, 17(3): 589–595(in Chinese) [李绍成, 左洪福, 张艳彬. 油液在线监测系统磨粒识别[J]. 光学精密工程, 2009, 17(3): 589–595]. doi:10.3321/j.issn:1004-924X.2009.03.020.
- [12] Wang Jingqiu, Wang Xiaolei. A wear particle identification method by combining principal component analysis and grey relational analysis[J]. Wear, 2013, 304(1–2): 96–102. doi:10.1016/j.wear.2013.04.021.
- [13] Schmidhuber J. Deep learning in neural networks: an overview[J]. Neural Networks, 2015, 61: 85–117. doi:10.1016/j.neunet.2014.09.003.
- [14] Fan Hongwei, Gao Shuoqi, Zhang Xuhui, et al. Intelligent recognition of ferrographic images combining optimal CNN with transfer learning introducing virtual images[J]. IEEE Access, 2020, 8: 137074–137093. doi:10.1109/ACCESS.2020.3011728.
- [15] Peng Yeping, Cai Junhao, Wu Tonghai, et al. A hybrid convolutional neural network for intelligent wear particle classification[J]. Tribology International, 2019, 138: 166–173. doi:10.1016/j.triboint.2019.05.029.
- [16] Wang S, Wu T H, Shao T, et al. Integrated model of BP neural network and CNN algorithm for automatic wear debris classification[J]. Wear, 2019, 426: 1761–1770. doi:10.1016/j.wear.2018.12.087.
- [17] Wang Jingqiu, Liu Xinliang, Wu Ming, et al. Direct detection of wear conditions by classification of ferrograph images[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2020, 42(4): 152. doi:10.1007/s40430-020-2235-4.
- [18] Peng Peng, Wang Jiugen. Wear particle classification considering particle overlapping[J]. Wear, 2019, 422: 119–127. doi:10.1016/j.wear.2019.01.060.
- [19] Fan Hongwei, Gao Shuoqi, Liu Qi, et al. Intelligent wear debris identification of gearbox based on virtual ferrographic images and two-level transfer learning[J]. International Journal of Pattern Recognition and

- Artificial Intelligence, 2022, 36(11): 2251012. doi:10.1142/s0218001422510120.
- [20] Peng Yeping, Cai Junhao, Wu Tonghai, et al. WP-DRnet: a novel wear particle detection and recognition network for automatic ferrograph image analysis[J]. Tribology International, 2020, 151: 106379. doi:10.1016/j.triboint.2020.106379.
- [21] Jia Fengguang, Wei Haijun, Sun Hongyuan, et al. An object detection network for wear debris recognition in ferrography images[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2022, 44(2): 67. doi:10.1007/s40430-022-03375-4.
- [22] He Lei, Wei Haijun, Wang Qixuan. A new target detection method of ferrography wear particle images based on ECAM-YOLOv5-BiFPN network[J]. Sensors, 2023, 23(14): 6477. doi:10.3390/s23146477.
- [23] Liu Xinliang, Wang Jingqiu, Sun Kang, et al. Semantic segmentation of ferrography images for automatic wear particle analysis[J]. Engineering Failure Analysis, 2021, 122: 105268. doi:10.1016/j.engfailanal.2021.105268.
- [24] Liu Xinliang, Cheng Liang, Chen Guoning, et al. Recognition of fatigue and severe sliding wear particles using a CNN model with multi-scale feature extractor[J]. Industrial Lubrication and Tribology, 2022, 74(7): 884–891. doi:10.1108/ilt-03-2022-0088.
- [25] Liu Xinliang, Zhang Longquan, Leng Sheng, et al. An autofocus algorithm for fusing global and local information in ferrographic images[J]. Chinese Optics, 2024, 17(2): 423-434(in Chinese)[刘信良, 张龙泉, 冷晟, 等. 融合全局和局部信息的铁谱图像自动对焦算法[J]. 中国光学(中英文), 2024, 17(2): 423-434]. doi: 10.37188/CO.2023-0124.
- [26] An Chao, Wei Haijun, Liu Hong, et al. Ferrographic wear debris intelligent segmentation and recognition based on mask R-CNN[J]. Lubrication Engineering, 2020, 45(3): 107–112(in Chinese) [安超, 魏海军, 刘弘, 等. 基于 Mask R-CNN 的铁谱磨粒智能分割与识别[J]. 润滑与密封, 2020, 45(3): 107–112]. doi:10.3969/j.issn.0254-0150.2020.03.019.
- [27] He K, Gkioxari G, Dollar P, et al. Mask R-Cnn [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 386-397.
- [28] Sun Kang, Liu Xinliang, Chen Guoning, et al. Wear debris recognition and quantification in ferrography images by instance segmentation[J]. Tribology Transactions, 2022, 65(3): 508–518. doi:10.1080/10402004.2022.2037800.
- [29] Wang Shuo, Wan Miao, Wu Tonghai, et al. Optimized Mask-RCNN model for particle chain segmentation based on improved online ferrograph sensor[J]. Friction, 2024, 12(6): 1194–1213. doi:10.1007/s40544-023-0800-4.
- [30] Guan Haojian, He Shizhong, Li Qiuqiu, et al. A review of convolutional neural networks in equipment wear particle recognition[J]. Tribology, 2022, 42(2): 426-445(in Chinese)[关浩坚, 贺石中, 李秋秋, 等. 卷积神经网络在装备磨损颗粒识别中的研究综述[J]. 摩擦学学报, 2022, 42(2): 426-445]. doi: 10.16078/j.tribology.2021025.
- [31] Cai Z W, Vasconcelos N. Cascade R-CNN: high quality object detection and instance segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(5): 1483–1498. doi:10.1109/TPAMI.2019.2956516.
- [32] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016, Las Vegas. IEEE, 2016: 770–778. doi:10.1109/CVPR.2016.90.
- [33] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017, Honolulu. IEEE, 2017: 936–944. doi:10.1109/CVPR.2017.106.