

编号 202130120



南京航空航天大学

本科毕业设计（论文）

题 目

基于深度学习的
复杂背景铁谱图像分析方法

学生姓名	王毅博
学 号	202130120
学 院	通用航空与飞行学院
专 业	交通运输（民航机务工程）
班 级	2021301
指导教师	陈果 教授

二〇二五年五月

南京航空航天大学

本科毕业设计（论文）诚信承诺书

本人郑重声明：所呈交的毕业设计（论文）是本人在导师的指导下独立进行研究所取得的成果。尽我所知，除了文中特别加以标注和致谢的内容外，本设计（论文）不包含任何其他个人或集体已经发表或撰写的成果作品。对本设计（论文）所涉及的研究工作作出贡献的其他个人和集体，均已在文中以明确方式标明。

作者签名：

王毅博

日期：2025 年 5 月 19 日

南京航空航天大学

毕业设计（论文）使用授权书

本人完全了解南京航空航天大学有关收集、保留和使用本人所送交的毕业设计（论文）的规定，即：本科生在校攻读学位期间毕业设计（论文）工作的知识产权单位属南京航空航天大学。学校有权保留并向国家有关部门或机构送交毕业设计（论文）的复印件和电子版，允许论文被查阅和借阅，可以公布论文的全部或部分内容，可以采用影印、缩印或扫描等复制手段保存、汇编论文。保密的论文在解密后适用本声明。

论文涉密情况：

☒ 不保密

☐ 保密，保密期（起讫日期：_____）

作者签名：

王毅博

导师签名：

江

日期：2025 年 5 月 19 日

日期：2025 年 5 月 19 日

摘 要

铁谱分析技术能够有效反映出油液中磨粒的分布与类型，对于及时发现设备故障和保障设备稳定运行具有重要意义。然而，对于背景复杂的铁谱图像，传统分割方法难以有效区分出磨粒与背景；同时，图像中普遍存在的油泥附着现象进一步干扰了磨粒的识别，严重影响分析结果的准确性。相比于传统方法，深度学习具有自动特征提取、泛化能力强等优势，适用于处理背景复杂、干扰因素多的图像任务。鉴于此，本文开展基于深度学习的铁谱图像智能分割与磨粒识别方法研究，主要研究工作如下：

（1）提出一种使用 AFNet 模型的复杂背景铁谱图像分割方法。利用传统分割方法初步提取掩码，筛选出效果较佳的图像作为训练样本。通过训练 AFNet 模型，获得适用于铁谱图像分割的模型，再结合伽马变换、重叠分块预测进行图像处理，实现优于传统方法的分割结果。

（2）提出一种结合基于密度的噪声应用空间聚类（DBSCAN）和 YOLOv12 模型的磨粒识别方法。借助 DBSCAN 算法对 AFNet 模型生成掩码进行聚类，提取磨粒与油泥区域，实现自动标注并构建数据集。然后训练并验证测试 YOLOv12 模型，实现对磨粒目标的有效识别。

通过真实航空发动机附件机匣试车铁谱图像进行方法验证与测试，验证了所提方法在磨粒分割与识别中的有效性与准确性。

关键字：铁谱图像分析，深度学习，图像分割，目标检测

ABSTRACT

Ferrography analysis technology can effectively reflect the distribution and type of wear particles in the oil, which is of great significance for timely detection of equipment faults and ensuring stable operation of the equipment. However, for ferrography images with complex backgrounds, traditional methods have difficulty effectively distinguishing wear particles from the background. At the same time, the common phenomenon of oil sludge adhesion in the images further interferes with the identification of wear particles, seriously affecting the accuracy of the analysis results. Compared with traditional methods, deep learning has advantages such as automatic feature extraction and strong generalization ability, and is suitable for processing images with complex backgrounds and a lot of noise. In view of this, this paper conducts research on intelligent segmentation and wear particle recognition methods for ferrography images based on deep learning. The main research work is as follows:

(1) A complex background ferrography image segmentation method based on AFNet model is proposed. Traditional segmentation methods are used to initially extract masks, and images with better effects are selected as training samples. By training AFNet, a model suitable for ferrography image segmentation is obtained, and then combined with gamma transformation and overlapping block prediction for image processing, achieving better segmentation results than traditional methods.

(2) A wear particle recognition method based on Density-Based Spatial Clustering of Applications with Noise (DBSCAN) and YOLOv12 model is proposed. DBSCAN algorithm is used to cluster the masks generated by the AFNet model, extract the wear particle and oil sludge regions, and realize the automatic labeling and construction of the dataset. Then, the YOLOv12 model is trained and verified for testing, achieving effective recognition of wear particle targets.

The proposed methods are tested on real ferrography images which from the test run of an aviation engine accessory gearbox, verifying their effectiveness and accuracy in wear particle segmentation and recognition.

KEY WORDS: Ferrography image analysis, Deep learning, Image segmentation, Object detection

目 录

第一章 绪论	1
1.1 研究背景	1
1.2 国内外研究现状	2
1.2.1 铁谱图像分割方法	2
1.2.2 铁谱图像识别方法	4
1.2.3 深度学习与铁谱图像分析	4
1.3 问题的提出及本文研究内容	6
1.3.1 现有铁谱图像分析存在的问题	6
1.3.2 研究内容	7
1.4 论文组织结构	8
第二章 基于 AFNet 的复杂背景铁谱图像分割方法	9
2.1 引言	9
2.2 铁谱图像集介绍	9
2.3 传统铁谱图像分割方法	10
2.3.1 颜色空间特征	10
2.3.2 K-means 聚类算法	10
2.3.3 颜色特征+K-means 聚类的铁谱图像分割方法	11
2.4 基于 AFNet 的铁谱图像分割方法	13
2.4.1 卷积神经网络	13
2.4.2 AFNet 模型	14
2.4.3 AFNet 数据集构建	16
2.4.4 AFNet 模型训练	18
2.4.5 AFNet 模型分割结果	21
2.5 小结	25
第三章 基于 DBSCAN 与 YOLOv12 的磨粒识别方法	27
3.1 引言	27
3.2 DBSCAN 实例区分	27
3.2.1 DBSCAN 密度聚类算法	27
3.2.2 DBSCAN 聚类结果	29
3.3 基于 YOLOv12 的磨粒识别方法	31
3.3.1 YOLO 模型	31
3.3.2 YOLO 数据集样本构建	32
3.3.3 YOLOv12 模型训练	35
3.3.4 YOLOv12 模型识别结果	38
3.4 小结	39
第四章 总结与展望	41
4.1 研究总结	41
4.2 研究展望	41
参考文献	43
致谢	45

第一章 绪论

1.1 研究背景

机械零件的磨损与设备运行状态密切相关。研究数据显示：近八成的机械部件失效源自于磨损问题，而超过五成的严重机械事故由润滑失效或严重磨损所引发。在欧美的工业发达国家中，每年因磨损造成的经济损失约占其 GDP 总值的 2%-7% 区间^[1]。在生产中，磨损会降低设备工作效率与精度，并进一步加剧机械零部件的损耗，导致一系列故障问题，进而严重影响设备正常运作甚至造成重大事故。因此，使用有效的故障诊断技术监测设备磨损状况，对及时发现设备潜在的故障与维护设备正常的运转具有重要实际意义。

油液分析技术是一种无损检测诊断方法，可用于判断当前机械设备状态以及可能即将要发生的故障，有效监测润滑油污染和机械磨损情况^[2]。其中的铁谱分析技术在机械设备故障诊断与状态监测应用广泛。该方法通过高磁场将磨粒从油液中分离，并在显微镜的观察下，研究和分析磨粒特征（尺寸特征、形态特征等）和成分，以此确定设备的磨损状况，可为监测机器磨损状况和正确诊断设备故障提供了重要依据。

常见的铁谱仪主要有四种类型，包括直读铁谱仪、在线铁谱仪、分析铁谱仪和旋转铁谱仪等，如图 1.1 所示。



(a) YTZ-5 直读式铁谱仪



(b) PULE-8A 在线铁谱仪



(c) YTF-8 双联分析式铁谱仪



(d) JLHMTP-SL 旋转铁谱仪

图 1.1 铁谱仪^[3]

铁谱图像中的磨粒形式主要包括：正常滑动磨粒、严重滑动磨粒、疲劳磨粒、层状磨粒、切削磨粒、球状磨粒、红色氧化物与黑色氧化物等^[4]，如图 1.2 所示。




图 1.2 磨粒类型^[4]

1.2 国内外研究现状

传统铁谱分析工作长期依赖人工操作，存在效率低下、精度不足、智能化水平有限以及结果易受操作人员经验影响等缺陷。为此，在过去十余年中，国内外高校、科研机构及企业研究人员致力于开发基于图像处理与识别的检测系统，以进一步提高分析准确性并实现自动化处理。铁谱图像分析主要包含两方面：一是图像分割，作用是实现磨粒等检测目标与背景的分离；二是图像识别，实现识别出不同区域、不同类型磨粒。本文将从上述两方面进行国内外相关研究介绍。




图 1.4 铁谱图像分析流程

1.2.1 铁谱图像分割方法

铁谱图像分割是指利用分割算法分离图像中的磨粒与背景，是铁谱图像分析中的重要步骤，图像的分割质量会直接影响到后续磨粒特征提取与识别的准确性。传统的铁谱图像分割方法主要包括基于阈值的图像分割方法和基于聚类的图像分割方法。

（1）基于阈值的铁谱图像分割方法

基于灰度阈值的二值化分割是早期磨粒检测的主要技术手段，其核心思路是基于铁谱图像中磨粒与背景的灰度分布特征，通过设定适当阈值来实现两者的区分。高孝清等^[5]指出，一般的磨粒图像中没有明显的双峰特性，使用传统阈值二值化分割难以将目标与背景分离。无论阈值设置为何，总会遗漏部分磨粒，导致分割不完全。相比于灰度图，彩色铁谱图像中包含更多的信息，更适合用于磨粒分割。

最大类间方差阈值法^[6]是由 Otsu 提出一种根据图像灰度直方图分布确定分割阈值的图像分割方法。陈果等^[7,8]将最大类间方差阈值法应用于彩色图像分割中，利用正交彩色特征量 I_1 、 I_2 、 I_3 ，提出一种基于彩色特征量直方图和一种使用 Fisher 评价准则的自动选取颜色特征的方法，实现了彩色磨粒图像的自动分割。Jiang 等^[9]针对阈值分割方法依赖人工调整、效率低、适应性差的特点，提出了一种基于图像目标区域面积及其二阶差分的铁谱图像自动阈值分割算法。

邢凡等^[10]开发了一种基于小波变换的多阈值分割技术，该方法将彩色铁谱图像分解成 RGB 通道图像，分别对各通道实施小波变换多阈值分割，通过划分磨粒区域后重组图像，实现了对背景区域、常规磨粒沉积链与异常大型磨粒的精准区分。刘万龙和王静秋^[11]提出了一种在 CIELAB 颜色空间下基于人工蜂群算法的彩色铁谱图像背景减除方法，该方法通过人工蜂群算法分别分割铁谱图像的 L、a、b 三通道灰度图，最终得到消除背景的彩色铁谱图像，实现磨粒与背景的分离。

（2）基于聚类的铁谱图像分割方法

相比于通过划定灰度阈值范围实现图像分割，颜色是区分不同区域最自然和直观的方法，往往能得到更好的效果。而这正是基于聚类的图像分割方法的核心思想之一。基于聚类的图像分割是从机器学习聚类理论中引入的一种方法^[12]，通过将图像像素或区域按照颜色、纹理、空间位置等特征的相似性自动进行分组，形成语意连贯的独立区域。其核心是利用聚类算法将特征空间中相近的像素归为同一类别，从而实现目标与背景的分离。

陈桂明等^[13]通过结合模糊 C 均值聚类和聚类树分析方法，提出了一种基于颜色特征的自动分割方法，在 RGB 与 HSV 三维空间下对铁谱图像进行磨粒与背景分割，结果表明在铁谱图像分割中，RGB 空间相较于 HSV 空间的分割效果更稳定。王静秋等^[4]在 CIELAB 颜色空间下将 K-means 均值聚类与标记分水岭算法相结合，实现了铁谱图像磨粒沉积链的自动分割，消除了背景因素在磨粒沉积连分割中的不良影响。Wang 等^[14]提出一种用于分割沉积链大磨粒和细小磨屑的分割方法，该方法先是使用标记分水岭算法分割铁谱图像，

获得磨粒的初始分割，然后再采用改进的灰色聚类算法对过分割区域进行合并。杨海等^[15]利用标记分水岭、自适应阈值法与灰色聚类分割并改进磨粒图像，提供了一种磨粒链的自适应分割方法。

1.2.2 铁谱图像识别方法

铁谱图像在经过分割等处理后，需要进一步识别提取铁谱图像中的磨粒特征判断磨粒的类型。传统的磨粒识别主要依赖于浅层机器学习与 BP 神经网络，需要专业人员提取磨粒性质的特征，包括形状、颜色、几何等参数，以此实现对磨粒的识别判断。

基于浅层机器学习的磨粒识别方法主要包括：基于 D-S 证据理论的方法、基于支持向量机的方法、基于灰色理论的方法。李艳军等^[16]提出一种基于 D-S 证据理论的磨粒识别方法，该方法通过研究筛选出 8 类磨粒形态特征参数等，构建了一个 D-S 证据理论的融合识别框架，有效解决了严重滑动磨粒与疲劳磨粒易混淆的问题。Stachowiak 等^[17]提取磨粒表面纹理与形态特征，使用支持向量机实现对疲劳、磨损、粘着三类磨粒的有效分类。石宏等^[18]通过引入非线性自适应权重调节权重与粒子变异算法改进了粒子群算法，同时优化支持向量机的惩罚参数与核参数，建立了一种自适应磨粒识别模型。王国忠等^[19]提出了一种融合主成分分析与灰色关联分析的磨粒识别方法，一是将主成分分析与欧式距离结合识别红色与黑色氧化物磨粒，二是将主成分分析与灰色关联分析结合识别严重滑动与疲劳磨粒。

Rumelhart 等^[20]提出的 BP 神经网络（Back Propagation Neural Network）由具有自学习与处理非线性问题等优势，在铁谱分析中常用于磨粒识别。左洪福等^[21]提出了一套磨粒形态学描述子提取磨粒特征，以此为输入参数构建了一种 BP 神经网络，并采用因子模糊化加速网络训练，实现了磨粒的自动识别分类。罗炳海等^[22]通过对磨粒图像进行预处理与特征参数提取，采用 PCA 对提取的参数进行优化，再使用 BP 网络实现优于传统 BP 网络的磨粒类型自动识别。田勇等^[23]使用共轭梯度法与 L-M 算法改进传统 BP 网络，结合数据归一化与冗余处理策略，实现了优化后的 BP 网络在磨损预测方面泛化能力的提升。

1.2.3 深度学习与铁谱图像分析

深度学习是一种通过多层神经网络自动提取数据的多层次抽象特征的机器学习方法。与传统方法相比，深度学习具有自动特征提取、良好的泛化能力等优势。其中，卷积神经网络（CNN）具有良好的自学习性，训练中诸如梯度消失或爆炸、容易过拟合等问题已得到明显改善，其模型目前常作为主干网络用于处理背景复杂、干扰因素多的图像任务。鉴于此，基于深度学习的铁谱图像分析方法在近些年有着较多的发展。

（1）卷积神经网络的发展

在图像分割方面,2012年,Krizhevsky等^[24]构建了名为 AlexNet 的卷积神经网络模型,他们在模型中使用了 ReLU 激活函数,提升模型效果的同时加速了模型收敛速度,并提出了 Dropout 正则化方法,用于解决全连接层容易过拟合的问题。随后,Ronneberger等^[25]提出采用了独特的 U 型结构的 U-Net 模型,该模型结构由捕获上下文的收缩路径和实现精确定位的对称扩展路径组成,并验证了该模型在少样本、高精度医学图像分割中的有效性。Li等^[26]在 U-Net 的基础上,引入位置注意力模块、多尺度特征融合模块以及语义聚合模块,构建 AFNet 模型用于如图 1.5 所示的视网膜血管分割,实现模型在灵敏度、准确率等关键指标以及分割性能上的有效提升。

在目标检测方面,Girshick等^[27]建立了首个目标检测卷积神经网络 R-CNN,但存在计算量大、精度低、不可端到端优化等问题而难以实际应用。Redmon等^[28]提出 YOLO (You Only Look Once) 目标检测网络,单个神经网络可在一次评估中直接从完整图像中预测边界框和类别概率,实现了对检测性能端到端的优化。Tian等^[29]提出基于注意力机制的 YOLOv12 模型,引入区域注意力模块并提出残差高效层聚合网络,有效降低了计算复杂度并提升了模型训练稳定性;相比 YOLOv10 与 YOLOv11,如图 1.6, YOLOv12 对图像中物体的感受也有着一定的提升。




图 1.5 AFNet 模型分割视网膜血管^[26]



图 1.6 YOLOv10-12 对物体的感受^[29]

（2）卷积神经网络在铁谱图像分析领域的应用

卷积神经网络模型的快速发展,以及其在复杂图像任务处理中的优秀表现,为铁谱图像分析提供了一种新思路。在目前的基于深度学习的铁谱图像分析中,通常将图像分割与磨粒识别集成为一体^[12,30-35],实现端到端的分割与识别,大大减少了分析过程中需要人工参与的步骤。

如图 1.7 所示, Liu 等^[31]建立了一个用于磨粒分割与识别的模型 DWear, 该模型的设计中引入多尺度空洞空间金字塔模块, 通过级联结构和互质空洞率组, 扩大了模型感受野并减少网格效应, 又结合了全连接条件随机场优化分割掩码的边界, 实现了对疲劳、严重、链状、球状、切削、氧化物六类磨粒的有效分割与识别。




图 1.7 DWear 模型对磨粒图像的分割与识别^[31]

He 等^[33]提出了一种基于改进 YOLOv5s 的 TCBGY-Net 模型, 通过在模型中构建或引入 C3TR 结构、CBAM 注意力机制以及双向特征金字塔网络, 用于解决磨粒图片中存在的背景干扰、小目标漏检与重叠颗粒识别困难等问题。古莹奎等^[34]基于改进 YOLOv8n 模型, 引入高效多尺度卷积与高效局部注意力, 并采用高级特征筛选金字塔网络, 实现模型在磨粒种类复杂、特征提取困难情况下对磨粒的有效识别。

1.3 问题的提出及本文研究内容

1.3.1 现有铁谱图像分析存在的问题

尽管传统的铁谱图像分析方法已经能够得到比较准确的结果, 但是仍然存在如下问题:

- (1) 传统的铁谱图像分割方法依赖于专业人员设计特征、可调参数多, 同时存在适用性差, 对与磨粒图像要求质量高等缺点。
- (2) 依赖于浅层机器学习算法传统磨粒识别方法, 其算法复杂度高、参数多, 需要耗费大量时间人工调试。
- (3) 依赖 BP 神经网络的磨粒识别方法, 其网络训练需要合适的神经元数量与大量的样本, 否则容易出现过拟合的现象。

以上传统方法中存在的问题, 大大制约了铁谱图像分析自动化、智能化的发展。

而基于深度学习的铁谱图像分析方法, 在一定程度上克服了传统方法的一些缺陷, 但就目前而言, 依旧存在着下列不足:

（1）模型的泛化能力较弱

跨设备或实验室采集的铁谱图像通常会存在光源、分辨率等差异，而模型依赖于特定的数据分布，迁移到新场景时分割或识别精度往往下降明显。

（2）所用样本缺乏代表性

用于模型训练和测试的多是一些质量比较高且图像尺寸比较小的铁谱图像，如图 1.7 所示，磨粒和背景的界限明显且不存在光斑等干扰因素。而实际中往往会如遇到图 1.8 所示，图像分辨率高（ $2952 \times 1944\text{px}$ ）、存在大量干扰且磨粒与油泥混杂的铁谱图像。

（3）依赖人工制作数据集

铁谱图像分析神经网络模型^[12,30-35]所用的训练集，需要几十张乃至数千张的人工标注好的铁谱图像，但人工标注过程需要消耗大量人力又易受主观经验影响，在样本较少难以达到良好的效果。




图 1.8 背景复杂的铁谱图像

1.3.2 研究内容

针对目前铁谱图像分析领域中传统方法和深度学习方法存在的问题和面临的调整，本文基于航空发动机附件机匣试车铁谱图像，对铁谱图像数据集构建方法以及分割与识别方法进行了研究：

（1）针对传统分割方法复杂背景铁谱图像分割失效问题提出一种使用 AFNet 模型的复杂背景铁谱图像分割方法。利用传统分割方法初步提取掩码，筛选出效果较佳的图像作为训练样本。通过训练 AFNet 模型，获得适用于铁谱图像分割的模型，再结合伽马变换、重叠分块预测进行图像处理，实现优于传统方法的分割结果。

（2）针对人工手动标注训练集繁琐问题，提出一种结合 DBSCAN 和 YOLOv12 模型的磨粒识别方法。借助 DBSCAN 算法对 AFNet 模型生成掩码进行聚类，提取磨粒与油泥区域，实现自动标注并构建数据集。然后训练并验证测试 YOLOv12 模型，实现对磨粒目标的有效识别。

1.4 论文组织结构

本论文的组织结构如下：

第一章 阐明课题的研究背景，总结了国内外在该领域内的研究。分析了当前铁谱图像磨粒分割中面临的困难与挑战，并提出了本文的研究内容与方法；

第二章 利用传统铁谱图像分割方法构建分割掩码数据集，结合图像和模型优化方法，训练并验证了 AFNet 进行铁谱图像分割的有效性 with 准确性；

第三章 利用 AFNet 分割结果和 DBSCAN 算法自动构建磨粒识别数据集，使用 YOLOv12 模型实现对铁谱图像中磨粒和油泥的分类识别；

第四章 总结全文，回顾并分析本文中的研究方法，对今后的研究做出展望。




图 1.9 论文结构框架

第二章 基于 AFNet 的复杂背景铁谱图像分割方法

2.1 引言

铁谱图像的复杂性不仅仅体现在图像中磨粒种类的多样性，更体现在不同批次之间工况环境差异等客观因素与背景颜色与亮度明暗多变、磨粒清晰度不一等主观因素方面。传统的基于阈值与聚类的磨粒分割方法往往仅针对少数类型的铁谱图像，而对以上背景复杂的铁谱图像的磨粒分割质量不稳定、易失效。基于深度学习的图像分割技术的出现，为复杂背景下铁谱图像磨粒分割方法提供了强有力的工具。

如图 2.1，本章首先介绍了本文研究所使用的铁谱图像来源；随后采用一种颜色空间结合 K-means 的传统铁谱图像分割方法，初步获得用于 AFNet 训练与验证的掩码，然后提出一套图像与模型优化方法，最终获得优于传统分割方法的铁谱图像分割结果。




图 2.1 本章方法简要流程

2.2 铁谱图像集介绍

本文中用于模型训练、验证与测试的铁谱图像，均来自某单位生产的航空发动机附件机匣的产品试车。试车使用的滑油为航空涡轮发动机用合成润滑油（4050），其结果为产品正常。试车过程中实施了油液监控，试验分厂每个循环共计送检 3 瓶油样，每 10 小时为一轮循环，采集了前 50 轮循环共 43 批次的油液检测结果（其中 20、28、33、35、37、38、44 轮未拍摄铁谱图像）。其中，每轮拍摄 1-6 张图像，共获得 152 张放大倍数为 100 倍、分辨率大小为 $2592 \times 1944\text{px}$ 的彩色铁谱图像。

由于铁谱图像由多人拍摄完成，不同操作人员间的操作差异导致图像背景颜色与亮度存在明显差异，而且部分图像中存在点光源、大量杂质以及噪声等干扰。原始铁谱图像的右下角有红色标注的比例尺，为防止其在后续分析产生影响，选择剪裁去除并将原图像大小调整为 $2592 \times 1700\text{px}$ 。图像编号命名方式为“取油轮次- 轮次内序号-总序号”。

2.3 传统铁谱图像分割方法

2.3.1 颜色空间特征

彩色图像的表达模型建立在三维空间，称为彩色空间或颜色空间，由三个相对独立的变量构成的空间坐标。对于传统分割，选择合适的颜色空间十分重要。颜色空间从应用角度可分为两类：一类是面向显示器等硬件设备的颜色空间，如 RGB、CMY；另一类是面向视觉和彩色分析处理的颜色空间，如 HIS、LAB。

(1) RGB 颜色空间

RGB 颜色空间在计算机技术中广泛使用，是一种建立在三种基色红（R）、绿（G）、蓝（B）的加性混合基础上的颜色空间。 R 、 G 、 B 分量的值可用笛卡尔坐标系的三个轴来表示，黑色位于原点（0,0,0），白色位于顶点（255,255,255），如图 2.2 所示，RGB 空间内的不同颜色位于边长 255 的立方体表面或内部。

(2) LAB 颜色空间

LAB 颜色空间中，颜色由 L^* 、 a^* 、 b^* 三个分量表示，如图 2.3 所示，其中 L^* 表示亮度分量，取值为[0,100]； a^* 表示从绿色到红色的范围，取值为[-128,127]； b^* 表示从蓝色到黄色的范围，取值为[-128,127]。与 RGB 空间不同的是，LAB 空间的亮度和颜色是分离的，可以更好地反映图像真实色彩。




图 2.2 RGB 颜色空间^[4]




图 2.3 LAB 颜色空间^[4]

2.3.2 K-means 聚类算法

K-means 是一种基于距离的聚类算法，旨在将数据划分为 k 个互不重叠的紧凑且独立的类簇。其核心思想是通过迭代优化，使每个样本点与其所属簇的中心点之间的欧氏距离平方和最小化，从而实现类内高内聚、类间高分离的聚类效果。

K-means 算法是个不断迭代收敛的过程，迭代包含两个步骤。先是选择 k 个簇的中心，并将每个数据点逐个划分到与其距离最近的中心的簇，得到初步聚类结果。然后根据每个簇内所有数据点更新簇中心；重复以上步骤，直到结果收敛为止。具体迭代过程如下^[36]：

首先根据给定的初始中心值 $(\bar{x}^{(1)}, \bar{x}^{(2)}, \dots, \bar{x}^{(k)})$ ，求一个划分 C ，使得目标函数极小化：

$$\min_C \sum_{l=1}^k \sum_{C(i)=l} \|x^{(i)} - \bar{x}^{(l)}\|^2 \quad (2.1)$$

在簇中心确定的条件下，将每个数据点分到与其最近的中心 $x^{(l)}$ 所在的簇 C_l 中。然后，对给定的划分 C ，再求得各个簇中心 $(\bar{x}^{(1)}, \bar{x}^{(2)}, \dots, \bar{x}^{(k)})$ ，使得目标函数极小化：

$$\min_{\bar{x}^{(1)}, \bar{x}^{(2)}, \dots, \bar{x}^{(k)}} \sum_{l=1}^k \sum_{C(i)=l} \|x^{(i)} - \bar{x}^{(l)}\|^2 \quad (2.2)$$

在划分确定的条件下，使得数据点与其所属簇中心的距离总和最小。对于每个包含 N_l 个数据点的簇 C_l ，更新其均值 $\bar{x}^{(l)}$ ：

$$\bar{x}^{(l)} = \frac{1}{N_l} \sum_{C(i)=l} x^{(i)}, \quad l=1, 2, \dots, k \quad (2.3)$$

重复（2.2）与（2.3）两个步骤，直到划分结果收敛，得到最终的聚类结果。

2.3.3 颜色特征+K-means 聚类的铁谱图像分割方法

（1）分割原理介绍

颜色特征+K-means 方法是一种代表性的基于聚类的铁谱图像分割方法，其核心思想是：将不同区域在 RGB 或 LAB 等三维颜色空间上的差异转化为三维欧式空间中距离的远近。如图 2.4 所示，使用合适的计算方法将 RGB 或 LAB 颜色空间的三维信息压缩至二维，然后将该二维信息与每个像素的坐标信息结合组成三维欧式空间坐标，最后基于该三维欧式空间坐标使用 K-means 聚类将磨粒与背景分离。





图 2.4 颜色特征+K-means 的铁谱图像分割方法演示


(2) 部分分割结果展示

该铁谱图像分割方法对于背景颜色统一、无光斑、无暗斑、无杂质、噪点少的高质量铁谱图像分割效果良好，能较准确地将磨粒与背景分离开，如图 2.5 与图 2.6 中 (a)~(f) 所示。

但是在实际状况下，由于工况的变化、操作人员拍摄水平不一、背景光源的差异以及杂质的存在，不同批次的铁谱图像容易产生较大的差异且难以保证图片质量，经常得到含有光斑或暗斑、杂质较多、亮度不一的背景复杂的铁谱图像。对于背景复杂的铁谱图像，K-means 无法通过三维欧式空间距离得到正确的聚类结果。而且由于影响失效的因素不同，仅仅通过调整算法参数（如增加或减少聚类数 k ）无法稳定解决失效问题。如图 2.4 与图 2.5 中 (e)~(h) 所示。



图像 2.5 待分割铁谱图像



图像 2.6 传统方法分割效果

对于大部分传统铁谱图像分割方法的分割失效问题而言，经过大量的参数调整设置与长时间的调试也未必能得出效果满意的分割图像。面对不同的失效形式，传统分割方法通常要引入对应的特例解决方法。而在复杂背景下，使用传统分割方法可能会出现多种失效形式，但引入过多的特例解决方法会导致算法复杂度骤升与计算效率降低，并不适合当前实际工况下铁谱图像类型多、干扰因素多等特点。

2.4 基于 AFNet 的铁谱图像分割方法

2.4.1 卷积神经网络

卷积神经网络是一类含有卷积运算并且具有深度结构的前馈神经网络，是深度学习的一种代表性算法。如图 2.7 所示，卷积神经网络结构由输入层、卷积层、池化层、全连接层和输出层构成，其中的卷积层和池化层交替设置。




图 2.7 卷积神经网络结构示意图

（1）输入层

输入层的主要任务是对输入数据进行预处理，常用的方法包括去均值和归一化，目的是消除量纲差异，为后续网络提供格式统一且数值规范的数据，避免因原始数据尺度不一导致训练不稳定等问题。其核心原理是将不同格式的输入数据转换为统一的张量结果，满足网络处理要求。

（2）卷积层^[37]

卷积层的主要任务是通过局部连接和参数共享提取经过输入层预处理的数据内容的特征值。如图 2.8 示，卷积核在计算的时候，按照设定好的步长移动扫描图像，但卷积核中的参数和偏差固定不变，即卷积核参数共享。网络局部连接和卷积核参数共享作为卷积

神经网络的两大核心思想，其目的是减少神经元的参数数量，使运算变得更简洁高效。通过逐层的卷积，卷积核可在某一层覆盖完整图像。

(3) 池化层^[37]

池化层的主要任务是对特征图进行下采样，以此实现压缩数据并增强鲁棒性。其原理是对局部区域进行聚合操作，常用的池化方法包括最大池化、平均池化和自适应池化等。池化层的作用主要体现在三个方面：一是降低特征图的空间尺寸，减少后续步骤的计算量；二是抑制细节噪声，提升模型泛化能力；三是引入平移不变性，使网络对目标的微小位置变化不敏感。尽管池化会丢失部分特征信息，但是其在平衡计算量和特征保留之间依然十分重要。




图 2.8 卷积原理示意图




图 2.9 池化示意图

(4) 全连接层

全连接层的主要任务是把经过卷积层提取的局部特征重新通过权值矩阵组成完整的图像。图像经过多次卷积和池化形成的特征图展开成一个一维向量，然后输入到全连接网络中进行训练，最后通过全连接层进行分类。

(5) 输出层

输出层的主要作用是根据任务类型将网络最终结果映射到目标空间。对于图像分类问题，输出层使用逻辑函数或归一化指数函数输出分类标签。在图像语义分割中，输出层则直接输出每个像素的分类结果。

2.4.2 AFNet 模型

结合铁谱图像背景复杂、图像间差异大、可用样本少等问题，选择合适的图像分割神经网络模型十分重要。综合分割任务要，AFNet 模型较好地满足了这一要求。

AFNet 模型是一种用于视网膜毛细血管图像分割任务的卷积神经网络。该模型在 U-Net 的基础上，减少了编码层与解码层数量，添加了位置注意力模块、多尺度特征融合模块、语义聚合模块三个模块。如图 2.10 所示，AFNet 主要由特征编码器、多尺度特征融合模块、语义聚合模块、特征解码器四部分组成。




图 2.10 AFNet 模型结构

（1）AFNet 重要模块功能^[26]

位置注意力模块



位置注意力可以将位置信息加入到通道注意力中，这使得模型即能捕获跨通道信息，还能捕获目标空间信息。通过分析每个位置之间的相关性，将局部特征与全局信息结合，该模块有助于模型关注待提取目标的特征。

多尺度特征融合模块

如图 2.11 所示，多尺度特征融合模块采用多比率空洞卷积并行结构，通过共享卷积权重降低参数量。每个分支后位置注意力机制，可以增强网络的特征提取能力。而尺度感知模块可以动态选择合适的尺度特征进行融合。综合来说，该模块的引入有助于提取细长目标。

语义聚合模块

卷积神经网络中的池化会导致部分特征信息丢失，而语义聚合模块可以将丢失的信息进行补全，并对编码器中的语义信息与解码器中的位置信息进行融合，进而实现有效的模型分割准确率提升。

图 2.11 多尺度特征融合模块^[26]图 2.12 语义聚合模块^[26]

（2）AFNet 模型优势

训练所需样本量少

AFNet 继承了 U-Net 的 U 型编码器-解码器结构，能有效利用样本进行模型训练，非常适用于小数据集图像分割任务。结合目前铁谱图像数据集缺乏大量有效的样本，使用 AFNet 进行图像分割任务，既能减少人工标注任务量又能有效利用现有数据集。

特征提取效率高

AFNet 引入的三个模块，有助于模型有选择地提取像素信息并减少冗余信息的干扰，能有效应对当前待分割的铁谱图像具有背景复杂、干扰因素多等特点。

轻量级模型

AFNet 比 U-Net 的编码层与解码层均少一层，同时每层的通道数大大减少。这使得 AFNet 的网络参数较少，模型训练可以快速迭代与收敛，便于模型测试与调整。


2.4.3 AFNet 数据集构建

训练卷积神经网络需要一定数量的样本，数据集的质与量影响着网络的最终分割性能。


（1）获取数据集样本

使用 2.3.3 中的方法对铁谱图像集进行分割，最终确定出 9 张分割效果良好的铁谱图像作为数据集样本。该 9 张图像较好地描述了现有铁谱图像集的主要特点：背景颜色上，选用了多种光源类型下产生的图像，包括白色、绿色、褐色等；分割目标特征上，包含丰富的颜色、亮度、尺寸等信息；在细节层面，选用的图像中含有一定的干扰因素，如杂质、亮斑、暗斑。

2.3.3 方法直接分割所得的 9 张掩码图像中，仍然包含有一定量的瑕疵，直接用于模型训练会产生较大的误差。人工修正 9 张图像的明显瑕疵后，最终得到如图 2.13 所示的数据集样本。



（a）样本中的铁谱图像



（b）样本中的掩码图像

图 2.13 AFNet 数据集原始样本

（2）构建数据集

数据集样本的分辨率为 $2592 \times 1700\text{px}$ ，对于一般的卷积神经网络而言，属于大尺寸图像。直接将大尺寸图像用于 AFNet 模型训练，对于硬件要求较高且训练消耗的时间也较长。此外，数据集的样本数量依旧较少，需通过合适的方法放大数据集。结合铁谱图像磨粒形态类似、分布广而散，本文选择随机截取的方式扩充数据。

经过测试，训练集图像尺寸为 $256 \times 256\text{px}$ 时，既能保留大部分图像特征，同时模型的训练速度与分割精度能保持在较高水平。从数据集的每张铁谱图像随机选取 128 个区域，共截取出 1152 个铁谱图像块，并从对应的掩码图像的对应位置也截取出 1152 个掩码图像块，共同构成如图 2.14 所示的最终 AFNet 数据集。随机选取其中的 80% 用于模型训练，剩余 20% 用于验证。




图 2.14 AFNet 训练与验证样本

2.4.4 AFNet 模型训练

(1) 训练环境

本文的实验框架基于 PyTorch 进行开发。模型训练所用的电脑配置为 CPU: AMD Ryzen 7 5800H with Radeon Graphics; 内存: 16GB; GPU: NVIDIA GeForce RTX 3060 Laptop GPU; 操作系统: 64 位 Windows11。

(2) 训练超参数设置

训练轮数 (Epochs)

一个 Epoch 表示模型完整遍历一次数据集的训练过程，多个 Epoch 可以让模型反复学习训练集数据并逐步优化参数。Epoch 过少会导致模型欠拟合，过多会导致过拟合。

本文模型训练的 Epochs 设置为 100。此外，训练中引入早停机制，当验证集准确率连续 5 轮不上升时，停止模型训练，防止模型过拟合。

批次大小（Batch）

每一个 Epoch 中，模型会将样本分为多个批次依次输入模型训练，Batch 表示每次输入的样本数量。较大的 Batch 可加速训练，但需要较大的内存且模型泛化能力可能会下降；较小的 Batch，可增强模型泛化能力但训练速度较慢。

综合可虑模型训练速度与泛化能力，本文模型训练的 Batch 设置为 8。

学习率（Learning Rate）

学习率控制每次参数更新的变化量，决定模型参数在每轮 Epoch 中根据损失率调整的范围。过大的学习率会导致训练损失震荡，无法收敛；过小的学习率会导致模型训练变慢，且容易陷入局部最优。

经过调整测试，本文模型训练的初始学习率设置为 0.0002，优化器选择 Adam。

（3）训练优化方法

损失函数

损失函数是用于衡量模型预测值与真实值之间差距的指标。模型通过最小化损失函数来调整模型参数。不同任务的模型一般采用不同的损失函数。图像分割可归类于对像素的分类，可使用图像分类常用的交叉熵（Cross-Entropy）损失函数。但不同铁谱图像样本中的磨粒尺寸与密度差异大，考虑引入 Dice 损失函数。

交叉熵损失计算公式如下：

$$L_{CE} = -\sum_{i=1}^N y_i \log(\hat{y}_i) \quad (2.4)$$

N 为类别数， y_i 为真实标签， $\hat{y}_i$ 为模型的预测概率。交叉熵衡量的是预测概率分布于真实分布的差异，差异越大，损失值 L_{CE} 越大。

Dice 损失计算公式为：

$$L_{Dice} = 1 - \frac{2\sum \hat{y}_i y_i}{\sum \hat{y}_i + \sum y_i + \varepsilon} \quad (2.5)$$

y_i 为真实标签， $\hat{y}_i$ 为模型的预测概率， ε 为极小常数，防止分母为零。Dice 描述的是预测区域与真实区域的重叠程度，重叠程度越高，损失值 L_{Dice} 越小。

联合损失函数可以综合两种损失函数的优势，弥补单个损失函数的不足。交叉熵与 Dice 的联合使用，既可以确保模型预测结果逐像素的准确性，又能提升目标区域的整体匹配度。联合损失函数计算公式如下：

$$L_{total} = 0.5L_{CE} + 0.5L_{Dice} \quad (2.6)$$

学习率调度器

学习率调度器用于在模型训练中动态调整学习率，可以加快模型训练收敛速度与稳定性，也可以通过周期性调整帮助模型跳出局部最优点。

本文模型训练使用余弦退火（Cosine Annealing）学习率调度器，该调度器的变化过程遵循余弦函数曲线，具体公式如下：

$$lr_t = lr_{\min} + \frac{1}{2}(lr_{\max} - lr_{\min})(1 + \cos(\frac{\pi \cdot t}{T})) \quad (2.7)$$

lr_t 为当前学习率， $lr_{\min}$ 为最小学习率， $lr_{\max}$ 为最大学习率， t 为当前周期迭代次数， T 为一个周期的总迭代次数。本文的参数设置为： $lr_{\min} = 0.000001$ ， $lr_{\max} = 0.0002$ ， $T=15$ 。

（4）训练结果

模型共训练了 25 轮，第 25 轮触发早停机制，最佳模型为第 20 轮训练结果。

如图 2.15，蓝线为训练集损失率曲线，红线为验证集损失率曲线，横轴代表训练轮数，纵轴代表损失率大小。从图中可知，两个曲线随着轮次迭代与学习率调整，由初始较高的损失率快速收敛至 0.3 以下，最终收敛于 0.2950 左右。末尾轮次，模型的损失率仅有较小浮动，表明模型已经收敛。




图 2.15 模型训练过程误差曲线

如图 2.16，蓝线为训练集准确率（Accuracy）曲线，红线为验证集准确率曲线，黄色为验证集交并比（Intersection over Union, IoU）曲线。横轴代表训练轮数，纵轴代表准确率

大小。结合图 2.15 可知，训练集与验证集的准确率随各自的损失率下降而上升。最终，准确率收敛于 99.50%，IoU 收敛于 99.58%。表明该模型已收敛且训练效果良好，可以用于图像分割。

准确率计算公式为：

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.8)$$

TP （True Positive）为正确预测为正类的数量， TN （True Negative）为正确预测为负类的数量， FP （False Positive）为负类中被误判为正类的数量， FN （False Negative）为正类中被误判为负类的数量。

交并比衡量的是分割任务中预测区域与真实区域的重叠程度，其计算公式为：

$$\text{IoU} = \frac{|P \cap G|}{|P \cup G|} \quad (2.9)$$

P 为模型预测区域， G 为目标真实区域。




图 2.16 模型训练过程准确率曲线

2.4.5 AFNet 模型分割结果

(1) 分割流程

图像分割的流程如图 2.17 所示，图中方框内，第一行为步骤名称，其余行是图片尺寸。




图 2.17 铁谱图像分割流程


(2) 伽马变换

由于铁谱图像质量参差不齐，存在一些亮度较低或较高、目标对比度低等的图像，这些因素对模型的最终分割效果会产生较大影响。此外，铁谱图像具有暗磨粒 RGB 值低、亮磨粒 RGB 高、背景 RGB 在中间范围的特点。如图 2.18 与图 2.19 所示，本文根据图片平均亮度，采用伽马变换适当调高图像暗区或亮区的对比度，以改善这些图像的分割效果。

伽马变换计算公式：


$$s = cr^\gamma \quad (2.10)$$

s 为变换后的像素值（归一化）， r 为输入的像素值（归一化）， γ 为伽马因子， c 为常数。本文中 $c=1$ ， $\gamma \in [0.7, 1.3]$ 。



(a) 原图对比度 20.0 (b) 变换后对比度 23.7 (c) 原图对比度 8.4 (d) 变换后对比度 8.6

图 2.18 伽马变换前后铁谱图像对比



(a) (b) (c) (d)

图 2.19 伽马变换前后分割结果对比

（3）重叠分块预测策略


本文模型测试所用的铁谱图像分辨率为 $2592 \times 1700\text{px}$ ，直接使用模型预测容易导致内存溢出。因此，本文考虑将铁谱图像分块裁切为多个小图片，并逐个预测后再拼接回原尺寸大小。但是如图 2.21（a）所示，直接分块会出现严重的边缘效应。

图像块边缘信息缺失以及模型感受野的限制会造成模型预测出现错误，这种错误的累计最终导致了边缘效应。因此，为了避免边缘效应导致的分割错误，本文使用重叠分块预测策略，优化结果如图 2.21（b）所示。

如图 2.20（a）所示，黄色区域 Y 为镜像扩充区域，扩充后图像尺寸为 $4096 \times 3072\text{px}$ ；绿色区域 $G_1 \sim G_6$ 是目标图像块，尺寸大小为 $1024 \times 1024\text{px}$ ；红色区域 $r_1 \sim r_6$ 是重叠区域，重叠尺寸长 $e = 128\text{px}$ ，绿色区域+邻近红色区域是裁剪出的待模型预测图像块 $R_1 \sim R_6$ （图中仅展示出 R_2, R_4, R_6 ），即 $G_i + r_i = R_i$ ，尺寸为 $1280 \times 1280\text{px}$ 。如图 2.19（b）所示， $R_1 \sim R_6$ 经过模型预测获得 $\hat{R}_1 \sim \hat{R}_6$ ，剪裁回 $\hat{G}_1 \sim \hat{G}_6$ 后再拼接成 $\hat{G}$ ，蓝色区域 B 为最终分割结果。

（4）分割结果比较

由图 2.22 可知，对于质量较高的铁谱图像（a）~（d），传统分割方法与 AFNet 模型均能有效分割；对于存在大量干扰的铁谱图像（e）~（h），传统分割方法明显失效，而 AFNet 模型仍然能保持较高的分割准确率。由此结果可得，本文所使用的基于 AFNet 模型的复杂背景铁谱图像分割方法，在一定程度上优于颜色空间特征+K-means 聚类所代表的传统铁谱图像分割方法。



（a）铁谱图像重叠分块裁切



（b）预测结果剪裁拼接再剪裁

图 2.20 重叠分块预测策略




图 2.21 重叠分块预测策略优化前后对比




图 2.22 传统分割方法（第 2 与第 6 行）与 AFNet（第 3 与第 7 行）的分割效果对比




图 2.22 传统分割方法（第 2 与第 6 行）与 AFNet（第 3 与第 7 行）的分割效果对比（续）

2.5 小结

本章首先介绍了本文研究所使用的铁谱图像集的来源、数量、特点等；随后使用该铁谱图像集提出了一套流程完整的图像分割方法：先是使用颜色特征+K-means 聚类的传统分割方法得到分割质量不一的掩码图，再从中挑选具有代表性的 9 张铁谱图像与对应掩码优化后构成 AFNet 数据集来源，然后利用该数据集并采用一系列训练优化方法获得最佳 AFNet 模型，最后使用伽马变换与重叠分块预测策略进行完整的铁谱图像分割。

通过使用 AFNet 模型对铁谱图像集中图像的分割并于传统分割对比，一是验证了利用传统分割方法构建 AFNet 数据集的可行性与有效性，二是证明了所提出的“基于 AFNet 模型的铁谱图像分割方法”相比于传统分割方法的优越性，三是展示出了本章方法的有效性与准确性。

第三章 基于 DBSCAN 与 YOLOv12 的磨粒识别方法

3.1 引言

一般磨粒识别模型的数据集依赖人工逐个标注磨粒范围与类型，而在面对背景复杂且存在杂质干扰的铁谱图像，不同操作人员确定的磨粒界限会产生较大差异，影响后续磨粒识别的准确性。针对以上问题，本文在第二章 AFNet 模型的分割结果基础上，提出一种使用 DBSCAN 算法的 YOLO 数据集构建方法，大大减少人工标注参与量。最终，使用该数据集训练 YOLOv12 模型，得到一个能区分出磨粒与油泥的磨粒识别模型。




图 3.1 本章方法简要流程

3.2 DBSCAN 实例区分

进行磨粒分析之前，需从掩码图像中区分出不同的磨粒与油泥区域，获得不同的实例。这一过程与聚类类似，将分割得到的掩码视为数据集，而聚类所得的簇，即为不同的磨粒与油泥。

3.2.1 DBSCAN 密度聚类算法

DBSCAN^[38]（Density-Based Spatial Clustering of Applications with Noise）是一种基于密度的聚类算法。该聚类算法适应各种簇形状，通过设置合适的参数值，能够准确聚合目标并过滤噪声点。该聚类算法的核心思想是：通过数据点的密度分布来定义簇，即将高密度区划分为簇，而低密度区看作噪声。

（1）算法相关概念

ε 邻域

在二维数据集中，对于数据点 p ，其 ε 邻域定义为：以 p 为中心、半径为 ε 的圆内所有的点：

$$N_{\varepsilon}(p) = \{q \in D \mid \text{distance}(p, q) \leq \varepsilon\} \quad (3.1)$$

D 为数据集, $\text{distance}(p, q)$ 为数据点 p 与数据点 q 之间的距离, 一般为欧式距离。

核心点、边界点与噪声点

若数据点 p 的 ε 邻域内, 至少包含有 MinPts (最小邻居数) 个点 (包括数据点 p), 则称 p 为核心点:

$$|N_\varepsilon(p)| \geq \text{MinPts} \quad (3.2)$$

若数据点 q 位于某个核心点的 ε 邻域内且点 q 的 ε 邻域内的数据点数量小于 MinPts 个, 则称点 q 是边界点。

既不是核心点, 也不属于任一核心点 ε 邻域的数据点, 称为噪声点。

密度直达、密度可达与密度相连

若数据点 q 位于数据点 p 的 ε 邻域内, 且数据点 p 是核心点, 则称数据点 q 可由于数据点 p 密度直达, 即:

$$\begin{cases} q \in N_\varepsilon(p) \\ |N_\varepsilon(p)| \geq \text{MinPts} \end{cases} \quad (3.3)$$

对于数据点 p 和数据点 q , 若存在一系列核心点 $p_1, p_2, \dots, p_n$, 满足 $p_1 = p$, $p_n = q$, 且核心点 p_{i+1} 可由核心点 p_i 密度直达, 则称数据点 q 由数据点 p 密度可达。

若存在数据点 o , 使得数据点 p 和数据点 q 都从数据点 o 密度可达, 则数据点 p 和数据点 q 密度相连。

(2) 算法原理

如图 3.2 所示, DBSCAN 算法的基本原理为: 从任意未被分类的数据点 p 开始, 如果该数据点的 ε 邻域内 (Eps 为邻域半径) 有不少于 MinPts 个点, 则视数据点 p 为一个核心点并建立一个新簇; 然后找到核心点 p 密度可达的数据点, 将这些数据点归入核心点 p 所在簇。重复上述过程, 直到所有的核心点都找到所归属的簇为止。

如图 3.3 所示, 在数据集 D 内, 蓝色点为核心点, 绿色点为边界点, 红色点为噪声, 点周围的圆形表示该点 ε 邻域范围, 黑色椭圆表示簇。点 p_1 为核心点, 其 ε 邻域内的数据点大于等于 MinPts; 点 p_2 和点 p_3 为边界点, 两点均在核心点的 ε 邻域内, 但两点的 ε 邻域内的数据点数量均小于 MinPts; 点 p_4 、 p_5 为噪声, 两点各自 ε 邻域内的数据点数量小于 MinPts 且两点均不在任意核心点的 ε 邻域内。对数据集 D 聚类的最终结果得到两个簇, 即簇 C_1 和簇 C_2 。




图 3.2 DBSCAN 算法流程图




图 3.3 DBSCAN 算法原理示意图 (MinPts=3)

3.2.2 DBSCAN 聚类结果

(1) 聚类过程

图 3.4 展示了使用 DBSCAN 聚类的流程：首先，提取掩码图像中磨粒和油泥区域的位置信息；然后，使用 DBSCAN 将位置信息分成多个簇，并获得簇的标签值，其中的每一个簇即代表一个磨粒或油泥；最后依据簇的标签值，获取最终聚类结果，并将结果可视化。

聚类过程中，DBSCAN 的相关参数设置主要参考掩码图中的实例特点：一是，掩码图中的磨粒实例或油泥实例是连续的，即单个实例大部分组成像素是相邻的，距离为 1 或 $\sqrt{2}$ ；二是，部分实例之间的间距仅有几个像素，稍大的 Eps 可能会明显的聚类偏差，如图 3.5

所示。三是，稍大的 MinPts 会滤除实例的细长部分，而稍小的 MinPts 会引入较多的噪声。因此，本文中 $\text{Eps}=1.42$ ， $\text{MinPts}=6$ 。





图 3.4 聚类过程图

图 3.5 不同 Eps 大小对聚类的影响（不同颜色表示不同实例）

(2) 聚类结果可视化

如图 3.6 所示，对于分布密度不一、形态各异的磨粒或油泥，该基于 DBSCAN 的实例区分方法均能实现较准确的区分。




图 3.6 聚类结果（不同颜色表示不同实例）




图 3.6 聚类结果（不同颜色表示不同实例）（续）

3.3 基于 YOLOv12 的磨粒识别方法

3.3.1 YOLO 模型

YOLO (You Only Look Once) ^[28] 是一种基于卷积神经网络的目标检测模型，其模型网络结构如图 3.7 所示。其核心思想是：将目标检测任务转化为全局回归问题。与其他神经网络目标检测模型（如 R-CNN^[27]）两阶段预测不同的是，YOLO 模型在单次前向传播中完成对图像中所有目标的边界框和类别概率的预测。这种特点使得 YOLO 模型具有较快的速度和高效的同时，能够保持较高精度的识别结果。

YOLOv12^[29] 是 YOLO 系列的第 12 代模型，该模型首次将注意力机制作为核心模块引入到网络结构中，实现了模型的架构革新以及性能与精度的提升。结合本文所使用的复杂背景铁谱图像的特点，即存在大量干扰、目标尺寸跨度大等。包含有区域注意力模块、多

尺度特征融合模块的 YOLOv12 模型，能实现在复杂背景铁谱图像中较为准确地识别和分类磨粒与油泥。如图 3.8 所示，该模型可更全面地捕捉目标特征。




图 3.7 YOLO 模型网络结构^[28]




图 3.8 YOLOv12 区域注意力模块功能示意图（红色为识别区域）

3.3.2 YOLO 数据集样本构建

构建用于 YOLOv12 模型训练与验证的数据集样本需要有 5 个数据：类别，包围实例的最小边界框的左上角横纵坐标、右下角横纵坐标（坐标值需归一化）。人工标注上述数据存在工作量大、不易确定边界框界限、无法确定目标尺寸大小等缺点。另外，本文研究所使用的铁谱图像相较于一般的铁谱图像，其单张图像存在较多干扰因素、包含的实例数量多且尺寸跨度大。针对这两类问题，本文提出一套基于 DBSCAN 聚类结果的 YOLO 数据集样本构建程序，可以大大减少人工标注的工作量。

（1）程序流程

YOLO 数据集样本构建程序流程如图 3.9 所示，算法分为两部分：一部分为 DBSCAN 聚类程序，得到实例的聚类结果；另一部分为样本标注程序，实现自动标注并输出符合尺寸要求的实例的最小边界框归一化纵横坐标。




图 3.9 YOLO 数据集样本构建程序流程示意图

（2）程序运行结果:

如图 3.10 所示，样本构建程序中目标尺寸范围参数设置为：大于 $20\mu\text{m}$ ；从图中可以看出，基于准确的分割掩码与适用的聚类程序，该样本构建程序准确标注出了铁谱图像中尺寸大于 $20\mu\text{m}$ 的实例。结果表明，基于第二章方法得到的掩码生成的聚类结果，使得该标注程序得以在背景复杂的铁谱图像中，能准确标注出实例的最小边界框；同时，该样本构建程序攻克了人工标注存在的边界框界限不确定、无法选择尺寸范围等缺陷，大大减少了数据集样本构建的工作量。




图 3.10 程序自动识别并标注尺寸大于 $20\mu\text{m}$ 实例结果图（红框根据标注数据生成）

图中目标尺寸选择大于 $20\mu\text{m}$ 的实例，其原因在于：在实际的生产活动中，关注较多的是尺寸 $20\mu\text{m}$ 以上的磨粒以及整体的磨粒覆盖率。另外，目标尺寸范围下限偏低会向 YOLO 数据集样本中引入较多的油泥实例，不利于后续人工区分磨粒和油泥工作的进行；而且小尺寸目标细节特征缺失，人工分类时容易混淆磨粒和油泥，为 YOLO 模型的磨粒识别引入不必要的误差。因此，本文 YOLO 数据集的构建将基于这些大于 $20\mu\text{m}$ 的磨粒。

（3）最终 YOLO 数据集样本

通过样本构建程序生成的数据集样本中不包含实例的类别，也就是说并未区分所标注的实例是磨粒还是油泥。此外，程序标注结果中也存有一些瑕疵需要修正。鉴于此，最后需要经由人工对磨粒与油泥分类以及修正标注结果中的瑕疵。

本文人工标注使用的软件为 Labelimg，如图 3.11 所示，默认实例标签设置为磨粒(Wear Particles)，仅需人工修正油泥(Oil)标签。最终 YOLO 数据集中，训练集 82 张图像、验证集 26 张图像、测试集 24 张图像，共计标注磨粒 548 个、油泥 505 个，部分数据集样本如图 3.12 所示。







图 3.11 使用 Labelimg 修改分类标签




(a) 6-1-17



(b) 19-1-68



(c) 32-2-106



(d) 40-1-117

图 3.12 YOLO 数据集部分样本

3.3.3 YOLOv12 模型训练

(1) 训练环境与参数设置

YOLOv12 模型训练环境与 2.4.4 中训练环境一致，训练程序与参数设置为下文所示，其中，epoch、batch、patience 前文已有介绍，scale、mosaic、mixup、copy_paste 为数据集增广操作，用于提升模型的鲁棒性，其他参数保持模型默认设置。

表 3.1 模型训练相关参数作用及设置

参数	作用	值
model	模型配置文件	yolov12n.yaml
imgsz	输入图片尺寸	640
epochs	训练轮数	1024
batch	批次大小	16
patience	早停轮数	128
scale	图像缩放比例	0.5
mosaic	四张图像拼接为一张训练	1
mixup	两张图像及其标签线性混合	0.05
copy_paste	复制图中的对象到另一个图	0.6

(2) 训练效果指标

损失率指标

边界框损失 (Bounding Box Loss)，衡量边界框的预测值和真实值之间差异的损失。

分类损失 (Classification Loss)，衡量预测类别和真实类别之间差异的损失。

分布式焦点损失 (Distribution Focal Loss)，衡量边界框位置概率分布准确性的损失。

评价指标

精确率 (Precision)，正确的预测为正样本的数量占有所有预测为正样本的数量比例：

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3.4)$$

召回率 (Recall)，正确的预测为正样本的数量占有所有真实正样本的数量比例：

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.5)$$

mAP (mean Average Precision)，即所有类别的平均精度 (AP) 均值，反应了模型的整体分割性能。计算公式如式 (3.6)。mAP50 表示 $\text{IoU} = 0.5$ 时的 mAP，mAP50-95 表示 IoU 在 $[0.5, 0.95]$ 、步长 0.05 的范围内的 10 个不同 mAP 的均值，是比 mAP50 更加严格的指标。

$$\begin{cases} \text{AP}_i = \int_0^1 \text{Precision}_i(\text{Recall}_i) d\text{Recall}_i, & i = 1, 2, \dots, k \\ \text{mAP} = \frac{1}{k} \sum_i \text{AP}_i \end{cases} \quad (3.6)$$

k 为类别总数。

(3) 模型训练结果

模型训练 Epochs 设置为 1024，在第 670 轮触发早停，最佳模型为第 542 轮训练结果。

图 3.13 为训练集与验集损失率变化，可以看出经过 542 轮的训练，三类损失率均有明显下降，且分类损失率已收敛。

图 3.14 为模型性能的相关评价指标变化与 P-R 曲线，metrics 表示统计数据来源于验证集。最佳模型的准确率为 0.80，召回率为 0.74，mAP50 为 0.81，mAP50-95 为 0.58。该结果表明：对于验证集中的铁谱图像，最佳模型可以较为准确地识别并分类出其中的磨粒和油泥。




图 3.13 损失率变化图




图 3.14 模型评价指标与 P-R 曲线

3.3.4 YOLOv12 模型识别结果

如图 3.15 所示，YOLOv12 模型得到的识别结果与人工标注结果相差无几，表明该 YOLOv12 模型可以进行有效的磨粒识别工作。图中，蓝色表示磨粒、红色表示油泥；1、4、7 行为人工标注结果；2、5、9 行为 YOLOv12 模型的识别结果。





图 3.15 YOLOv12 模型识别结果（蓝色为磨粒、红色为油泥）



(g) 32-2-106

(h) 40-1-117

(i) 49-4-148

图 3.15 YOLOv12 模型识别结果（蓝色为磨粒、红色为油泥）（续）

3.4 小结

本章提出了一种基于 DBSCAN 与 YOLOv12 模型的磨粒识别方法。先是使用 DBSCAN 对掩码中的实例进行区分，然后使用样本标注程序自动提取出铁谱图像中满足尺寸要求的实例边界框归一化坐标并构建数据集，最后使用该数据集训练 YOLOv12 模型，成功得到能有效识别磨粒和油泥的 YOLOv12 磨粒识别模型。

本章最后的铁谱图像磨粒识别结果：一是证明了 DBSCAN 进行实例区分的准确性，二是验证了基于 DBSCAN 聚类的 YOLO 数据集构建方法的有效与高效，三是本章“基于 DBSCAN 与 YOLOv12 模型的磨粒识别方法”实现了对复杂背景铁谱图像中磨粒与油泥的区分。

第四章 总结与展望

4.1 研究总结

铁谱分析技术是常用的油液分析技术之一，也是一种重要的故障诊断与状态检测方法。但现有的铁谱图像分析方法存在较多缺陷，缺乏对复杂背景图像的分析验证，而且过于依赖人工参与，不利于铁谱分析自动化与智能化的发展。鉴于此，本文通过分析现有传统方法和深度学习方法的优点与不足，针对铁谱图像分割和磨粒识别方法进行了研究，具体的研究内容与结论如下：

（1）提出一种基于 AFNet 的复杂背景铁谱图像分割方法

利用颜色特征+K-means 聚类的传统铁谱图像分割法对本文的铁谱图像集进行分割，得到了分割质量不一的掩码图。从中挑选出能概括铁谱图像集特点的原始数据集样本，经过简单的优化获得了可用于 AFNet 模型训练的数据集样本。设计了一套模型训练优化方法，训练并得到了一个高准确率、高适用性的 AFNet 铁谱图像分割模型。针对亮度异常高或低的图像，提出使用伽马变换适当提高图像对比度，实现了对此类图像分割效果的优化。利用重叠分块预测策略，解决了 AFNet 预测图像块时出现边缘效应这一问题，实现了对高分辨率铁谱图像的准确有效分割。综合图像预处理方法与 AFNet 预测分割铁谱图像，实现了对铁谱图像集中所有类型铁谱图像的有效分割，证明了 AFNet 模型处理复杂背景铁谱图像的准确性，验证了本文提出的使用传统分割方法构建 AFNet 数据集样本与基于 AFNet 的复杂背景铁谱图像分割方法的有效性。

（2）提出一种基于 DBSCAN 和 YOLOv12 的磨粒识别方法

通过 AFNet 模型分割得到的掩码图，利用 DBSCAN 聚类算法处理掩码图得到聚类结果，实现了对图中不同实例的区分。设计了一套标注程序，根据预设的目标尺寸范围，自动提取出 DBSCAN 聚类结果中符合要求的实例，并输出 YOLO 数据集样本边界框归一化坐标数据。使用区分出磨粒与油泥的 YOLO 数据集训练 YOLOv12 模型，得到了一个有效的磨粒识别模型，实现较为准确地识别分类复杂铁谱图像中的磨粒和油泥，验证了本文提出的基于 DBSCAN 聚类的 YOLO 数据集样本构建方法的有效性与准确性以及基于该数据集的 YOLOv12 磨粒识别方法的可行性。

4.2 研究展望

本文对铁谱图像分析中的图像分割方法与磨粒识别方法进行了研究，但仍存在一定的问题有待在后续工作中优化改善，如：

（1）目前的铁谱图像分割领域缺少由专业人员标注的公开数据集，本文两个模型训练所使用的铁谱图像数据集均为自行构建所得，有待进一步使用标准数据集验证模型的准确性能。

（2）本文提出的铁谱图像分割方法所得到的掩码区域范围与真实实例区域范围存在一定的误差，对于实例间的单位像素级间隙的分割效果不稳定，后续研究可考虑调整或修改 AFNet 的网络结构，使用更大的卷积核或引入注意力机制模块等提升模型性能。

（3）本文使用 DBSCAN 聚类算法实现实例分离，但该算法对于大数据集处理效率较低、耗时较长，其时间复杂度可达 $O(n^2)$ ，在后续工作中可考虑使用其改进算法或其他高效率方法代替。

（4）YOLOv12 模型训练需要较多的样本，本文数据集铁谱图像中各类型磨粒数量较少，所以仅使用其识别磨粒与油泥，未能进一步分析磨粒具体类型，后续可收集更多的铁谱图像，实现对具体磨粒类型的直接识别。

参考文献

- [1] 张嗣伟. 我国摩擦学工业应用的节约潜力巨大——谈我国摩擦学工业应用现状的调查[J]. 中国表面工程, 2008(2): 50-52.
- [2] 姚春江, 陈小虎, 阳能军, 等. 机械设备摩擦磨损标准铁谱图谱分析技术研究[J]. 机械, 2018, 45(7): 63-67.
- [3] 马佳丽. 航空发动机磨损故障多目标智能融合诊断[D]. 南京航空航天大学, 2023.
- [4] 王静秋. 铁谱图像分割及磨粒识别关键技术研究[D]. 南京航空航天大学, 2014.
- [5] 高孝清, 左洪福, 陈果, 等. 复杂背景下磨粒显微图像分割[J]. 南京航空航天大学学报, 2001(6): 565-568.
- [6] Otsu N. A Threshold Selection Method from Gray-Level Histograms[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62-66.
- [7] 陈果, 左洪福. 彩色磨粒图像自动分割技术[J]. 信号处理, 2001(5): 449-453, 428.
- [8] 陈果, 左洪福. Fisher 评价准则下的彩色磨粒图像自动分割[J]. 小型微型计算机系统, 2002(6): 721-725.
- [9] Jiang L, Chen G, Long F. Auto-threshold Confirming Segmentation for Wear Particles in Ferrographic Image[C]//2008 International Symposium on Computational Intelligence and Design: Vol. 2. 2008: 61-64.
- [10] 邢凡, 樊瑜瑾. 基于小波变换多阈值彩色铁谱图像的分割方法[J]. 润滑与密封, 2008(7): 69-72.
- [11] 刘万龙, 王静秋. 基于人工蜂群算法的彩色铁谱图像背景减除[J]. 机械制造与自动化, 2016, 45(5): 145-146, 214.
- [12] 刘信良. 基于深度学习的铁谱图像磨粒分类与检测[D]. 南京航空航天大学, 2020.
- [13] 陈桂明, 谢友柏, 江良洲. 图像颜色特征提取在铁谱图像分类及磨粒识别中的应用研究[J]. 中国机械工程, 2006(15): 1576-1580.
- [14] Wang J, Yao P, Liu W, 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.
- [15] 杨海, 盛晨兴. 融合颜色与形状信息的铁谱磨粒链分割方法研究[J]. 润滑与密封, 2024, 49(3): 183-188.
- [16] 李艳军, 左洪福, 吴振锋, 等. 基于 D-S 证据理论的磨粒识别[J]. 航空动力学报, 2003(1): 114-118.
- [17] Stachowiak G P, Stachowiak G W, Podsiadlo P. Automated classification of wear particles based on their surface texture and shape features[J]. Tribology International, 2008, 41(1): 34-43.
- [18] 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.
- [19] 王国忠, 王静秋, 于海武. 融合灰色关联和主成分分析的磨粒自动识别[J]. 计算机技术与发展, 2012, 22(4): 16-20.
- [20] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [21] 左洪福, 吴振锋, 杨忠. 双 BP 神经网络在磨损颗粒自动识别中的应用[J]. 航空学报, 2000(4): 372-375.
- [22] 罗炳海, 黄永武, 刘远飞. 基于 PCA-BP 神经网络的磨粒自动识别[J]. 润滑与密封, 2010, 35(6): 117-120.

- [23]田勇, 廉书林, 陈闽杰. BP 神经网络在油液污染与磨损预测中的应用[J]. 机床与液压, 2014, 42(7): 163-166.
- [24]Krizhevsky A, Sutskever I, Hinton G E. ImageNet Classification with Deep Convolutional Neural Networks[C]//Advances in Neural Information Processing Systems: Vol. 25. Curran Associates, Inc., 2012.
- [25]Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]//Navab N, Hornegger J, Wells W M, et al. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.
- [26]Li D, Peng L, Peng S, et al. Retinal vessel segmentation by using AFNet[J]. The Visual Computer, 2023, 39(5): 1929-1941.
- [27]Girshick R, Donahue J, Darrell T, et al. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. 2014: 580-587.
- [28]Redmon J, Divvala S, Girshick R, et al. You Only Look Once: Unified, Real-Time Object Detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [29]Tian Y, Ye Q, Doermann D. YOLOv12: Attention-Centric Real-Time Object Detectors[A]. arXiv, 2025.
- [30]蔡俊豪. 基于混合卷积神经网络的铁谱图像目标磨粒检测与识别方法研究[D]. 深圳大学, 2020.
- [31]Liu X, Cheng L, Chen G, 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.
- [32]Liu Z, Zuo H, Bai F, et al. Intelligent classification of online wear particle in lubricating oil using optical direct imaging method and convolutional neural network for rotating machinery[J]. Tribology International, 2023, 189: 109015.
- [33]He L, Wei H, Sun C. TCBGY net for enhanced wear particle detection in ferrography using self attention and multi scale fusion[J]. Scientific Reports, 2024, 14(1): 31549.
- [34]古莹奎, 胡宇辉, 陈孝鑫, 等. 基于改进 YOLOv8n 的铁谱图像磨粒多目标识别方法[J]. 润滑与密封, 2025: 1-9.
- [35]王雨薇, 陈果, 何超, 等. 基于改进 YOLOv4 的扫描电镜磨粒图像智能识别[J]. 摩擦学报, 2023, 43(7): 809-820.
- [36]胡清华, 杨柳. 机器学习[M]. 高等教育出版社, 2024.
- [37]彭凌西, 唐春明, 彭绍湖, 等. 图像分割原理与技术实现[M]. 科学出版社, 2024.
- [38]Ester M, Kriegel H P, Sander J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[C]//Proceedings of the Second International Conference on Knowledge Discovery and Data Mining. Portland, Oregon: AAAI Press, 1996: 226-231.

致 谢

时光荏苒，四年的本科生活转瞬即逝。失望、喜悦，遗憾、惊喜，不甘、满足，相互交织，融作记忆中这四年的底色。一路走来，我绝非一人。

首先，感谢陈果教授，感谢他对我的教导以及对本文工作的指导。陈老师是一个严肃活泼、博学多识的人。在本科期间，陈老师曾教过我两门课程，但是在当时我并没有正视这些知识。经过本文的工作后，回过头看才发现，这些课程里的知识跨度是如此之广，虽有些许老旧，但依旧不缺乏满足如今需求的方法，这也使我认识到陈老师的博识。在本文工作期间，陈老师给予我充分的自由，使得我能够多学多看多尝试。在指导过程中，陈老师也总能抓住问题关键点，为我的后续工作指点迷津、拨云见日。在此，再次感谢陈老师的教导与指点！

其次，特别感谢盛嘉玖师兄，感谢他在这半年中对我生活学习上的关照以及对本文工作的鼎力相助。虽然见面次数不多，但在我印象里盛师兄是一个善解人意、认真严谨、勤奋努力的人。我于去年十二月与盛师兄相识于溧阳，当时正是临近考研初试的时候，盛师兄给予了我生活上的关照与初试的建议，让我得以在那段时间里专心准备考试相关事宜。初试后的日子里，本文的相关工作逐步开展，在盛师兄的指导下，我渐渐明确了本文的工作方向。虽总有懈怠与停滞，但盛师兄包容了我的不足，认真指导我开展本文的相关工作。三月，复试临近，盛师兄又给予我鼓励与经验，为我面对复试加油助威。在即将毕业的这段时间里，尽管盛师兄身在外地，但是他依旧关心着本文工作的进展，为我的研究排忧解难，最终得以呈现出本文。可预见的是，没有盛师兄的鼎力相助，本文的研究成果不会如此丰富。在此，我向盛师兄表达由衷的敬意与感谢！

然后，感谢本科期间的辅导员王亚云老师、陈冬老师、柳小营老师在学习生活中对我的关照，感谢生活与考研期间互相陪伴努力的好友刘俊、周思鑫、王亚龙，感谢生活与学习中给予我关照与帮助的好友孙凯敏、侯翔国、彭雅莉，感谢共同生活四年的 805 宿舍的所有人。

最后，感谢我的父母与爷爷奶奶，感谢你们在生活上对我的关心与鼓励，没有你们的支持，我将寸步难行。

最后的最后，感谢自己一直以来的坚持，虽然生活有些许波折，但总是前进的。

“人生如逆旅，我亦是行人”，活在当下，展望未来。

王毅博

2025 年 5 月 19 日