

文章编号: 1000-4734(2024)01-0024-09

基于深度学习的鲕粒智能检测与特征统计

张晓燕¹, 李艳², 芦碧波^{1*}, 侯广顺³, 邢智峰³, 杨晓芃⁴

(1. 河南理工大学 计算机科学与技术学院, 河南 焦作 454003; 2. 焦作冶金建材高级技工学校 计算机科学与技术学院, 河南 焦作 454003; 3. 河南理工大学 资源与环境学院, 河南 焦作 454003; 4. 河南理工大学 测绘与国土信息工程学院, 河南 焦作 454003)

摘要: 鲕粒是一类特殊的沉积颗粒, 其分布的疏密程度、粒径大小等信息可以直观地反映形成环境的水深以及水动力条件, 具有重要的地质意义。在地质学中, 通常将鲕粒岩石标本磨制成岩石薄片, 并依靠专业人员在显微镜下观察来获取鲕粒含量、圆度、径粒大小等数据的估计值, 存在着计算量大、成本高、周期长、人力投入大等缺点, 而且该方法受主观因素影响较大, 不同专家得出的结果也不尽相同。针对上述问题, 本文提出了基于深度学习的鲕粒智能检测与特征统计方法, 主要采用 YOLOv5 检测模型对鲕粒岩石薄片显微图像进行检测, 并在 YOLOv5 网络主干部分添加轻量级的 SE-Net 通道注意力机制模块来提升检测性能; 其次, 本次使用 DIoU-NMS 替换 NMS 方法, 改善图像中鲕粒分布拥挤时的漏检问题。实验证明改进后的算法最终精确率达到了 98.8%, 比原算法提升了 1.3%。最后利用图像处理技术, 对检测结果进行量化统计和分析, 得到图像中鲕粒含量、圆度信息、粒径大小的统计结果直方图, 为地质工作人员进行相关工作提供了极大的便利。

关键词: 深度学习; 改进 YOLOv5; 鲕粒检测; 注意力机制; 统计分析

中图分类号: P585; TP391.41

文献标识码: A

doi: 10.16461/j.cnki.1000-4734.2023.43.059

第一作者: 张晓燕, 女, 2000 年生, 硕士, 主要从事数字图像处理及智能数据处理. E-mail: 2195822015@qq.com

Oolitic intelligent detection and feature statistics based on deep learning

ZHANG Xiaoyan¹, LI Yan², LU Bibo^{1*}, HOU Guangshun³, XING Zhifeng³, YANG Xiaopeng⁴

(1. School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454003, China; 2. College of Computer Science and Technology, Jiaozuo Metallurgical building Materials Senior Technical School, Jiaozuo 454003, China; 3. Institute of Resources and Environment, Henan Polytechnic University, Jiaozuo 454003, China; 4. School of Surveying and Land Information Engineering, Henan Polytechnic University, Jiaozuo 454003, China)

Abstract: Oolite is a special kind of sedimentary particles, and its distribution density, grain size and other information can intuitively reflect the water depth and hydrodynamic conditions of the formation environment. It has important geological significance. In geology, oolitic rock specimens are usually ground into rock thin sections which are then observed under the microscope by professionals for obtaining the estimated values of oolitic content, roundness, grain size and so on. This method has various shortcomings including the large amount of computation, high cost, long period and large manpower input, etc. Moreover, this method is greatly affected by subjective factors, with relatively different results obtained by different experts. To address the above problems, in this paper, we have proposed a deep learning-based oolite intelligent detection and feature statistics method. The YOLOv5 detection model is mainly adopted for detecting micrographs of oolite rock thin sections, and a lightweight SE-Net channel attention mechanism module is then added into the backbone part of the YOLOv5 network for improving the detection performance. Then, the NMS method is replaced by the DIoU-NMS method for improving the problem of missing detection when the oolite distribution is crowded in the image. The experimental results show that final accuracy of the improved algorithm reached 98.8%, which was 1.3% higher than that

收稿日期: 2022-10-04

基金项目: 国家自然科学基金项目 (编号: 41773024); 河南省高等学校重点科研项目资助计划 (编号: 21A520016); 河南省本科高校省级大学生创新创业训练计划项目 (编号: S202110460005)

* 通信作者, E-mail: lubibo@hpu.edu.cn

of the original algorithm. Finally, quantitative statistics and analysis of the detection results have been carried out by using the image processing technology, and histograms of the statistical results of the oolite content, roundness information and grain size in images have been obtained. The great convenience is provided to geological staffs for carrying out related works.

Keywords: deep learning; improved YOLOv5; oolitic detection; attention mechanism; statistical analysis

鲕粒是球形或椭球形的碳酸盐颗粒, 以一个核心被外部的皮质所包裹为特征, 其核心通常为生物碎屑、似球粒等, 外部皮层具有较好的纹理结构, 一般呈光滑同心状或放射状^[1]。鲕粒直径较小, 大多数在 0.5~1.0 mm 之间。鲕粒的微结构、粒径分布等特征可以直观地反映形成环境、水动力条件和水深等信息^[2-4]。因此鲕粒在研究浅海的沉积作用模式、还原古沉积环境等方面, 都有很大的研究价值^[5-7]。除此之外, 富含鲕粒的地层, 其孔隙度、渗透性均较高, 是很好的油气储集地点, 因而常被认为是油气勘探的重要地区^[8]。由于鲕粒的形成机理较为特殊, 很多地质学家对鲕粒的成因有着浓厚的兴趣。

在偏光显微镜下观察鲕粒岩石薄片, 对薄片中的鲕粒分布的疏密程度、颗粒的大小、形状、结构和矿物成分等因素进行识别与分析, 是常规地质工作^[9]。该项工作一般由相关专业人员根据多年的知识和经验来完成, 但这种方法存在着周期长、人力投入大等问题, 而且容易受到主观因素的影响, 因此不同专家的分析结果也有一定的差异。近些年来很多学者采用深度学习对岩石薄片图像的识别与分类做了大量研究, 取得了不少成果。例如, 2016 年, 程国建和刘丽婷^[10]提出了基于深度信念网络对岩石孔隙进行识别研究的技术路线以及基于 CNN 的分类方法。刘丽婷^[11]在 2017 年运用深度信念网络对岩石薄片图像进行了分类, 取得了良好的实验效果。2019 年, 白林和魏昕等^[12]选取了 6 种常见的岩石薄片图像, 并使用 VGG 模型进行训练, 识别准确率达到 82%, 并对实验结果进行分析实验, 结果显示了模型的可行性。2019 年, 彭伟航和白林等^[13]使用改进的 InceptionV3 模型对常见矿物进行识别, 取得了较好的识别效果。2020 年, 朱世松和杨文艺等^[14]采集了 10 种常见矿物岩石薄片图像, 使用 VGG16 进行训练, 最终 10 种岩石薄片图像的平均分类准确率达到 98.1%。2021 年贾立铭和梁少华^[15]采用了 ResNet 模型, 选取了“中国科学数据”中的部分岩石薄片图像进行训练, 最终准确率收敛在 96.8% 左右。大多数实例表明, 利用深度学习网络模型对岩石薄片图像进行自动识别与分析, 可以显著提升分类效率, 解放人力。

尽管上述方法证明了将深度学习技术应用于岩石薄片图像智能识别与分类中可以提高准确性, 但大多数模型通常是将鲕粒岩石薄片图像作为常见的岩石薄片图像中的一类进行分类工作, 并没有针对鲕粒岩石薄片图像进行处理的方法。因此无法获取鲕粒岩石薄片图像中鲕粒的个数、形状、大小等重要信息, 目前这些信息的获取还是依靠专业人员在显微镜下进行观察估计或借助 PS 等第三方软件进行估计, 存在着效率低、速度慢、无法形成地质大数据等缺点。

基于以上问题, 本文基于 YOLOv5 模型提出了一种基于深度学习的鲕粒智能检测与特征统计方法, 通过在 YOLOv5s 主干部分加入 SE-Net^[16]通道注意力模块, 提升模型训练效果; 其次, 本文使用 DIoU-NMS^[17]对原 YOLOv5 模型中的 NMS 方法进行改进, 改善鲕粒分布拥挤时的漏检问题。最后通过实验验证了改进后模型的有效性, 改进后的模型几乎能检测出图像中的所有鲕粒颗粒, 能获取到图片中的鲕粒的个数、长宽比、外接矩形面积、颗粒含量、粒径大小等数据, 为地质工作者的研究分析工作提供了极大的便利。

1 相关理论介绍

1.1 YOLOv5 网络模型介绍

为了对镜下地质薄片显微图像中的鲕粒进行定位和特征提取, 本文采用深度学习中的 YOLOv5 模型来检测鲕粒位置。YOLOv5 是一阶段目标检测模型, 其候选框产生、对目标分类以及位置的调整操

作同时进行检测速度较快。根据网络深度和宽度的不同, YOLOv5 分为 4 个模型。基于对模型部署的难易以及识别精度等因素的综合考量, 本文选用体积最小的网络 YOLOv5s 模型, 并根据鲕粒数据特点对网络结构进行改进。

1.2 SE-Net 注意力机制

SE (squeeze and excitation) 是一个轻量级的注意力模块, 其结构如图 1 所示。




图 1 SE 模块

Fig. 1. The squeeze and excitation module

SE 模块的具体操作过程: 对于一张输入大小为 $H' \times W' \times C'$ 的彩色图片 X , 首先对 X 进行卷积运算 F_{tr} 获得尺寸为 $H \times W \times C$ 的特征图 U , 然后对特征图 U 进行 squeeze 操作, 即对特征图 U 进行全局平均池化, 将得到一组 $1 \times 1 \times C$ 维向量。然后进行 excitation 操作, 首先通过一个全连接层将这组 $1 \times 1 \times C$ 向量降维到 $1 \times 1 \times (C/r)$, 此处的 r 为降维率, 起到降低通道数从而减少计算量的作用; 再通过一个全连接层将这组向量升维到 $1 \times 1 \times C$, 经激活函数后得到各通道的权值, 输出为加权后的特征图。

2 YOLOv5 算法改进

鲕粒颗粒在显微图像中分布稀疏程度不一且背景复杂。若鲕粒颗粒大小适中且分布较为稀疏, YOLOv5 模型可以较为准确地检测到鲕粒颗粒, 但颗粒较为密集甚至出现粘连现象时, 原 YOLOv5 模型会出现漏检、错检等情况。为此, 本文结合图像的特征对原有模型进行改进。

2.1 特征提取网络的改进

深度学习的注意力机制实质上类似于人类的选择性注意力机制, 其主要目的在于将注意力集中于关键区域, 获取更详细的信息, 同时抑制不必要的信息。SE-Net 具有构造简单, 容易部署, 可以通过学习的方式来自动获取到每个特征通道的重要程度的优点。因此本文在 YOLOv5s 主干网络结构的最后一层添加了 SE 模块。改进后的网络结构如图 2 所示。

2.2 非极大值抑制 (NMS) 改进

在目标检测过程中, 同一个目标可能会产生很多预测框, 需要极大值抑制算法去除冗余的预测框。YOLOv5 模型中的非极大值抑制算法处理步骤为: 将所有的预测框按照置信度值从大到小进行排序, 挑选出得分最高的预测框 M 作为基准, 依次计算其余预测框与预测框 M 的交并比 (Intersection over Union, IoU) 值, 当 IoU 值大于预先设定的阈值时, 则删除该预测框, 反之则保留。在训练过程中发现, 这样的处理方法可能会造成鲕粒颗粒的漏检。分析后得知, 原因在于显微图像中的鲕粒颗粒分布稀疏不均匀, 存在较为密集的情况, 仅使用 IoU 阈值作为判断条件去筛掉其他预测框时, 易出现检测框被误删的情况, 从而造成鲕粒漏检问题。图 3 给出漏检示例, 由于鲕粒 A 和鲕粒 B 检测框重叠面积较大, 当检测框 A 的得分较高时, 检测框 B 易被错误的删除。




图 2 YOLOv5s+SE 网络框架

Fig. 2. The YOLOv5s+SE network framework.

为此, 本文使用距离 IoU-NMS (DIoU-NMS) 算法替换 YOLOv5s 原模型中的非极大值抑制方法。DIoU-NMS 不仅将预测框和真实框的交并比值作为考量因素, 还考虑到了预测框和真实框中心点的距离, 当 2 个预测框有较大的重叠面积但中心点较远时, DIoU-NMS 会认定为 2 个鲷粒, 因此可以改善鲷粒的漏检情况。DIoU-NMS 对预测框得分的更新公式如式(1)所示:

$$S_i = \begin{cases} S_i, \text{IoU} - R_{\text{DIoU}}(M, B_i) < N_t \\ 0, \text{IoU} - R_{\text{DIoU}}(M, B_i) \geq N_t \end{cases} \quad (1)$$

其中, S_i 为第 i 个检测框的分数, M 为得分最高的预测框, B_i 为第 i 个检测框, N_t 为阈值, R_{DIoU} 是 2 个检测框中心点的距离与 2 个检测框的最小包围框的最短对角线长度的比值, 公式如式(2)所示:

$$R_{\text{DIoU}} = \frac{\rho^2(b, b^{gt})}{c^2} \quad (2)$$

其中 $\rho^2(\cdot)$ 是欧式距离, b 和 b^{gt} 是预测框和真实框中心点, c 是 2 个检测框的最小包围框的最短对角线长度。




图 3 目标框重叠面积较大图像示例

Fig. 3. Example of image with large overlapped area of target box.

3 实验过程及结果分析

3.1 实验数据


鲕粒数据集由 3 部分数据构成。第 1 部分自采于河南理工大学, 第 2 部分源自鄂尔多斯盆地中寒武统徐庄组岩石薄片显微图像数据集^[18] (下称“徐庄组数据集”), 第 3 部分源自上扬子西北缘飞仙关组碳酸盐岩显微图像数据集^[19] (下称“飞仙关组数据集”)。表 1 给出原始图像来源、图像数量、采集设备等信息和分辨率等情况。采用旋转、添加噪声、直方图均衡化等方法对原始图像进行增强后得到最终图像为 1800 张。

图 4 展示了本文使用到的部分图像。从图 4 中可以看出, 鲕粒图片背景、鲕粒颜色、形状等因素复杂多样, 部分鲕粒分布密集, 给检测带来了一定的困难。

表 1 实验数据信息

Table 1. Experimental data information

图像来源	数量/张	采集设备型号	分辨率
自采数据集	260	Leica DM750P	2560×1920
徐庄组数据集 ^[18]	20	WieNikon LV100POL	1280×960
飞仙关组数据集 ^[19]	20	Nikon LV100 POL	800×600



c. 飞仙关组数据集部分图像展示

图 4 鲕粒岩石薄片图像

Fig. 4. Images for oolitic rock thin section.

3.2 实验环境

实验使用 linux 操作系统、Quadro RTX 8000 显卡、Pytorch 深度学习框架、CUDA 11.4 计算架构进行。

3.3 模型训练

本文使用 labeling 标注工具对图像进行标注, 并按 8 : 1 : 1 的比例将图像分为数据集、验证集和测试集。图片分辨率大小设置为 640×640, 批次大小 (batch size) 设置为 8, 初始学习率设置为 0.01, IoU 阈值设置为 0.5, 训练轮数设置为 200。

3.4 评价指标

为检验模型的性能, 本文选取精确率 (Precision)、召回率 (Recall)、平均精确率 (mAP)、参数量等客观指标对模型进行评估, 精确率、召回率、平均精确率计算公式如式(3) ~ (6)所示:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (3)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (4)$$

$$\text{mAP} = \frac{\sum_{i=1}^C \text{AP}_i}{C} \quad (5)$$

$$\text{AP} = \int_0^1 P(R) dR \quad (6)$$

其中, TP 表示被正确检测出的目标数量, 本文中指正确检测出的鲕粒岩石薄片图像中的鲕粒数量; FP 代表被误检的目标数量, 本文中指被误检的鲕粒数量; FN 为未被检测出的目标数量, 本文中指未被检测出的鲕粒数量; C 为类别个数, 本文中只对图像中的鲕粒进行检测, 因此 $C=1$; AP_i 为第 i 个类别的精确率。

3.5 实验结果及分析


为了证明模型各项改进点的有效性, 本文对模型改进前后的性能指标进行了记录, 如表 2 所示。表 2 显示, 仅添加 SE 注意力模块之后的网络模型训练平均精确率比 YOLOv5s 原网络模型提高了 0.8%, 仅将 NMS 替换为 DIoU-NMS 后训练平均精确率比 YOLOv5s 原网络模型提高了 0.6%, 同时使用这两种方法后平均精确率提高了 1.3%, 最终精确率达到了 98.8%, 而模型参数量仅有小幅度的增加。

为了更加直观的比较改进模型前后对图像中鲕粒的检测效果, 将改进前后的模型分别对背景与鲕粒颜色相差较小以及鲕粒分布较为密集的鲕粒岩石薄片显微图像进行检测。为了能够更清晰地观察到检测效果, 对于鲕粒分布较为密集的鲕粒岩石薄片图像, 去掉了

表 2 改进过程的对比实验结果

Table 2. Comparative experimental results of the improvement process

模型	召回率/%	平均精确率/%	参数量
YOLOv5s	99	97.5	7.06M
YOLOv5s+SE	99	98.3	7.37M
YOLOv5s+DIoU-NMS	99	98.1	7.06M
YOLOv5s+SE+DIoU-NMS	99	98.8	7.37M



a. YOLOv5s 检测结果; b. YOLOv5s+SE+DIoU 检测结果

图 5 背景与目标鲕粒色差较小的图像检测结果

Fig. 5. Images of detection results with small color difference between background and targeted oolitic particles.

检测框左上方的置信度预测值的显示,仅保留了目标检测框,图 5 和图 6 给出了算法改进前后的部分检测结果。由图 5a 中可以看出,当图像背景颜色与目标鲕粒的颜色色差较小时,原算法易将背景识别为鲕粒目标,从而造成误检的问题,由图 5b 中可以看出,改进后的算法则较好的解决了误检的问题。由图 6a 中可以看出,当图像中鲕粒分布较为密集时,原算法易出现漏检的问题,由图 6b 中可以看出,改进后的算法则较好地解决了漏检的问题。

为了验证本文模型的检测能力与泛化能力,使用测试集对模型进行测试,结果如图 7 所示。对于鲕粒密集的图片,在展示时去掉了置信度预测值数值、只给出检测框以增强显示效果。从结果可以看出,模型基本可以检测出不同背景、不同颜色、不同形状、不同类型的鲕粒颗粒,表明改进后的算法对鲕粒岩石薄片图像有较好的泛化能力以及很好的识别效果。

3.6 本文算法与其他算法的对比


将本文中的算法与主流的目标检测模型 Faster RCNN、SSD、YOLOv3-SPP、YOLOv4-tiny 进行

比较,结果如表 3 所示。数据显示,与 Faster RCNN、SSD、YOLOv3-SPP、YOLOv4-tiny 等模型相比,本文算法具有较高的平均精确率、权重文件大小较小、检测速度较快。此外,由于本文模型较小,因此可以嵌入到智能显微镜设备中,实现鲕粒智能识别和分析。

4 鲕粒特征统计分析

由于从河南理工大学资源环境学院采集到的鲕粒岩石薄片图像的取材地点不详,因此本文仅对徐庄组数据集与飞仙关组数据集中的图像进行统计分析。

根据检测框形状和比例尺信息,即可计算得到鲕粒粒径大小,对徐庄组数据集以及飞仙关组数据集中的鲕粒粒径大小进行统计,以 0.3 mm 为一个区间长度进行划分,给出粒径大小在该区间内的鲕粒数量占全部鲕粒数量的百分比,结果如图 8 所示。



a. YOLOv5s 检测结果; b. YOLOv5s+SE+DIoU 检测结果

图 6 密集目标图像检测结果

Fig. 6. Image of detection results of intensive targets.

表 3 本文算法与其他算法对比实验结果

Table 2. Experimental results of comparison between the proposed algorithm and other algorithm models

模型	平均精确率/%	权重文件大小/MB	速度/(帧/s)
YOLOv5s+SE+DIoU-NMS	98.8	15.0	67
Faster RCNN	90.7	315.0	2
SSD	91.1	100.2	34
YOLOv3-SPP	90.2	323.0	9
YOLOv4-tiny	87.3	22.4	87





图 7 检测结果展示

Fig. 7. Display for detection results.




a. 徐庄组数据集鲕粒粒径大小分布直方图; b. 飞仙关组数据集鲕粒粒径大小分布直方图

图 8 鲕粒粒径大小统计直方图

Fig. 8. Histograms of size statistics for oolitic particles.


根据检查结果, 可以估计鲕粒颗粒占图像面积的比值, 即可得到鲕粒占比信息; 使用椭圆拟合检测框形状, 可以估算出鲕粒的圆度信息。鲕粒占比以及圆度信息统计结果如图 9、图 10 所示。



a. 徐庄组数据集鲕粒含量分布直方图; b. 飞仙关组数据集鲕粒含量分布直方图

图 9 鲕粒含量分布直方图

Fig. 9. Histograms for oolitic contents.



a. 徐庄组数据集鲕粒圆度分布直方图; b. 飞仙关组数据集鲕粒圆度分布直方图

图 10 鲕粒圆度分布直方图

Fig. 10. Histograms for oolitic roundness values.

5 结语

针对传统人工在显微镜下观察鲕粒岩石薄片显微图像方法中存在的成本高、周期长、人力投入大等缺点,本文提出了一个基于深度学习的鲕粒岩石薄片检测分析方法,根据图像的特征对YOLOv5s网络进行了改进,将YOLOv5s和SENet相结合的方法运用到岩石薄片图像的检测分析中,并且使用DIoU-NMS对原NMS方法进行替换,来提高对分布较为密集鲕粒图像的检测精确率,改进后的模型在保持了较高的平均精确率的同时,模型大小、参数量和计算量仅仅只有小幅度的增加。鲕粒检测结果不仅可以用于鲕粒判定、鲕粒计数,还可以进一步估计鲕粒颗粒的粒径大小、图像中鲕粒颗粒占图像面积的比值以及鲕粒颗粒的圆度大小分布情况等信息,可为地质分析提供基础数据。

参考文献:

- [1] 郭芪恒, 金振奎, 史书婷, 等. 鲕粒粒度特征及其指示意义——以北京西山下苇甸寒武系张夏组剖面为例[J]. 沉积学报, 2020, 38(4): 737-746.
- [2] 齐永安, 杨小伟, 代明月, 等. 豫西登封地区寒武系第三统鲕粒和鲕粒灰岩演化及其意义[J]. 古地理学报, 2014, 16(1): 55-64.
- [3] 倪胜利. 北京西郊下苇甸剖面寒武系叠层石中的底栖鲕粒: 基本特征和重要意义[J]. 地质通报, 2017, 36(Z1): 485-491.
- [4] Trower E J, Lamb M P, Fischer W W. Experimental evidence that ooid size reflects a dynamic equilibrium between rapid precipitation and abrasion rates[J]. Earth and Planetary Science Letters, 2017, 468: 112-118.
- [5] 李飞, 武思琴, 刘柯. 鲕粒原生矿物识别及对海水化学成分变化的指示意义[J]. 沉积学报, 2015, 33(3): 500-511.
- [6] 宋文天, 刘建波. 碳酸盐鲕粒包壳结构研究综述[J]. 古地理学报, 2020, 22(1): 147-160.
- [7] 巩恩普, 杨臻元, 黄文韬, 等. 广西隆安都结剖面下石炭统都安组上部鲕粒类型及其地质意义[J]. 古地理学报, 2021, 23(1): 125-141.
- [8] 李开开, 张学丰, 贺训云, 等. 川东北飞仙关组白云岩化作用对鲕粒滩储层的孔隙改造效应[J]. 石油与天然气地质, 2018, 39(4): 706-718.
- [9] 姜枫. 基于语义识别的砂岩薄片图像分割方法研究[D]. 南京: 南京大学, 2018.
- [10] 程国建, 刘丽婷. 深度学习算法应用于岩石图像处理中的可行性研究[J]. 软件导刊, 2016, 15(9): 163-166.
- [11] 刘丽婷. 深度信念网络在岩石薄片图像处理中的应用研究[D]. 西安: 西安石油大学, 2017.
- [12] 白林, 魏昕, 刘禹, 等. 基于VGG模型的岩石薄片图像识别[J]. 地质通报, 2019, 38(12): 2053-2058.
- [13] 彭伟航, 白林, 商世为, 等. 基于改进InceptionV3模型的常见矿物智能识别[J]. 地质通报, 2019, 38(12): 2059-2066.
- [14] 朱世松, 杨文艺, 侯广顺, 等. 一种岩石薄片智能分类识别方法[J]. 矿物学报, 2020, 40(1): 106.
- [15] 贾立铭, 梁少华. 一种基于Resnet的岩石薄片识别方法[J]. 电脑知识与技术, 2021, 17(28): 107-109.
- [16] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2018: 7132-7141.
- [17] GONG M, WANG D, ZHAO X, et al. A review of non-maximum suppression algorithms for deep learning target detection[C]//Seventh Symposium on Novel Photoelectronic Detection Technology and Application 2020: 2021.
- [18] 钱红杉, 邢凤存, 张春林, 等. 鄂尔多斯盆地中寒武统徐庄组岩石薄片显微图像数据集[J]. 中国科学数据(中英文网络版), 2020, 5(3): 205-215.
- [19] 柴寒冰, 邢凤存, 古强, 陈孝全, 周绍鹏. 上扬子西北缘飞仙关组碳酸盐岩显微图像数据集[J]. 中国科学数据(中英文网络版), 2020, 5(3): 131-140.