

文章编号: 1671-251X(2024)02-0009-09

DOI: 10.13272/j.issn.1671-251x.2023100002

基于双层路由注意力机制的煤粒粒度定量分析

程德强¹, 郑丽娟¹, 刘敬敬¹, 寇旗旗², 江鹤¹

(1. 中国矿业大学 信息与控制工程学院, 江苏 徐州 221000;

2. 中国矿业大学 计算机科学与技术学院, 江苏 徐州 221000)

摘要: 煤粒粒度分布特征与煤中甲烷气体传播规律的分析密切相关。目前, 基于图像分割的煤粒粒度分析方法已成为获取煤粒粒度的主流方案之一, 但存在上下文信息丢失、煤粒特征融合不当造成煤粒漏分割和过分割等问题。针对上述问题, 设计了一种基于双层路由注意力机制(BRA)的煤粒粒度分析模型。在残差 U 型网络 ResNet-UNet 中嵌入 BRA 模块, 得到 B-ResUNet 网络模型: 为减少在煤粒分割过程中出现的漏分割问题, 在 ResNet-UNet 网络的上采样前添加 BRA 模块, 使网络根据上一层的特征调整当前特征层的重要性, 增强特征的表达能力, 提高长距离信息的传递能力; 为减少在煤粒分割过程中出现的过分割问题, 在 ResNet-UNet 网络的特征拼接模块后添加 BRA 模块, 通过动态选择和聚合重要特征, 实现更有效的特征融合。对分割出的煤粒进行特征信息提取, 针对实验分析中采用的煤粒数据集的煤粒粒度与细胞大小相当, 为精确表征煤粒粒度, 采用等效圆粒径获取煤粒粒度及粒度分布。实验结果表明: ① B-ResUNet 网络模型的准确率、平均交并比、召回率较 ResNet-UNet 基础网络分别提高了 0.6%, 14.3%, 35.9%, 准确率达 99.6%, 平均交并比达 92.6%, 召回率达 94.4%, B-ResUNet 网络模型在煤样中具有较好的分割效果, 能够检测出较为完整的颗粒结构。② 在上采样前和特征拼接后均引入 BRA 模块时, 网络对煤粒的边缘区域给予了足够的关注, 且对一些不太重要的区域减少了关注度, 从而提高了网络的计算效率。③ 煤粒的粒度大小在 1~2 mm 内呈相对均衡的分布趋势, 粒度在 1~2 mm 内的煤粒占比最大为 99.04%, 最小为 90.59%, 表明基于 BRA 的图像处理方法在粒度分析方面具有较高的准确性。

关键词: 煤粒粒度; 粒度分布; 双层路由注意力机制; 图像处理; 残差 U 型网络; 语义分割; 等效圆粒径
中图分类号: TD391.41 文献标志码: A

Quantitative analysis of coal particle size based on bi-level routing attention mechanism

CHENG Deqiang¹, ZHENG Lijuan¹, LIU Jingjing¹, KOU Qiqi², JIANG He¹

(1. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221000, China; 2. School of Computer Science & Technology, China University of Mining and Technology, Xuzhou 221000, China)

Abstract: The distribution features of coal particle size are closely related to the analysis of methane gas propagation in coal. At present, the coal particle size analysis method based on image segmentation has become one of the mainstream solutions to obtain coal particle size. But there are problems such as loss of contextual information, improper fusion of coal particle features resulting in missed segmentation and over-segmentation of coal particles. In order to solve the above problems, a coal particle size analysis model based on bi-level routing

收稿日期: 2023-10-03; 修回日期: 2024-02-05; 责任编辑: 王晖, 郑海霞。

基金项目: 国家自然科学基金项目(52204177, 52304182); 济宁市重点研发计划项目(2021KJHZ013, 2023KJHZ007); 徐州市推动科技创新专项资金项目(KC23401)。

作者简介: 程德强(1979—), 男, 河南洛阳人, 教授, 博士, 博士研究生导师, 主要研究方向为图像处理、机器视觉, E-mail: chengdq@cumt.edu.cn。通信作者: 江鹤(1990—), 男, 江苏徐州人, 讲师, 博士, 主要研究方向为图像超分辨率重建、图像识别, E-mail: jianghe@cumt.edu.cn。

引用格式: 程德强, 郑丽娟, 刘敬敬, 等. 基于双层路由注意力机制的煤粒粒度定量分析[J]. 工矿自动化, 2024, 50(2): 9-17.

CHENG Deqiang, ZHENG Lijuan, LIU Jingjing, et al. Quantitative analysis of coal particle size based on bi-level routing attention mechanism[J]. Journal of Mine Automation, 2024, 50(2): 9-17.



扫码移动阅读

attention (BRA) is designed. The BRA module is embedded in the residual U-shaped network ResNet-UNet to obtain the B-ResUNet network model. To reduce the problem of missed segmentation in coal particle segmentation, a BRA module is added before upsampling in the ResNet-UNet network. It allows the network to adjust the importance of the current feature layer based on the features of the previous layer, enhance the expression capability of features, and improve the transmission capability of long-distance information. To reduce the problem of over segmentation in coal particle segmentation, a BRA module is added after the feature concatenation module of the ResNet-UNet network. By dynamically selecting and aggregating important features, more effective feature fusion is achieved. The feature information from the segmented coal particles is extracted. The coal particle size of the coal particle dataset used in the experimental analysis is equivalent to the cell size. In order to accurately characterize the coal particle size, equivalent circular particle size is used to obtain the coal particle size and size distribution. The experimental results show the following points. ① The accuracy, average intersection to union ratio, and recall of the B-ResUNet network model have been improved by 06.%, 14.3%, and 35.9% compared to the ResNet-UNet basic network, with an accuracy of 99.6%, an average intersection to union ratio of 92.6%, and a recall of 94.4%. The B-ResUNet network model has good segmentation performance in coal samples and can detect relatively complete particle structures. ② When the BRA module is introduced before upsampling and after feature concatenation, the network pays sufficient attention to the edge areas of coal particles and reduces attention to some less important areas, thereby improving the computational efficiency of the network. ③ The particle size of coal particles shows a relatively balanced distribution trend within 1-2 mm, with the maximum proportion of coal particles within 1-2 mm being 99.04% and the minimum being 90.59%. It indicates that the image processing method based on BRA has high accuracy in particle size analysis.

Key words: coal particle size; particle size distribution; double layer routing attention mechanism; image processing; residual U-shaped network; semantic segmentation; equivalent circular particle size

0 引言

随着煤炭工业不断发展,煤粒粒度成为直接影响分析煤中甲烷气体传播规律的关键因素。不同粒度的煤粒对甲烷气体的吸附、扩散及释放等过程表现出显著差异^[1-2]。因此,煤粒粒度分析成为煤炭工业生产和能源利用领域的重点和热点研究内容。

传统的煤粒粒度分析方法包括筛分、液体排量和激光粒度分析等^[3-4],这些分析方法通过直接测量煤粒的筛选情况、沉降速度或光散射等物理特性来获取煤粒的粒度信息。尽管这些方法在煤炭工业中有一定的应用,但它们在准确性、效率方面都存在限制,难以满足现代工业生产的需求。

近年来,随着图像处理技术的快速发展,许多学者采用图像分析法对煤粒粒度进行测量。文献^[5]利用图像采集系统获取煤粒的二维图像,通过形态学方法测量粒度在 1~2 mm 的煤粒,进而推导出煤粒的粒度分布对甲烷气体扩散系数的影响。但使用二维方法^[6-7]对煤粒粒度进行研究时,常会面临图像噪声、煤粒形状多样性等挑战。文献^[8]使用 X 射线计算机断层扫描技术,以微米级分辨率图像直观展

示颗粒的三维粒度特征。由于 X 射线计算机断层扫描仪价格昂贵,难以在实验室中进行大规模应用。随着计算机视觉技术的快速发展,基于深度学习^[9]的语义分割网络在处理复杂煤粒图像时表现出色,能够获取更为准确的煤粒粒度特征。文献^[10]提出了一种基于区域的卷积神经网络,用于煤粒图像的分割,但由于缺乏路由模块,导致网络会过度关注像素之间微小的差异,从而造成过分割的问题。文献^[11-12]以 U 型网络对煤尘颗粒图像进行分割,成功获取了煤粒粒度特征,证明了 U 型网络可较好地满足煤粒粒度分析的要求,且具有良好的知识迁移性,但直接使用 U 型网络对煤粒进行分割时,传统的跳跃连接不能很好地处理煤粒图像像素之间的长程依赖性,从而造成漏分割情况。

为解决在煤粒分割过程中出现的过分割和漏分割问题,本文提出了一种基于双层路由注意力机制 (Bi-level Routing Attention, BRA) 的煤粒粒度定量分析模型。首先,在残差 U 型网络 ResNet-UNet 中嵌入 BRA 模块^[13],得到 B-ResUNet 网络模型。然后,对分割出的煤粒提取特征信息,采用等效圆粒径获取煤粒粒度及粒度分布。

1 煤粒分割网络模型

1.1 ResNet-UNet 网络

ResNet-UNet 在 U-Net 基础上使用 34 层残差网络作为编码器,并使用 7×7 卷积核来提取图像特征,这样的设计使得 ResNet-UNet 具有出色的空间感知能力,能够捕获更多上下文信息,提取更全面的特征。直接将 ResNet-UNet 网络应用于煤粒的分割时,由于煤粒图像像素之间的依赖性,上下文信息在网络传输中常常会丢失,从而造成漏分割的情况;对于大小和形状相似的煤粒来说,ResNet-UNet 网络会过度关注像素之间微小的差异,从而造成过分割的问题。

1.2 BRA 模块结构

BRA 模块是一种通过双层路由机制实现的自适应注意力模块,其结构如图 1 所示。其中,双层路由机制由区域级路由和令牌级路由组成,这 2 个级别的路由有助于理解特征在不同路由区域之间的传递过程。




图 1 BRA 模块结构

Fig. 1 Structure of the BRA module

将 $H \times L$ (长 $\times$ 宽) 的二维输入特征图分为 $s \times s$ 个不重叠的区域,从而得到输入特征图中的特征向量。通过对这些特征向量进行线性映射,可得到查询张量 Q 、键张量 K 和值张量 V 。

$$Q = x^r L^Q \quad (1)$$

$$K = x^r L^K \quad (2)$$

$$V = x^r L^V \quad (3)$$

式中: x^r 为重塑后的特征图; L^Q , L^K , L^V 分别为查询张量、键张量、值张量在网络中对应的权重。

采用 Q 、 K 的平均值进行区域级路由计算,并推导出区域级查询张量 Q^r 和区域级键张量 K^r ,将 Q^r 与 K^r 的转置矩阵相乘,得到区域间的邻接矩阵 B^r 。在注意力机制中, $\text{top-}k$ 策略^[14]是一种选择前 k 个最大或最小元素的算法。使用 $\text{top-}k$ 策略选择邻接矩阵 A^r 的前 k 个最大元素,并通过 topkindex 方法返回这些元素的索引地址,将其保存在矩阵 F^r 中,以此来高效

地定位有价值的键值对。

$$B^r = Q^r (K^r)^T \quad (4)$$

$$F^r = \Gamma(B^r) \quad (5)$$

式中 $\Gamma(\cdot)$ 为 topkindex 方法。

索引地址在 F^r 中的分布是分散的,因此使用 gather 算法^[15]从 F^r 中收集离散的键张量 K 和值张量 V 。为了捕捉路由区域中不同令牌之间的语义关系,采用细粒度的注意力机制。为增强上下文信息,在网络模型中引入局部上下文增强数据 U ^[16]。

$$K^s = G(K, F^r) \quad (6)$$

$$V^s = G(V, F^r) \quad (7)$$

$$O = Z(Q, K^s, V^s) + BU \quad (8)$$

其中: K^s 为聚合键张量; $G(\cdot)$ 为 gather 算法; V^s 为聚合值张量; O 为 BRA 模块最后的输出; $Z(\cdot)$ 为注意力计算函数。

1.3 B-ResUNet 网络模型结构

为减少在煤粒分割过程中出现的漏分割问题,在 ResNet-UNet 网络的上采样前添加 BRA 模块,使网络根据上一层的特征调整当前特征层的重要性,增强特征的表达能力,提高长距离信息的传递能力。同时,为减少在煤粒分割过程中出现的过分割问题,在 ResNet-UNet 网络的特征拼接模块后添加 BRA 模块,通过动态选择和聚合重要特征,实现更有效的特征融合。

B-ResUNet 网络模型主要由编码器和解码器组成,并借助跳跃连接实现了不同特征层的融合,其结构如图 2 所示。

在编码器部分,本文以 34 层预训练残差网络为基础,通过 5 次下采样来提取图像的底层语义特征。首先对输入图像进行 7×7 的卷积处理,并利用 3×3 最大池化层提取图像的重要信息。然后,使用 4 组通道数不同的残差块(3 个通道数为 64 的残差块、4 个通道数为 128 的残差块、6 个通道数为 256 的残差块和 3 个通道数为 512 的残差块)对输入向量进行特征融合,以缓解网络梯度消失的现象。每个残差块由 2 个 3×3 卷积层和非线性激活单元组成,如图 3 所示。其中, X_l 为残差块的输入, l 为神经元的层数, $f(\cdot)$ 为残差网络的映射函数, Y_l 为残差块的最终输出。最后,使用 2×2 的最大池化层进行池化。在解码器部分,网络通过 5 次上采样操作恢复编码器输出的语义特征,从而实现对图像的精准分割。将解码器输出的结果与原始图像尺寸相匹配,得到煤粒分割图。




图 2 B-ResUNet 网络模型结构

Fig. 2 Structure of B-ResUNet network model




图 3 残差块

Fig. 3 Residual block

2 煤粒粒度分析

通过对分割出的煤粒提取特征信息,成功获取煤粒粒度及粒度分布,这对于量化甲烷气体传播规律和优化煤炭加工工艺具有重要意义。鉴于煤粒形态的多样性,不同煤粒粒度表征方法可能引起不同程度的误差^[17]。因此,为了精确表征煤粒的粒度,选择合适的粒度表示方法至关重要。

等效圆粒径^[18-19]是将颗粒的实际形态近似为具有相同面积的圆形,通过计算该圆形的直径来获得等效粒度,其等效过程如图 4 所示。本文所制作的煤粒数据集中的粒度与细胞大小相当,且形态复杂多样,因此,采用等效圆粒径来表征煤粒的粒度大小。

$$D = (4e/\pi)^{0.5} \quad (9)$$

式中: D 为等效圆粒径; e 为煤粒的实际面积。




图 4 等效圆粒径原理

Fig. 4 Principle of the equivalent circular particle size

在使用等效圆粒径方法计算煤粒的像素粒度大小时,为了将像素转换为实际尺寸,以确保粒径测量的准确性,须确定像素与实际长度之间的转换比例系数^[20]。首先校准图像中的像素大小,将像素转换为实际尺寸。接着,进行图像系统的标定,以建立图像中像素坐标与实际物理坐标之间的转换关系,从而确保粒度分析的准确性和可靠性。

选用边长为 5 mm 的正方形^[21]作为标定对象。

$$\delta = \frac{M}{E} \quad (10)$$

$$S' = S\delta^2 \quad (11)$$

$$P' = P\delta \quad (12)$$

$$d' = d\delta \quad (13)$$

式中: δ 为长度比例系数; M 为单位长度; E 为单位长度的像素数; S' 为实际的粒子面积; S 为粒子以像素为单位的面积; P' 为实际粒子周长; P 为粒子以像素为单位的周长; d' 为实际粒子直径; d 为粒子以像素为单位的直径。

3 模型数据及训练

3.1 数据集构建

基于深度学习的煤粒分割网络需大量数据进行训练,但网上缺乏开源的煤粒数据集。因此,本文制作了煤粒数据集。首先,从永煤集团股份有限公司顺和煤矿随机选取粒径为1~2 mm的4 000多个煤粒,并将它们编组为1—6。然后,使用Labelme^[22]对煤粒进行标注,并对标注后的图像进行数据格式转换和可视化,可视化结果如图5所示。最后,为提高煤粒图像质量并突出煤粒粒度特征,对煤粒图像进行了预处理,其中包括图像灰度化和二值化、高斯滤波和网格畸变、翻转等。在网络训练过程中,按照5:2:1的比例将煤粒数据集划分为训练集、验证集和测试集。其中训练集和验证集用于网络模型训练,测试集用于网络模型评估。




图5 煤样可视化结果

Fig. 5 Visualization of coal sample

3.2 超参数设置与模型训练

本文使用Pytorch1.12深度学习框架,在Windows10操作系统下进行煤粒的分割实验。硬件环境为AMD Ryzen 55600x处理器、16 GiB内存和Nvidia GeForce RTX 3060 12 GiB显存GPU。在自建的煤粒数据集上,利用34层残差网络的预训练模型进行训练。训练轮数为15,训练步长为1,批处理尺寸为2。训练集包括约2 500个形态各异的煤粒,在训练过程中,优化器为AdamW,其学习率为0.001,权重衰减因子为0.01,动量参数 β_1 和 β_2 分别为0.9和0.999。使用交叉熵损失函数来计算网络输出结果与真实标签之间的差异,并添加 L_2 正则化项来减轻过拟合。为加快网络模型的收敛速度,采用OneCycleLR训练策略调整学习率。

$$J = -[\eta \log_2 \hat{y} + (1 - \eta) \log_2 (1 - \hat{y})] + \frac{\psi}{2} \|w\|^2 \quad (14)$$

式中: J 为网络总损失; η 为煤粒的真实标签; $\hat{y}$ 为网络模型的预测概率; ψ 为 L_2 正则化项的超参数; $\|w\|^2$ 为权重 w 的 L_2 范数。

3.3 评估指标

采用准确率、平均交并比、召回率作为网络模型

的评价指标。

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{FN} + N_{TN}} \quad (15)$$

$$I = \frac{1}{2} \left(\frac{N_{TP}}{N_{TP} + N_{FP} + N_{FN}} + \frac{N_{TN}}{N_{TN} + N_{FN} + N_{FP}} \right) \quad (16)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (17)$$

式中: A 为准确率; N_{TP} 为模型正确预测为正类的样本数; N_{TN} 为模型正确预测为负类的样本数; N_{FP} 为模型错误预测为正类的样本数; N_{FN} 为模型错误预测为负类的样本数; I 为平均交并比; R 为召回率。

4 实验结果与分析

4.1 煤粒分割实验

4.1.1 对比实验

为评估B-ResUNet在煤粒分割任务中的性能,将B-ResUNet网络模型与PAN^[23]、PSPNet^[24]、U-Net^[25]、Link-Net^[26]和ResNet-UNet^[27]网络模型进行对比,结果见表1,从6组煤样中随机选取4组煤样进行对比,不同网络模型的语义分割结果如图6所示。由表1可看出,B-ResUNet网络模型在所有的分割指标中都取得了最佳结果。B-ResUNet网络模型的准确率、平均交并比、召回率较ResNet-UNet基础网络模型分别提高了0.6%,14.3%,35.9%,这说明BRA模块在提升分割性能方面的优越性,证明了B-ResUNet网络模型的卓越性。

表1 不同网络模型评价指标对比

Table 1 Comparison of the evaluation indexes of different network models

模型	准确率	平均交并比	召回率
PAN	98.3	62.8	27.8
PSPNet	98.4	66.6	36.9
U-Net	99.1	79.4	62.0
Link-Net	97.9	68.6	60.3
ResNet-UNet	99.0	78.3	58.5
B-ResUNet	99.6	92.6	94.4

由图6可看出,PAN、PSPNet、U-Net、Link-Net和ResNet-UNet网络模型在煤粒分割过程中都存在不同程度的过分割和漏分割问题,B-ResUNet网络模型在4组煤样中具有较好的分割效果,能够检测出较为完整的颗粒结构。这是因为在B-ResUNet网络中加入的BRA模块使模型更加关注与分割相关的语义信息,忽略与模型无关的特征信息,从而突出煤粒边界区域特征,有效改善颗粒分割效果。




图 6 不同网络模型的语义分割结果

Fig. 6 Semantic segmentation results for the different network models

4.1.2 消融实验

为测试 B-ResUNet 网络模型的效果,进行消融实验。分别对比在解码器结构的特征拼接后和上采样前引入 BRA 模块的情况,实验结果如图 7 所示,各模型性能见表 2。可看出在没有引入 BRA 模块的情况下,网络的特征提取效果最差,难以有效区分煤

粒目标和背景;当在解码器结构的上采样前或特征拼接后引入 BRA 模块时,网络开始对煤粒的边缘区域产生一定的关注,但关注程度并不是很高;在解码器结构的上采样前和特征拼接后均引入 BRA 模块时,网络对煤粒的边缘区域给予了足够的关注,且对一些不太重要的区域减少了关注度,从而提高了网络的计算效率,B-ResUNet 网络模型的准确率、平均交并比、召回率分别为 99.6%, 92.6%, 94.4%。这说明 BRA 模块的引入对于改善分割性能和提高运行效率起到了积极的作用。




图 7 BRA 模块的消融实验

Fig. 7 Ablation experiments of the BRA module

表 2 各网络模型性能

Table 2 Network performan %

模型	准确率	平均交并比	召回率
ResNet-UNet	99.0	78.3	58.5
ResNet-采样BRA	99.4	87.2	79.0
ResNet-拼接BRA	99.2	82.6	66.5
B-ResUNet	99.6	92.6	94.4

4.2 煤粒粒度分析

为获得更准确的煤粒粒度分布,首先采用 B-ResUNet 语义分割网络对 6 组煤粒图像进行了分割。随后,利用等效圆粒径的方法表征煤粒粒度,从而得到了 6 组煤粒粒度分布直方图,如图 8 所示。可看出 6 组煤样的粒度分布接近正态分布,表明煤粒的粒度大小在 1~2 mm 内呈相对均衡的分布趋势,说明本文方法在粒度分析方面具有一定稳定性。粒度在 1~2 mm 内的煤粒占比最大为 99.04%,最小为 90.59%,表明本文方法在粒度分析方面具有较高的准确性。

为进一步验证本文方法的可靠性和优越性,采用本文方法、基于形态学的测量方法和基于激光粒度分析(Laser Particle Analyzer, LPA)的测量方法对




图8 6组煤粒的粒度分布

Fig. 8 Particle size distribution of six groups of coal particles

6组煤样在1~2 mm内的粒度分布进行了对比, 结果见表3。

由表3可看出, 使用本文方法测量大小在1~2 mm范围内的煤粒粒度准确率较基于形态学的测量方法、基于LPA的测量方法分别提高了12.92%, 35.24%, 准确率最高达97.42%。

5 结论

1) 为了更好地对煤粒图像进行分割, 设计了B-

表3 不同方法测量粒度的准确率

Table 3 Accuracy of particle size measurement by different methods %

测量方法	准确率					
	第1组	第2组	第3组	第4组	第5组	第6组
LPA方法	62.18	57.78	56.44	38.75	67.35	68.78
形态学方法	84.50	87.83	87.82	92.0	88.48	94.29
本文方法	97.42	97.37	89.80	95.56	96.47	96.15

ResUNet 语义分割网络。与 6 种经典语义分割模型进行评估对比, B-ResUNet 网络模型准确率、平均交并比、召回率分别为 99.6%, 92.6%, 94.4%, 有效缓解了分割煤粒的过程中出现的漏分割和过分割的情况, 为获取准确的煤粒粒度分布提供了可靠的基础。

2) 通过深度学习和图像处理相结合的方法, 得到了煤粒的粒度分布, 并与基于形态学的测量方法和基于 LPA 的测量方法进行了对比。结果显示, 基于双层路由注意力机制的图像处理方法的准确率较基于形态学的测量方法、基于 LPA 测量方法分别提高了 12.92%, 35.24%。

3) 深度学习技术对训练数据集的质量要求较高, 且数据集越大、标注越精确, 效果越好, 这增加了方法的难度。因此, 未来在煤粒粒度分析方面, 需建立适用于广泛场景且具有高准确度的深度学习模型, 以进一步推动该领域的发展。

参考文献(References):

- [1] 邢震, 韩安, 陈晓晶, 等. 基于工业互联网的智能矿山灾害数字孪生研究[J]. 工矿自动化, 2023, 49(2): 23-30, 55.
XING Zhen, HAN An, CHEN Xiaojing, et al. Research on intelligent mine disaster digital twin based on industrial Internet[J]. Journal of Mine Automation, 2023, 49(2): 23-30, 55.
- [2] 张哲, 魏晨慧, 刘书源, 等. 煤粒尺寸对气体扩散过程影响的数值模拟研究[J]. 矿业研究与开发, 2021, 41(7): 85-92.
ZHANG Zhe, WEI Chenhui, LIU Shuyuan, et al. Numerical simulation study of the influence of coal particle size on gas diffusion process[J]. Mining Research and Development, 2021, 41(7): 85-92.
- [3] 马卫国, 曾立, 曾琦, 等. 真空过滤数值模拟和试验验证[J]. 流体机械, 2022, 50(12): 49-55.
MA Weiguo, ZENG Li, ZENG Qi, et al. Numerical simulation and experimental verification of vacuum filtration[J]. Fluid Machinery, 2022, 50(12): 49-55.
- [4] 李文凯, 吴玉新, 黄志民, 等. 激光粒度分析和筛分法测粒径分布的比较[J]. 中国粉体技术, 2007(5): 10-13.
LI Wenkai, WU Yuxin, HUANG Zhimin, et al. Measurement results comparison between laser particle analyzer and sieving method in particle size distribution[J]. China Powder Science and Technology, 2007(5): 10-13.
- [5] LIU Jingjing, CHENG Deqiang, LI Yunlong, et al. Quantitative evaluation of the influence of coal particle size distribution on gas diffusion coefficient by image processing method[J]. Fuel, 2022, 314: 122946.
- [6] GUIDA G, VIGGIANI G M B, CASINI F. Multi-scale morphological descriptors from the fractal analysis of particle contour[J]. Acta Geotech, 2020, 15(5): 1067-1080.
- [7] SU D, YAN W M. Prediction of 3D size and shape descriptors of irregular granular particles from projected 2D images[J]. Acta Geotech, 2020, 15(6): 1533-1555.
- [8] LAI Zhengshou, CHEN Qiushi. Reconstructing granular particles from X-ray computed tomography using the TWS machine learning tool and the level set method[J]. Acta Geotech, 2019, 14(1): 1-18.
- [9] 程德强, 钱建生, 郭星歌, 等. 煤矿安全生产视频 AI 识别关键技术研究综述[J]. 煤炭科学技术, 2023, 51(2): 349-365.
CHENG Deqiang, QIAN Jiansheng, GUO Xingge, et al. Review on key technologies of AI recognition for videos in coal mine[J]. Coal Science and Technology, 2023, 51(2): 349-365.
- [10] 李颖, 李秀宇, 卢兆林, 等. 基于深度学习的煤粉颗粒 CT 图像分割方法[J]. 计算机工程与设计, 2022, 43(8): 2252-2259.
LI Ying, LI Xiuyu, LU Zhaolin, et al. Coal particle CT image segmentation method based on deep learning[J]. Computer Engineering and Design, 2022, 43(8): 2252-2259.
- [11] 徐江川, 金国强, 朱天奕, 等. 基于深度学习 U-Net 模型的石块图像分割算法[J]. 工业控制计算机, 2018, 31(4): 98-99, 102.
XU Jiangchuan, JIN Guoqiang, ZHU Tianyi, et al. Segmentation of rock images based on U-Net[J]. Industrial Control Computer, 2018, 31(4): 98-99, 102.
- [12] 王征, 张赫林, 李冬艳. 特征压缩激活作用下 U-Net 网络的煤尘颗粒特征提取[J]. 煤炭学报, 2021, 46(9): 3056-3065.
WANG Zheng, ZHANG Helin, LI Dongyan. Feature extraction of coal dust particles based on U-Net combined with squeeze and excitation module[J]. Journal of China Coal Society, 2021, 46(9): 3056-3065.
- [13] ZHU Lei, WANG Xinjiang, KE Zhanghan, et al. BiFormer: vision transformer with bi-level routing attention[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, Vancouver, 2023: 10323-10333.
- [14] 梅昕苏. 基于多粒度 Top-k 查询的流式数据事件获取方法研究[D]. 沈阳: 辽宁大学, 2019.
MEI Xinsu. Research on streaming data event acquisition method based on multi-granular Top-k

- query[D]. Shenyang: Liaoning University, 2019.
- [15] LIU Huajie, XU Ke. Recognition of gangues from color images using convolutional neural networks with attention mechanism[J]. *Measurement*, 2023, 206: 1-13.
- [16] 伊建峰, 黎思成, 吕珊, 等. 基于频域数据增强及YOLOv7的动火作业检测模型[J]. *计算机应用*, 2023, 43(增刊2): 285-290.
- YI Jianfeng, LI Sicheng, LYU Shan, et al. Hot work detection model based on frequency domain data enhancement and YOLOv7[J]. *Journal of Computer Applications*, 2023, 43(S2): 285-290.
- [17] ZHOU Buzhuang, YANG Shengqiang, JIANG Xiaoyuan, et al. Experimental study on oxygen adsorption capacity and oxidation characteristics of coal samples with different particle sizes[J]. *Fuel*, 2023, 331. DOI: [10.1016/J.FUEL.2022.125954](https://doi.org/10.1016/J.FUEL.2022.125954).
- [18] MIYAKAWA T, TAKETANI F, TOBO Y, et al. Measurements of aerosol particle size distributions and INPs over the Southern Ocean in the late austral summer of 2017 on board the R/V Mirai: importance of the marine boundary layer structure[J]. *Earth and Space Science*, 2023, 10(3). DOI: [10.1029/2022EA002736](https://doi.org/10.1029/2022EA002736).
- [19] TANG Songlei, LIU Qiang, TANG Hong, et al. Study on the movement of pulverized coal particles in fractal fracture network[J]. *ACS Omega*, 2023. DOI: [10.1021/acsomega.3c02902](https://doi.org/10.1021/acsomega.3c02902).
- [20] REN Sucheng, ZHOU Daquan, HE Shengfeng, et al. Shunted self-attention via multi-scale token aggregation[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, New Orleans, 2022: 10853-10862.
- [21] LIU Jingjing, LIU Ruihang, ZHANG Haoxiang, et al. Fast image processing method for coal particle cluster box dimension measurement and its application in diffusion coefficient testing[J]. *Fuel*, 2023, 352. DOI: [10.1016/J.FUEL.2023.129050](https://doi.org/10.1016/J.FUEL.2023.129050).
- [22] RUSSELL B, TORRALBA A, MURPHY K P, et al. LabelMe: a database and web-based tool for image annotation[J]. *International Journal of Computer Vision*, 2008, 77(1/2/3): 157-173.
- [23] LIU Shu, QI Lu, QIN Haifang, et al. Path aggregation network for instance segmentation[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 2018: 8759-8768.
- [24] ZHU Xiliang, CHENG Zhaoyun, WANG Sheng, et al. Coronary angiography image segmentation based on PSPNet[J]. *Computer Methods and Programs in Biomedicine*, 2021. DOI: [10.1016/J.CMPB.2020.105897](https://doi.org/10.1016/J.CMPB.2020.105897).
- [25] DU Getao, GAO Xu, LIANG Jimin, et al. Medical image segmentation based on U-net: a review[J]. *Journal of Imaging Science and Technology*, 2020, 64(2). DOI: [10.2352/J.ImagingSci.Technol.2020.64.2.020508](https://doi.org/10.2352/J.ImagingSci.Technol.2020.64.2.020508).
- [26] CAI Junxiong, MU Taijiang, LAI Yukun, et al. LinkNet: 2D-3D linked multi-modal network for online semantic segmentation of RGB-D videos[J]. *Computers & Graphics*, 2021, 98: 37-47.
- [27] QIN Jiayin, SUN Yibo, WU Luji. Research on gear surface damage identification based on the ResNet Network[C]. *The 2nd International Conference on Mechanical Automation and Electronic Information Engineering*, Guizhou, 2023. DOI: [10.1088/1742-6596/2419/1/012090](https://doi.org/10.1088/1742-6596/2419/1/012090).