

煤矿机电与智能化

基于改进 U-Net 的煤矸图像分割模型与放煤控制技术

袁 永¹, 秦正寒¹, 夏永琪^{1,2}, 武 让¹, 李立宝¹, 李 勇¹

(1. 中国矿业大学 矿业工程学院, 江苏 徐州 221116; 2. 中煤天津设计工程有限责任公司, 天津 300120)

摘要: 煤矸识别技术是综放工作面实现智能化的关键技术之一, 同时也是该领域面临的一个重要挑战。针对目前煤矸图像数据集整体质量差、数据规模小、煤矸图像分割模型检测速度慢、识别精度低等问题, 参考实际综放工作面搭建了大尺寸等比例综放开采相似模拟平台, 基于该平台建立了煤矸图像采集系统, 采集构建了高清仿真综放工作面煤矸图像数据集, 提出一种基于特征金字塔网络(FPN)和空洞空间金字塔池化(ASPP)的改进U-Net煤矸分割模型, 提高了煤矸图像的分割精度。通过在U-Net模型的跳跃连接中添加FPN模块, 同时在解码器部分引入ASPP模块, 建立了FPN-ASPP-U-Net煤矸分割模型, 消融试验验证了FPN模块和ASPP模块对U-Net模型性能的提升。结果表明: FPN-ASPP-U-Net模型分割效果最好, 均准确率(M_A)为97.29%, 均F1得分(M_{F1})为97.44%, 均交并比(M_I)为95.65%, 模型参数量(M_p)为29.64 M, 浮点运算量(F)为341.29 G, 每秒帧数(f)为41.1 f/s, 与U-Net模型相比, M_I 、 M_{F1} 和 M_A 分别提升了2.64%、1.06%和1.15%, 模型参数量仅仅增加了0.33 M, 改进后的模型在图像分割速度上有少量提升。设计了FPN-ASPP-U-Net模型与PSPNet、SegFormer、DeepLabV3+、PSANet语义分割模型的图像分割效果对比试验, 结果表明: FPN-ASPP-U-Net模型对煤矸图像分割的性能最好, 同时模型整体计算参数量最小, 在分割精度和分割速度之间有着较好的平衡。对于粉尘影响下的不清晰图像, 采用暗通道与高斯加权相结合的方法对图像数据集进行去雾增强, 轻度粉尘、中度粉尘、重度粉尘去雾前后的模型对煤的分割精度提高了14.81%、17.79%、23.62%, 对矸的分割精度提高了11.73%、14.50%、14.86%。基于研究结论提出了FPN-ASPP-U-Net模型的煤矸图像混矸率计算方法, 开展了煤矸图像分割控制放煤试验, 以混矸率20%作为放煤口关闭的阈值, 单次放煤口开关期间真实混矸率与模型预测混矸率平均误差率为4.71%, 验证了基于煤矸图像混矸率对放煤控制的可行性。最后, 封装模型代码研发了煤矸图像智能识别软件, 设计了煤矸分割现场应用方案, 在榆树田煤矿110501综放工作面进行了图像控制放煤试验, 验证了该方法能够对煤矸图像进行精准分割, 对放煤口开关进行合理控制, 提高了综放工作面的智能化水平, 为推动煤矿进一步智能化建设提供了有效的技术手段与参考价值。

关键词: 放顶煤; 煤矸识别; 图像分割; 混矸率; U-Net模型

中图分类号: TD823 **文献标志码:** A **文章编号:** 0253-9993(2025)05-2722-17

Coal gangue image recognition model based on improved U-Net and top coal caving control

YUAN Yong¹, QIN Zhenghan¹, XIA Yongqi^{1,2}, WU Rang¹, LI Libao¹, LI Yong¹

收稿日期: 2024-05-27 策划编辑: 郭晓炜 责任编辑: 陈思成 DOI: 10.13225/j.cnki.jecs.2024.0588

基金项目: 国家自然科学基金资助项目(51974294); 江苏高校“青蓝工程”资助项目(苏教师函[2022]29号)

作者简介: 袁 永(1983—), 男, 河南泌阳人, 教授, 博士生导师, 博士。E-mail: yy20062006@163.com

通讯作者: 夏永琪(1999—), 男, 山东德州人, 硕士。E-mail: xia15621220206@163.com

引用格式: 袁永, 秦正寒, 夏永琪, 等. 基于改进U-Net的煤矸图像分割模型与放煤控制技术[J]. 煤炭学报, 2025, 50(5): 2722–2738.

YUAN Yong, QIN Zhenghan, XIA Yongqi, et al. Coal gangue image recognition model based on improved U-Net and top coal caving control[J]. Journal of China Coal Society, 2025, 50(5): 2722–2738.



移动阅读

(1. School of Mines, China University of Mining & Technology, Xuzhou 221116, China; 2. China Coal Tianjin Design Engineering Co., Ltd., Tianjin 300120, China)

Abstract: Coal gangue identification technology is a critical component for the automation of fully mechanized mining faces and represents a significant challenge within this domain. To address the challenges of suboptimal quality and limited scale of existing coal gangue image datasets, as well as the slow detection speeds and low recognition accuracy of coal gangue image segmentation models, a large-scale, proportionally accurate simulation platform for fully mechanized mining faces has been established, drawing from real-world mining scenarios. Utilizing this platform, a coal gangue image acquisition system has been developed to construct a high-resolution, simulated dataset of coal gangue images for fully mechanized top coal caving face. An advanced U-Net-based coal gangue segmentation model has been developed, incorporating Feature Pyramid Networks (FPN) and Atrous Spatial Pyramid Pooling (ASPP). This approach significantly improves the segmentation accuracy of coal gangue images. By incorporating the Feature Pyramid Networks (FPN) module into the skip connections of the U-Net architecture and integrating the Atrous Spatial Pyramid Pooling (ASPP) module within the decoder stage, a novel FPN-ASPP-U-Net coal gangue segmentation model has been developed. Ablation studies confirmed that the integration of the FPN and ASPP modules significantly enhances the performance of the U-Net model. The FPN-ASPP-U-Net model exhibits superior segmentation efficacy, achieving a mean accuracy (M_A) of 97.29%, a mean F1-score (M_{F1}) of 97.44%, and a mean Intersection over Union (M_I) of 95.65%. The model's parameter count is 29.64 M, with FLOPs (F) 341.29 G and a frame rate (f) of 41.1 frames per second. Relative to the baseline U-Net model, the M_I , M_{F1} , and M_A are improved by 2.64%, 1.06%, and 1.15%, respectively, with only a marginal increase of 0.33 M. This enhancement results in a modest improvement in image segmentation speed. A rigorous comparative analysis was conducted to evaluate the performance of the FPN-ASPP-U-Net model relative to PSPNet, SegFormer, DeepLabV3+, and PSANet for image segmentation tasks. The results substantiate that the FPN-ASPP-U-Net model delivers superior performance in coal gangue image segmentation, while also maintaining the lowest overall computational parameter count. This model demonstrates a well-balanced compromise between segmentation accuracy and computational efficiency, thereby optimizing both precision and processing speed in practical scenarios. In response to image degradation caused by dust, a hybrid dehazing approach leveraging dark channel prior combined with Gaussian weighting was implemented on the image dataset. This methodology significantly enhanced segmentation accuracy. Specifically, for coal, the segmentation accuracy improved by 14.81%, 17.79%, and 23.62% under light, moderate, and severe dust conditions, respectively. For gangue, segmentation accuracy saw improvements of 11.73%, 14.50%, and 14.86% under the same dust conditions. These enhancements demonstrate the effectiveness of the proposed dehazing strategy in mitigating dust-related artifacts and improving segmentation performance across varying levels of dust intensity. Building on the research conclusions, a method for calculating the gangue mixture rate in coal gangue images utilizing the FPN-ASPP-U-Net model was developed. A control experiment for the drawing opening was performed, with a threshold of 20% gangue mixture rate established for closing the drawing opening. During a single operational cycle of the drawing opening, the average discrepancy between the actual and model-predicted gangue mixture rates was 4.71%, thereby confirming the viability of employing gangue mixture rate measurements from coal gangue images for effective discharge control. Finally, the encapsulated model code facilitated the development of an intelligent software solution for coal gangue image recognition. An application framework for gangue segmentation in operational environments was designed, and an image-based discharge control experiment was conducted at the 110501 fully mechanized mining face of the Yushutian coal mine. The validation of this methodology demonstrated its capability to perform accurate segmentation of coal gangue images and to facilitate rational control of the drawing opening. This advancement has significantly enhanced the automation level of the fully mechanized mining face, providing a robust technical framework and valuable reference for advancing the intelligent development of coal mining operations.

Key words: top coal caving; coal-gangue recognition; image segmentation; gangue rate; U-Net model

0 引言

我国长期以来一直是煤炭资源的重要消费国^[1], 2000年—2020年, 我国一次能源消耗中煤炭消耗占比0.57%~69%, 自从“碳达峰、碳中和”倡议提出以来, 煤炭的消费量逐年下降, 但仍然保持在50%以上, 在相当长的时间里, 煤炭一直是我国最为重要的能源资源^[2-4]。煤炭智能开采是煤炭行业实现高质量发展的必然选择, 而综放工作面的智能化程度相对滞后于综采工作面^[5-6]。

目前, 综放工作面普遍采用人工控制放煤口开关进行放煤的方式, 推进综放工作面智能化, 实现放煤口自动控制的关键在于对放煤口的后部刮板输送机上的煤矸混流进行智能区分识别—煤矸识别^[7-8]。研究图像识别技术并将其应用于放顶煤工作面的煤矸识别具有重要意义, 该技术的应用可以提升我国厚煤层智能开采的科技水平与效益, 提高放煤效率并降低误操作风险, 实现智能放煤并推动煤炭行业智能化发展^[9-11]。

近年来, 国内外学者在煤矸识别方面取得了较多的研究进展。孙继平等^[12]提出了一种基于CLBP和支持向量的煤矸识别方法, 包括特征提取、字典学习和类别判定。试验证明该方法具有较高的正确率和存储效率; 伍云霞等^[13]提出基于字典学习算法的煤矸图像特征提取方法, 可使识别率达到96.15%; 田慧卿等^[14]以灰度值和纹理作为表征煤矸的特征向量进行煤矸识别, 多特征的准确率大于单特征的煤矸识别率。借助于深度学习图像识别技术强大的学习能力, 逐渐被引入煤矸识别领域^[15-17]。曹现刚等^[18]提出了一种基于卷积神经网络的煤矸识别定位系统, 利用改进的神经网络进行图像识别和定位, 满足了煤矿分选的要求; 郭永存等^[19]则通过结合迁移学习和结构优化, 得出基于TW-RN优化CNN的煤矸识别模型, 显著提高了模型性能; LI等^[20]对YOLOv3算法进行了改进, 显著提高了对小目标煤矸的检测精度; ALFARZAE-AI等^[21]构建了CGR-CNN煤矸石识别模型, 并通过应用增强原理对数据集进行扩容来训练模型, 最终实现了高达98.75%的总体预测准确率; 徐志强等^[22]构建了一个轻量化的煤矸图像识别模型(ResNet结合SqueezeNet), 根据各模型在训练过程中的收敛情况, 成功实现了模型的压缩, 提高了效率。张释如等^[23]在YOLOv5模型的空间金字塔池化模块添加空洞卷积, 增大输出感受野, 最终模型精度提升了2.27%。何凯等^[24]针对井下煤矸聚集问题, 在YOLOv5s模型中引入CA注意力机制和EIoU损失函数, 最终检测精度

提高至94.8%; 崔斌等^[25]在YOLOv4模型中引入Focal函数与空洞卷积的金字塔结构, 并将卷积模块为CSP模块, 检测精度提升至98.14%。

深度学习图像识别技术的迅速发展使得基于图像的煤矸识别技术成为了可能, 笔者将该技术引入到综放工作面煤矸识别中, 实现对综放工作面煤矸图像的分割, 进而获得综放工作面混矸率数据, 指导放煤口的自动控制, 推动综放工作面智能化发展。

1 煤矸图像数据集构建

1.1 放顶煤模拟试验平台

深度学习图像识别技术迅速发展, 已广泛渗透于各个行业、各个领域。为基于图像的煤矸识别技术提供了技术保障, 图像数据集的质量决定了图像识别模型的准确性和泛化能力。将深度学习图像识别技术引入到综放工作面放煤口煤矸识别中, 首要任务是构建一个高质量且大规模的煤矸图像数据集作为研究基础。

然而, 对于复杂的煤矿生产环境, 构建煤矸图像数据集也是最困难的, 这也使得图像识别的前沿性理论难以适用于煤矿工程实践。本文用自主研制的放顶煤模拟试验平台, 开展了模拟放煤试验, 并搭建了相应的煤矸图像采集系统收集煤矸图像, 建立煤矸图像数据集, 模拟试验平台如图1所示。

该平台可实现等比例缩放模拟综合机械化放顶煤工作面。该平台主体由上料框、下料框、下部主承力框、模拟支架、后刮板输送机、移架油缸、回收料箱等几个部件组成。料框部分采用透明材料, 便于观察和拍摄。下部主承力框设计成透明, 便于观察, 下半部设有金属随动挡板, 可以跟随刮板输送机移动, 防止物料放落过程中溢出。支架尾梁通过液压油缸调节放落角度, 插板通过油缸可以打开或关闭。刮板输送机由电动驱动, 通过滚筒、链轮带动传动链条工作, 可将放落的物料带出。

平台的尺寸为3.3 m×2.2 m×0.9 m(长×高×宽), 主要组成部分包括煤矸物料框架、放顶煤液压支架(ZFY12000/23/34型号支架相似比1:6)、后部刮板输送机、图像采集装置(高速摄像机)、电液控系统等。移架油缸拉力设计为2 t, 采用PLC控制, 每启动1次, 支架移动1个步距。支架上表面用聚四氟材料粘贴进行降低摩擦力处理。支架操作全程由电液控制, 可按设定步骤进行试验, 也可人工操作系统进行试验。

放煤口的开闭状态可通过放煤支架伸缩插板进行模拟。该平台搭建了3台放顶煤液压支架, 共设有3个放煤口, 可最大程度上还原实际放煤情况, 采一放

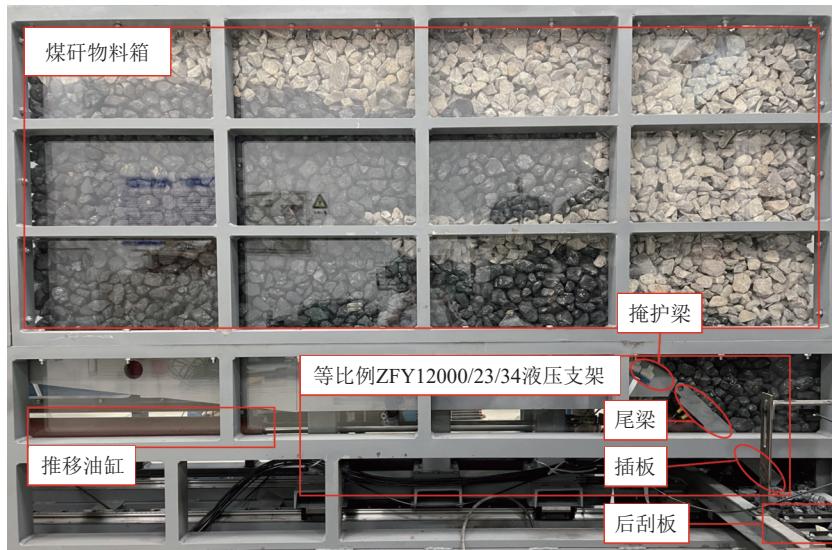


图 1 大尺寸等比例放顶煤模拟实验平台

Fig.1 Large-size iso-scale simulation experimental platform of top coal caving mining

一, 煤矸颗粒随推进逐步下落。平台最大推进步距为 8 个推进步距, 整个放煤流程如图 2 所示。

该试验平台液压支架尾梁可绕掩护梁进行转动, 插板可自由伸缩。放煤开始后, 煤矸流经过放煤口落入后刮板, 在放煤口和刮板输送机上方布置高速摄像

机捕捉不同时刻煤矸放出图片, 煤矸图像采集系统如图 3 所示。

煤矸图像采集系统包括 2 个视角, 其位置设计考虑了后续在煤矿现场的指导需求。A 视角位于放煤支架后部刮板输送机上方, 用于捕捉刮板输送机排出

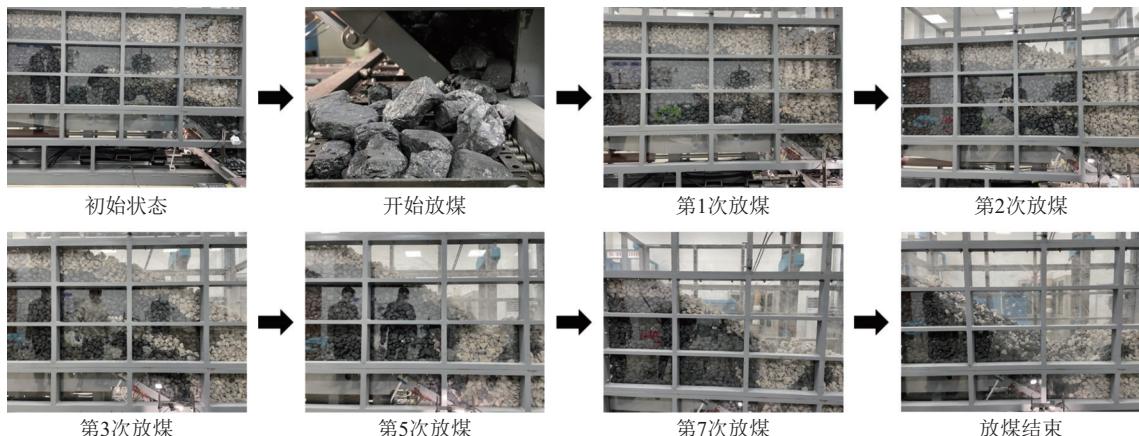


图 2 放顶煤开采模拟试验流程

Fig.2 Simulation experiment process of top coal caving mining

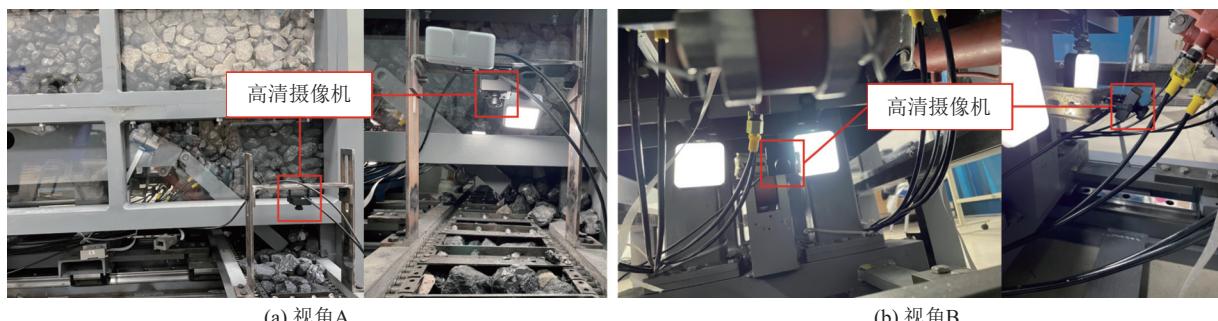


图 3 煤矸图像采集系统

Fig.3 Coal and gangue image acquisition system

的煤矸图像;B 视角位于中间放煤支架立柱梁上,用于捕捉3个放煤口处的煤矸图像。每个视角都配备了1个高速摄像机和2个灯源。摄像头选用USB工业级相机,可通过USB直接连接电脑进行图像采集,最高帧率可达480帧/s,能够监测和识别高速运动物体。为了克服光照对高速摄像机的影响,确保获取的煤矸图像质量,综合考虑应用情况,选择了ULANZI VL49白光光源。

1.2 煤矸图像数据集构建

运用上述搭建的放顶煤模拟平台进行煤矸图像数据集构建,通过煤矸图像采集系统共采集到约15 000张煤矸图像,并对原始图像样本进行预处理操作(筛选有效图像、统一图像尺寸),经该过程之后共获得了约9 000张煤矸图像。

按照PASCAL VOC(Visual Object Classes)数据集的格式制作煤矸图像数据集,使用CVAT图像标注软件,对煤矸图像进行人工标注,标注方法为沿着煤矸颗粒的轮廓进行人工点“点”,最终的轮廓为多个“点”构成的不规则多边形,操作示意如图4a所示,将CVAT标注的文件转化为PASCAL VOC数据集格式,其中可视化分割标签如图4b所示。

最终得到的煤矸图像数据集包含9 436个样本。

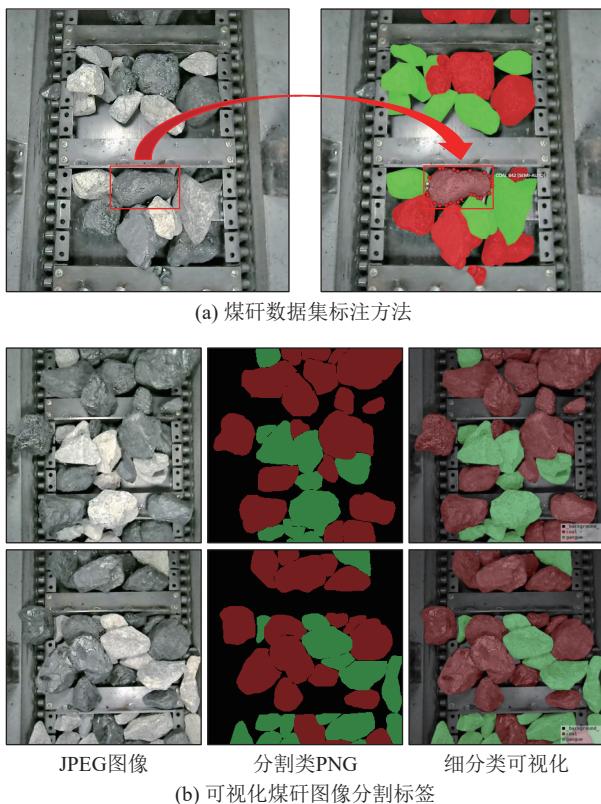


图4 煤矸图像标注分割示意

Fig.4 Schematic diagram of annotated segmentation of coal gangue image

按照 $6:2:2$ 的比例,将数据集划分为训练集、验证集和测试集。

2 煤矸图像分割模型

2.1 U-Net 模型

图像分割是根据图像中的语义信息将图像划分成多个语义上有意义的区域,实现像素级别的分类。RONNEBERGER等^[26]提出了U-Net模型实现图像分割任务,该模型采用编码器-解码器结构。相比传统网络,它在少量样本下表现更加出色且分割速度更快,被广泛应用于多个领域。

U-Net模型结构如图5所示,由左侧的编码器(Encoding)、中间的跳跃连接(Skip Connection)和右侧的解码器(Decoding)组成。其中,编码器通过4个结构相同的子模块提取出4种不同尺度的特征图,每个子模块包含卷积层、ReLU激活函数和最大池化层;跳跃连接负责将这4个特征图传递到解码器中;解码器与编码器的结构对称,通过集成相应编码层输出的浅层特征图来补充图像的细节特征,并通过上采样逐层恢复特征图的分辨率,生成分割结果。U-Net在通道维度上对不同尺度特征图进行连接,具有更好的特征融合效果,本研究选择U-Net作为后续煤矸图像分割模型中的基础结构。

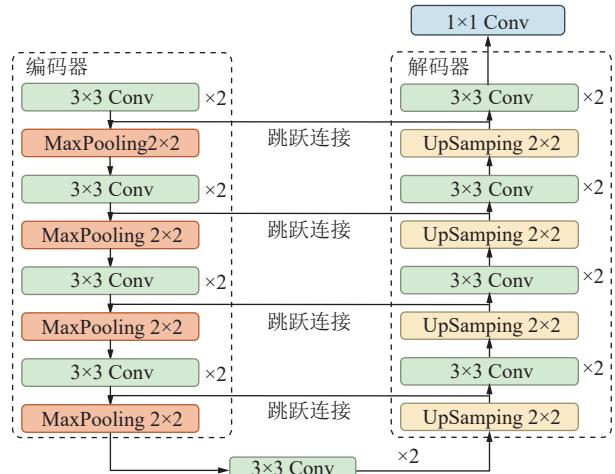


图5 U-Net 模型结构示意

Fig.5 Schematic diagram of U-Net mould structure

2.2 特征金字塔

特征金字塔^[27](Feature Pyramid Network, FPN)是一种用于目标检测和语义分割任务的网络结构,可以从每一种尺度的图像进行特征提取,从多尺度角度上进行特征表示,从而提高模型在多尺度目标检测和语义分割任务中的性能,其结构如图6所示。

FPN整体由自下而上(Bottom-up)和自上而下

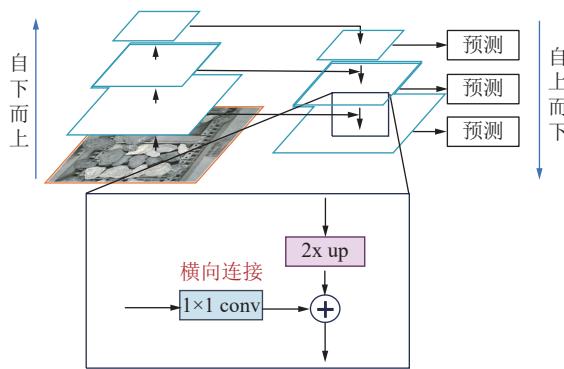


图 6 FPN 结构示意

Fig.6 Schematic diagram of FPN structure

(Top-down)2 部分构成。在网络的不同层次,可以利用不同层次的特征完成不同目标的分割。最终得到不同尺度的特征图,且每一个特征图中都有丰富的语义信息。

2.3 空洞空间金字塔池化

空洞空间金字塔池化^[28](ASPP)最初出现于 DeepLabv2 语义分割模型,利用多个不同采样率的空洞卷积并行采样输入,捕获不同尺度上的图像上下文信息。传统的池化操作会损失位置和密集语义信息,而 ASPP 通过空洞卷积保持图像分辨率,减少参数和计算依赖,实现有效的感受野扩大和上下文信息聚合。

对于输入特征图 y 的每个位置 i 和滤波器 w , 应用空洞卷积为

$$y_i = \sum_{k=1}^K x(i+rk)w(k) \quad (1)$$

式中: k 为卷积核大小, P_x ; r 为采样率。

空洞卷积可以控制滤波器的感受野和输出特征

的紧凑程度,而不增加参数量和计算量,ASPP 结构图如图 7 所示。

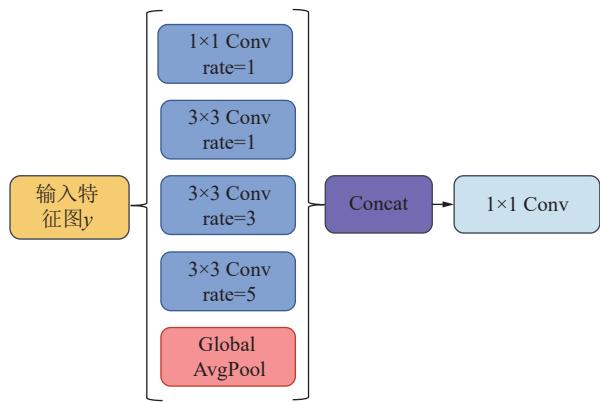


图 7 ASPP 结构示意

Fig.7 Schematic diagram of ASPP structure

2.4 FPN-ASPP-U-Net 图像分割模型

综放工作面放煤口放出的煤研图像具有较强的空间信息,煤研放出的尺寸跨度大并且煤与背景(刮板输送机)较为相似,U-Net 基础模型对这种尺寸跨度大、分割目标与背景相似程度比较高的特征表示较差。

为了解决 U-Net 模型用于煤研图像分割面临的特征表达能力和感知能力较弱的问题,以经典语义分割 U-Net 模型为基础,引入了 FPN 和 ASPP 结构,提出 FPN-ASPP-U-Net 煤研图像语义分割模型,如图 8 所示,该模型进一步提高了 U-Net 模型对不同尺度目标的分割能力,使模型能够更好地适应复杂的场景和目标形态。

本文提出的 FPN-ASPP-U-Net 模型结构和 U-Net 语义分割模型类似,分为编码器部分、跳跃连接和

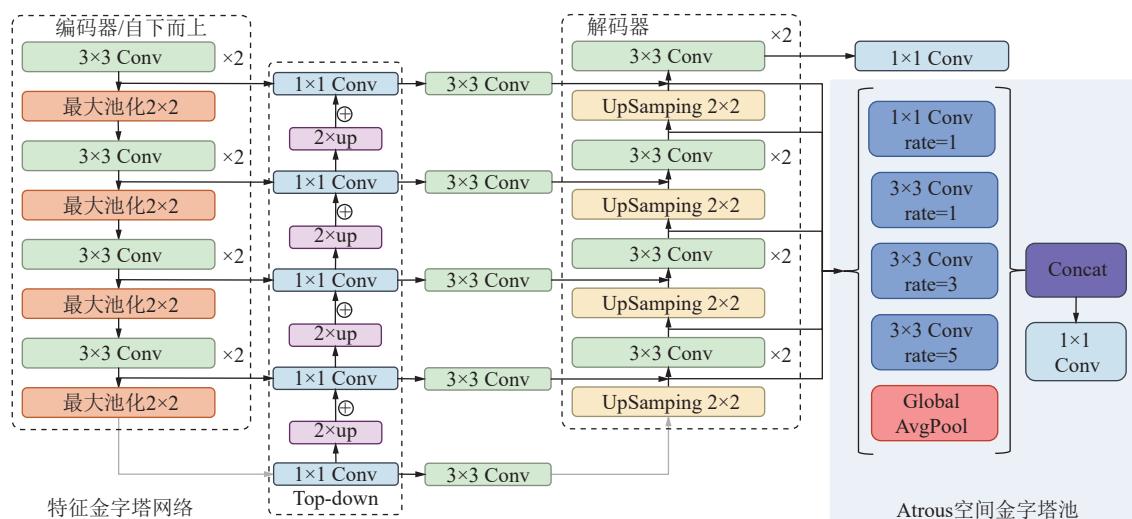


图 8 FPN-ASPP-U-Net 语义分割模型

Fig.8 FPN-ASPP-U-Net semantic segmentation model

解码器 3 个部分。FPN-ASPP-U-Net 模型在 U-Net 的跳跃连接部分(中间特征提取层)构建了 FPN 结构。网络中使用 U-Net 的编码器部分提取图像的特征,这些特征将被用作 FPN 的输入。FPN 自下而上的路径可以利用 U-Net 编码器的特征图,自上而下的路径则用于将高级语义特征向下传播,与低级特征进行融合,使得 U-Net 在不同尺度上都具有丰富的语义信息。通过将 FPN 输出的特征图传递给 U-Net 的解码器部分。

为了更充分利用网络在不同深度上学习到的信息,在解码器部分引入 ASPP 模块,充分利用了网络在不同深度上学习到的信息,提高了分割模型的精度。

2.5 图像分割模型评价指标

煤矸图像分割属于语义分割领域的范畴,其评价指标与图像分类同样是根据混淆矩阵(confusion matrix),该矩阵是大小为(C, C)的方阵,其中 C 为类别数量,可从中得知每个类别的预测情况。以煤矸图像分割为例,根据真实标签与预测结果的不同组合,可将混淆矩阵分为表 1 中的 4 种情况。

表 1 图像分割的混淆矩阵

Table 1 Confusion matrix for image segmentation

实际	预测	
	煤	矸石
煤	T_P	F_N
矸石	F_P	T_N

注: T_P 为被模型预测为正类的正样本; T_N 为被模型预测为负类的负样本; F_P 为被模型预测为正类的负样本; F_N 为被模型预测为负类的正样本。

本文从混淆矩阵中计算出平均准确率(M_A)、F1-Score(M_{F1})、交并比(R_I)、平均交并比(M_I)、Dice 指数(V_{Dice})、平均 Dice 系数(M_{Dice})来作为各模型分割效果的评价指标^[29],具体如下。

1) 平均准确率 M_A , 计算公为

$$M_A = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \quad (2)$$

2) F1-得分 M_{F1} , 计算式为

$$M_{F1} = \frac{2PR}{P+R} \quad (3)$$

$$P = \frac{T_P}{T_P + F_P} \quad (4)$$

$$R = \frac{T_P}{T_P + F_N} \quad (5)$$

3) 交并比 R_I , 计算式为

$$R_I = \frac{|S_{Seg} \cap S_{GT}|}{|S_{Seg} \cup S_{GT}|} = \frac{T_P}{T_P + F_P + F_N} \quad (6)$$

4) 平均交并比 M_I , 计算式为

$$M_I = \frac{\sum_{i=1}^C R_{I_i}}{C+1} \quad (7)$$

5) Dice 指数, 计算式为

$$V_{Dice} = 2 \left| \frac{S_{Seg} \cap S_{GT}}{S_{Seg} + S_{GT}} \right| = \frac{2T_P}{2T_P + F_P + F_N} \quad (8)$$

6) 平均 Dice 指数, 计算式为

$$M_{Dice} = \frac{\sum_{i=1}^C V_{Dice_i}}{C+1} \quad (9)$$

此外,本文还通过模型参数量(Parameters, M_P),浮点运算量(Floating Point Operations, F)和每秒帧数(Frames Per Second, f)来评估煤矸图像分割模型的计算开销。

3 煤矸图像分割试验结果与分析

3.1 试验环境配置及训练参数

本文试验使用 Pycharm 作为编程软件,对应的版本号 2023.1.1; 使用 Pytorch 作为模型训练和验证的框架,对应的版本号为 1.9.0,其封装了很多深度学习方法,可以更加方便搭建网络; 使用 Python 作为编程语言; 使用 NVIDIA GeForce RTX 3070 显卡进行试验,搭建了 CUDA11.1 和 cuDNN 框架,提供高效的计算和数据传输,大幅提高了深度学习算法的训练速度,煤矸图像分割模型训练参数见表 2。

表 2 煤矸图像分割模型训练参数

Table 2 Coal-gangue image segmentation model training parameters

参数	选取结果
损失函数	Cross Entropy Loss
批次大小	4
优化器类型	SGD
学习率	0.01
迭代次数	8 000
网络评价指标	M_{Dice}

由于在解码器部分引入了 ASPP 模块,选择了组合损失函数(Cross Entropy Loss+Dice Loss)。交叉熵损失函数(Cross Entropy Loss)用于解码器最后一层输出的损失计算,其衡量了模型预测的像素与真实标

签之间的差异。其优势在于不受多分类问题中不同类别尺度和占比的影响。而 Dice 被用作 ASPP 输出的损失计算, Dice 是一种衡量预测分割结果与真实分割结果重叠程度的指标, 通常用于图像分割任务中, 特别是在边缘部分的分割。通过结合交叉熵损失和 Dice 损失, 能充分利用其各自的优势, 从而在整体分割效果和边缘部分准确性上都取得提升。其中, 交叉熵损失函数的权重为 1.0, 而 Dice 损失函数的权重为 0.4。

选择优化器类型为随机梯度下降 (Stochastic Gradient Descent, SGD)。其中指定动量 (momentum) 参数为 0.9, 动量是一种在更新过程中添加的项, 可以加速收敛, 并且有助于跳出局部最优解。权重衰减 (weight decay) 参数为 0.0005, 用于防止模型过拟合。

指定了学习率调整的策略为多项式衰减 (Polynomial Decay)。多项式衰减是一种常用的学习率调整策略, 通过多项式函数来动态调整学习率。多项式衰减函数的幂次数为 0.9, 其决定了学习率的衰减速度。学习率的下限为 0.0001, 以避免学习率过小导致训练过程过于缓慢。

3.2 训练策略

1) Dropout 正则化。Dropout 是一种常用的深度学习正则化技术, 其目的在于减少神经网络在训练阶段可能出现的过拟合现象。Dropout 通过在每个训练批次中随机丢弃部分神经元的输出, 从而减少神经元之间的联合适应性, 降低模型对特定特征的依赖程度, 提高模型的泛化性能。本章在训练过程中, 每个神经元以概率 p 被保留, 而以概率 $1-p$ 被丢弃。经测试设置为 0.1, 在测试阶段, 不应用 Dropout, 通过对权重进行缩放来调整模型, 权重会被乘 p , 以保持预期的激活值。

2) 类标签平滑。在深度学习中, 类标签平滑是一种用于改善模型输出的技术。它通过将硬性的 One-

hot 编码标签转换为软性的概率分布, 减少模型的过度自信性, 提高其泛化能力。通常使用交叉熵损失函数, 并逐渐将目标标签的概率从 1 向其他类别平滑过渡, 以减少对训练数据的过度拟合。类标签平滑已在多个领域中取得了成功应用。本章中将平滑参数设为 0.1, 以确保真实标签的概率从 1.0 减少到 0.9。

3.3 试验结果

1) 模型消融试验量化结果对比。为验证本文提出模型的有效性, 进行消融对比实验。在表 3 中, U-Net 为 U-Net 基础模型; FPN-U-Net 为在 U-Net 基础模型引入 FPN 模块; ASPP-U-Net 为在 U-Net 基础模型添加 ASPP 模块; F-A-U-Net 为在 U-Net 基础模型同时引入 FPN、ASPP 模块; FPN-ASPP-U-Net 在 F-A-U-Net 模型的基础上选择组合损失函数 (Cross Entropy Loss+Dice Loss) 作为网络的损失函数, 其余损失函数皆为 Cross Entropy Loss。

由表 3 可知, FPN-U-Net 在添加了 FPN 模块后, 虽然模型复杂度增加, 但提高了模型煤研图像分割的性能; ASPP-U-Net 说明 ASPP 模块的加入, 能够更好的利用网络在不同深度上学习到的信息, 使语义信息更加丰富; F-A-U-Net 说明同时引入 FPN 与 ASPP 模块可进一步优化网络, 提高模型的分割性能; FPN-ASPP-U-Net 由于添加了 DiceLoss, 提高了网络性能, 说明本文提出的组合损失函数能够较好地增强煤研图像分割模型性能, 使其为训练网络贡献更多的损失, 从而提高煤研图像的分割精度。

试验证明, 提出的 FPN-ASPP-U-Net 模型分割效果最好, M_A 、 M_{F1} 和 M_I 相比于 U-Net 模型分别提升了 2.64%、1.06% 和 1.15%, 模型参数量仅仅增加了 0.33 M。训练过程中的损失函数曲线如图 9 所示, 其结果与表 3 量化分析结果一致, FPN-ASPP-U-Net 模型最终损失值最低, 且最终稳定在 0.09 左右, 相对其他方法分别提高了 0.1、0.05、0.04、0.03。

表 3 消融试验量化结果对比

Table 3 Comparison of quantitative results of ablation experiments

模型	$M_A/\%$	$M_{F1}/\%$	$M_I/\%$	M_p/M	F/G	$f/(f \cdot s^{-1})$
U-Net	96.14	96.38	93.01	29.06	316.52	44.2
FPN-U-Net	96.23	96.31	93.88	29.34	339.96	42.2
ASPP-U-Net	96.11	96.34	93.84	29.07	317.86	43.6
F-A-U-Net	96.99	97.34	94.86	29.39	341.29	41.3
FPN-ASPP-U-Net	97.29	97.44	95.65	29.39	341.29	41.1

注: M_A 、 M_{F1} 、 M_I 、 f 为望大特性; M_p 、 F 为望小特性。

2) 模型消融试验可视结果对比。煤研图像分割模型消融试验可视化结果对比如图 10 所示, 其结果

与模型消融实验量化对比结果一致, FPN-ASPP-U-Net 模型对于煤研图像分割效果最佳, 对图 10a 存

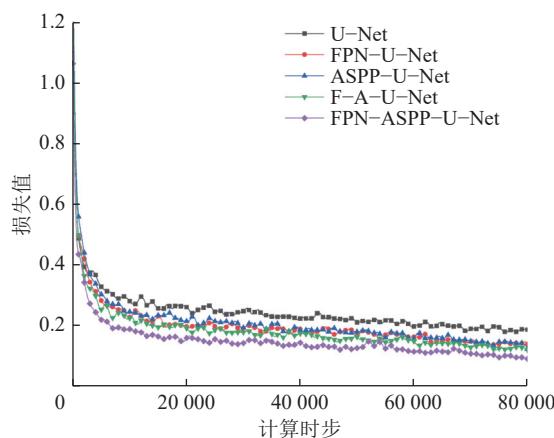


图 9 模型训练损失曲线对比

Fig.9 Comparison of model training loss curves

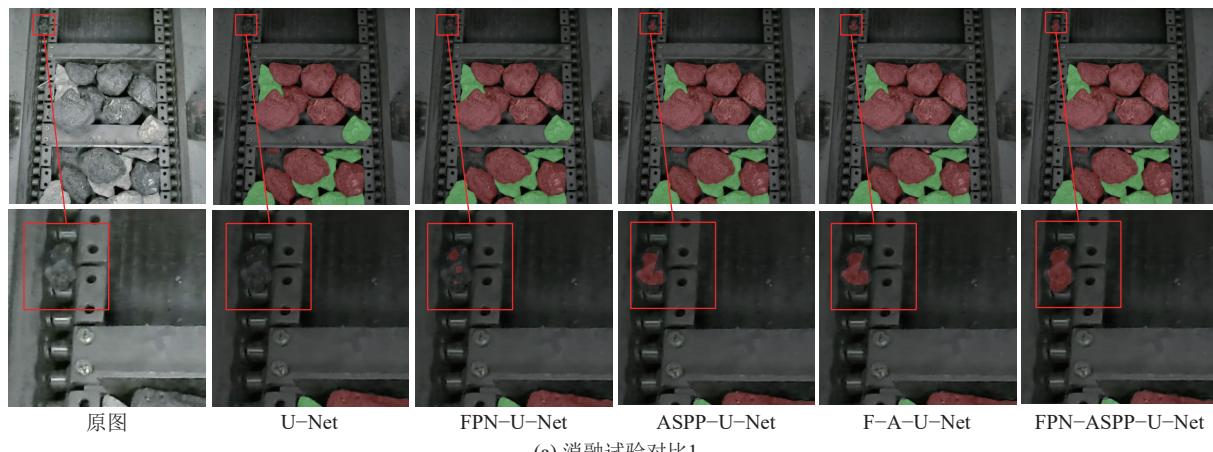
在的小目标煤块，其边缘与周围的刮板输送机具有相似的颜色、纹理，致使其在不同程度上被其他模型错误地分类为背景，而 FPN-ASPP-U-Net 模型则检测出了大部分的小目标煤矸，这得益于 ASPP 能保留充足的语言信息，降低了对小尺寸煤矸的漏预测。图 10b 中，因矸石的大部分区域被煤块覆盖，其部分无法被识别分割，FPN-ASPP-U-Net 模型凭借高表征能力的

多尺度和丰富的语义信息有效地避免了这种误预测。在面对由众多形状、尺寸、纹理煤矸组成的刮板输送机的复杂煤流时，FPN-ASPP-U-Net 模型均展现出了较强的鲁棒性。

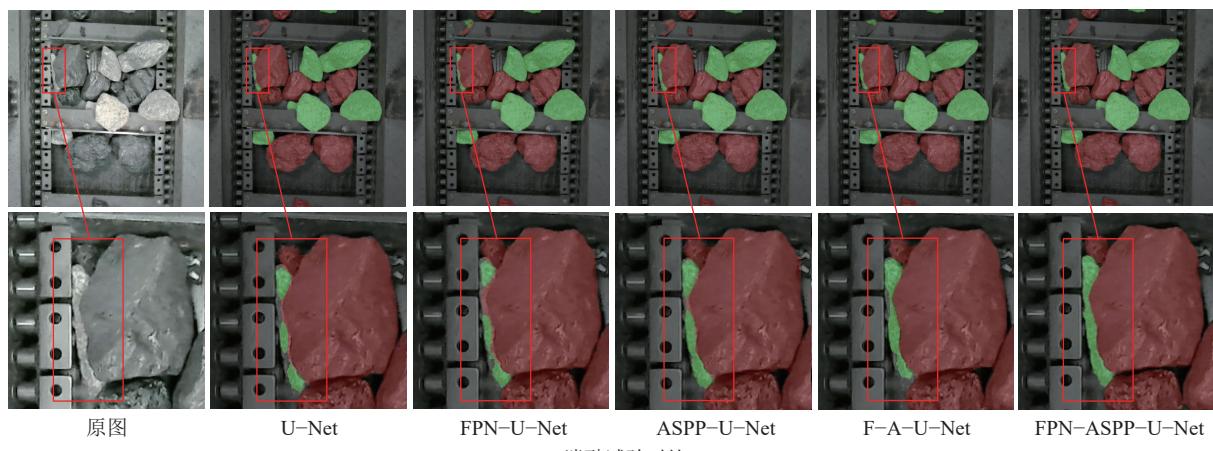
3) 不同模型试验结果对比。为了进一步验证 FPN-ASPP-U-Net 模型的优越性，将本文提出的模型与 PSPNet、SegFormer、DeepLabV3+、PSANet 4 种图像分割模型在相同试验环境、数据集和训练策略下进行对比试验，其他 4 种模型结构均为标准原始模型，参数除表 2 规定的参数外均采用默认参数，量化分析结果见表 4，混淆矩阵如图 11 所示。

笔者所提出的 FPN-ASPP-U-Net 模型的 M_A 、 M_{FI} 和 M_I 3 种指标分别为 97.29%、97.44% 和 95.65%，相比于其他网络中表现最好的 PSANet，3 种指标上分别以 1.23%、1.13% 和 2.78% 较大的优势领先，具有最小的模型参数量，由此也证明了笔者提出的 FPN-ASPP-U-Net 模型相对于 PSPNet、SegFormer、DeepLabV3+ 和 PSANet 模型，对于煤矸图像分割的性能最好。

不同模型进行煤矸图像分割结果如图 12 所示。



(a) 消融试验对比1



(b) 消融试验对比2

图 10 消融试验可视化结果对比

Fig.10 Comparison of ablation experiment visualization results

表 4 不同模型的试验结果对比
Table 4 Comparison of experimental results among different models

模型	$M_A/\%$	$M_{FI}/\%$	$M_I/\%$	M_p/M	F/G	$f(f \cdot s^{-1})$
PSPNet	94.94	95.92	91.12	48.96	278.79	42.9
SegFormer	96.01	96.06	91.42	68.10	421.32	19.3
DeepLabV3+	96.03	96.27	92.81	43.58	275.35	28.2
PSANet	96.06	96.31	92.87	59.13	312.08	47.2
本文方法	97.29	97.44	95.65	29.64	341.29	41.1

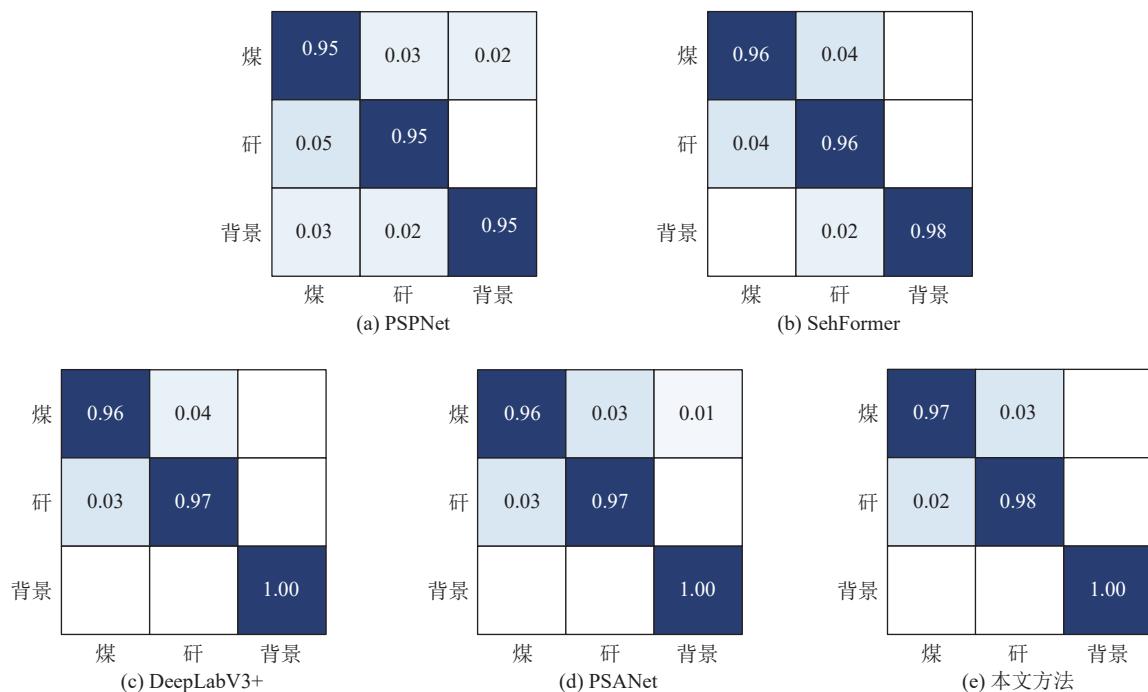


图 11 不同模型混淆矩阵

Fig.11 Confusion matrices of different models

由图可知, FPN-ASPP-U-Net 模型在煤矸图像分割方面具有出色的效果。在图 12a 中, 只有 PSANet 和 FPN-ASPP-U-Net 网络能够完整地将矸石分割出来, 而在图 12b 中, 只有 FPN-ASPP-U-Net 网络的分割效果较为符合实际情况, 其他网络的预测图中存在部分误判。这主要是因为在该区域, 真石的颜色与煤相似, 容易被误判为煤块。相比较其他方法, FPN-ASPP-U-Net 网络在煤矸分割的精度上表现更佳, 具有较低的遗漏率和误检率, 展现出显著的优势。

4 煤矸图像混矸率计算与试验

4.1 高粉尘图像去雾增强

在放顶煤模拟试验过程中, 煤矸颗粒在碰撞破碎过程中会产生粉尘影响采集的图像质量, 结合实际综放工作面的高粉尘环境, 本节重点讨论粉尘对煤矸图像识别效果的影响。

因试验中煤矸碰撞产生的粉尘较少, 无法模拟综

放工作面的高粉尘, 通过人工准备煤粉, 利用风扇制造粉尘, 轻度粉尘利用白色粉末制备, 中度粉尘为白色粉末与黑色粉末混合制备, 重度粉尘为黑色粉末制备, 如图 13 所示, 采集到不同粉尘浓度的煤矸图像, 如图 14 所示。

当粉尘浓度较低时, 如图 14a—图 14c, 粉尘对煤矸识别结果影响较小; 当粉尘浓度较高时, 如图 14d—图 14h, 图像整体模糊, 煤矸边缘轮廓不清晰, 特征不明显, 导致训练得到的模型无法准确地区分煤与矸石, 需要消除粉尘对煤矸图像采集的影响。

笔者针对部分采集的高粉尘图像, 采用双暗通道结合与高斯加权结合的去雾改进的方法^[30]对图像进行增强处理。HE 等^[31]提出了一种基于暗通道的透射率的估计方法, 该方法利用暗通道先验知识可以求出透射率 $t(x)$ 与大气光值 A , 透射率的计算式见式(10)。

$$t(x) = 1 - \omega \min_{y \in \Omega(x)} \left(\min_{c \in \{r, g, b\}} \frac{I^c(y)}{A^c} \right) \quad (10)$$

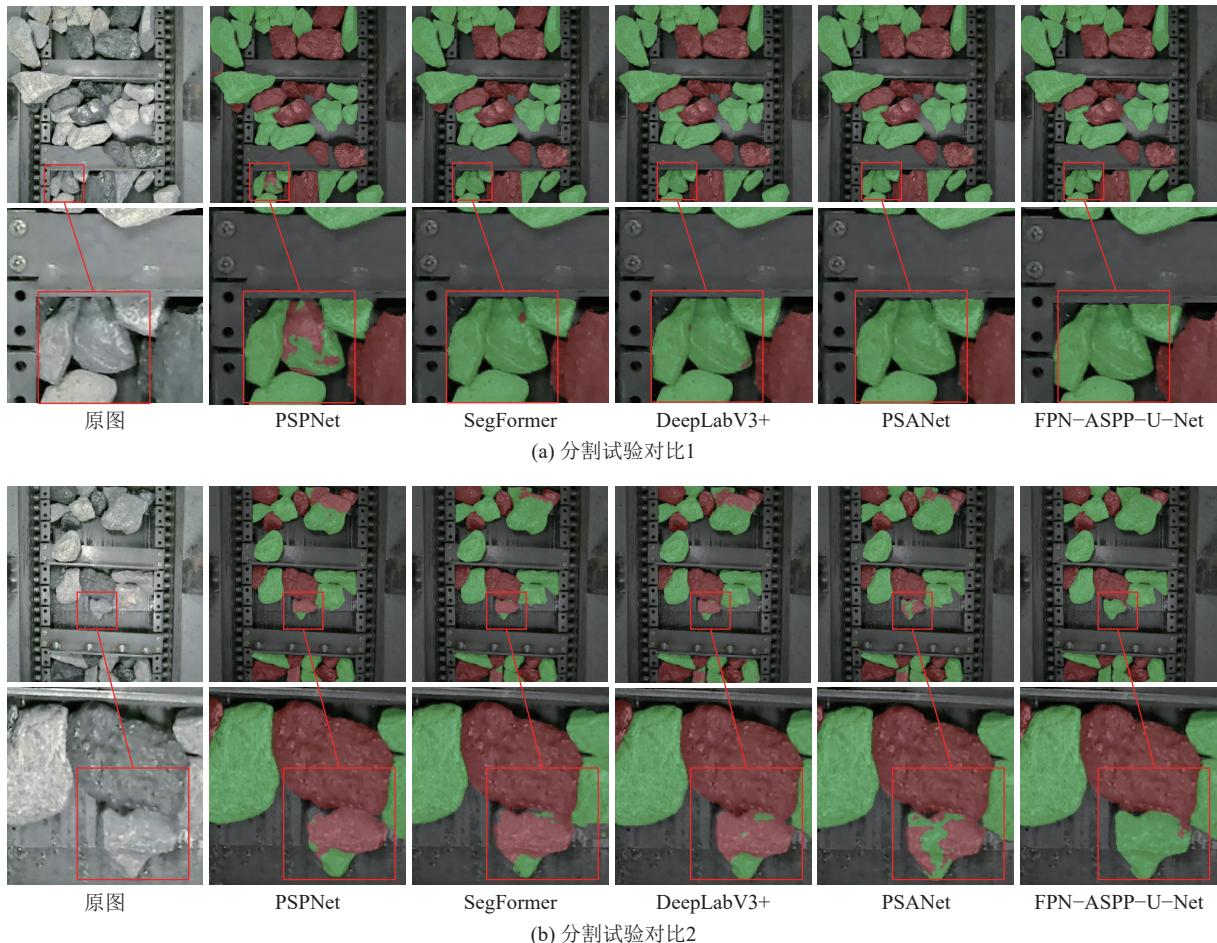


图 12 不同模型可视化结果对比

Fig.12 Comparison of different model visualization results

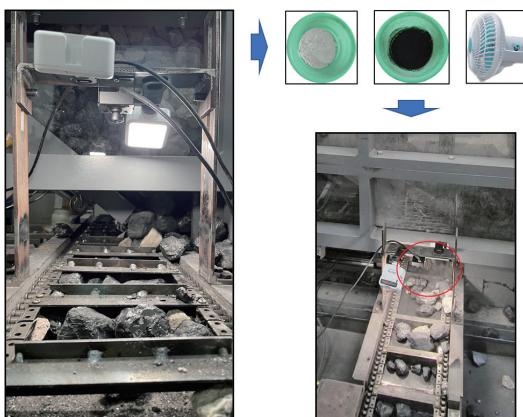


图 13 粉尘模拟制备

Fig.13 Preparation dust simulation

式中: x 为图像每个像素点的坐标; y 为该区域内所有像素的位置; $t(x)$ 为介质透射率,代表在坐标 x 位置处所有光线穿过雾的比例; $I^c(y)$ 为像素 y 处颜色通道 c 的强度值; ω 为引入的雾保留指数,一般取0.95,无量纲; $Q(x)$ 为以坐标 x 为中心的滤波窗口; $\{r, g, b\}$ 表示 r, g, b 图像的3个通道; c 为 r, g, b 中的某个通道; I 为原有雾图像; A 为大气光,一般为无穷远处或雾最浓处。

的值。最后利用大气散射模型恢复无雾图像,计算式为

$$J(x) = \frac{I(x) - A}{\max(t(x), t_0)} + A \quad (11)$$

式中: $J(x)$ 为恢复后无雾图像; t_0 为避免透射率过低而引入的常数,一般取0.1。

但是该方法依赖于暗通道求取的准确性,HE采用最小滤波计算得到的无雾图像具有明显的方块效应,造成图像存在伪影效应,会影响模型对煤矸特征的提取,影响分割精度。

针对上述问题,对暗通道算法进行改进,提出基于双暗通道结合与高斯加权的透射率估计方法,分别使用超像素滤波窗口与中值滤波窗口求取两层暗通道,并对两层暗通道进行像素级结合,结合高斯函数优化暗通道区域,最后利用式(10)计算得出透射率进行计算。

其中超像素滤波与中值滤波计算式为

$$I_1(x) = \min_{y \in \phi(x)} [\min_{c \in \{r,g,b\}} I^c(y)] \quad (12)$$

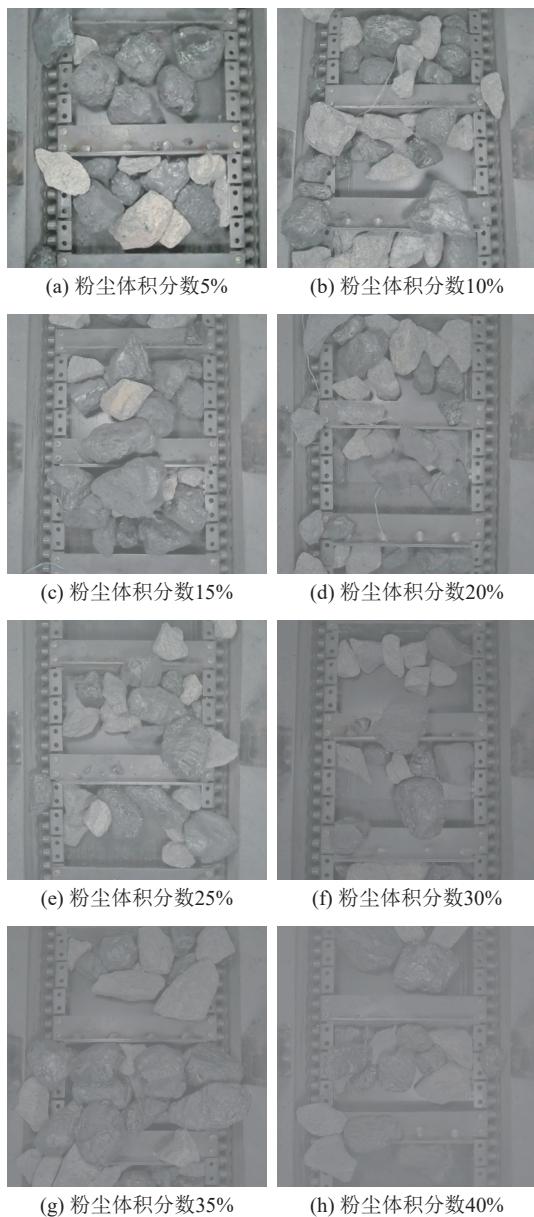


图 14 不同粉尘浓度影响下煤矸图像

Fig.14 Image of coal waste under the influence of different dust concentrations

$$I_2(x) = \max_{y \in \Omega(x)} [\min_{\Omega \in \{r,g,b\}} I^c(y)] \quad (13)$$

式中: $I_1(x)$ 为超像素滤波, $I_2(x)$ 为中值滤波; $\phi(x)$ 为采用超像素算法分割的具有相同景深的块; $\Omega(x)$ 为 15×15 的方形滤波窗口。

两层暗通道融合的计算式为

$$I_S(x) = \beta I_1(x) + (1 - \beta) I_2(x) \quad (14)$$

式中: $I_S(x)$ 为融合后的暗通道图; β 为调节因子, 一般取 0.3。

图像结合后远景的暗通道值会偏小, 导致原图存在残雾, 影响图像整体质量, 故使用高斯加权函数进行优化, 计算式为

$$I_g(x) = \frac{1}{S(x)} [\lambda_1 I_S(x) + G(x) \times I_3(x)] \quad (15)$$

式中: $I_g(x)$ 为高斯优化后的暗通道; $I_3(x)$ 为采用最小值方块滤波的暗通道图; $S(x)$ 为总权值; $G(x)$ 为高斯权重; 其中 $G(x)$ 与 $I_3(x)$ 的计算式为

$$G(x) = \lambda_2 e^{\frac{[1.5 - I_3(x)]^2}{Z}} \quad (16)$$

$$I_3(x) = \min_{y \in \Omega(x)} (\min_{c \in \{r,g,b\}} I^c(y)) \quad (17)$$

式中: $\Omega(x)$ 为 15×15 的方形滤波窗口; λ_2 与 Z 为调整高斯函数形状的参数, λ_2 越大高斯曲线越高, Z 越大高斯曲线越平缓。

由试验分析知: 取 $\lambda_2=2$, $Z=0.6$ 时, 图像细节保留完好, 整体效果最好。最后结合式(10)与式(16)计算得出透射率, 将计算得到的透射率代入式(11)即可得出去雾增强的图像。

放顶煤模拟试验过程中, 随着煤矸的逐步放出, 产生的煤尘浓度不同, 采集图像的模糊程度也有所不同。为研究不同煤尘浓度下的煤矸图像的图像增强效果, 使用图像增强算法对图像进行去雾处理, 选择轻度粉尘、中度粉尘、重度粉尘进行去雾前后的识别对比。用训练好的本文模型对去雾前后的图像进行测试, 识别结果见图 15 与表 5。

表 5 结果表明: 不同煤尘浓度下的去雾后图像识别准确率均高于去雾前图像识别准确率。在粉尘的影响下, 粉尘浓度越大, 模型对煤矸的误识率越高, 在高粉尘影响下煤的识别准确度仅有 63.22%。去雾后轻度、中度、重度粉尘影响下, 煤的识别准确度分别提高了 14.81%、17.79%、23.62%, 砾石的识别准确度分别提高了 11.73%、14.50%、14.86%, 图像去雾速度要显著高于识别速度。试验结果表明在去雾算法能显著提高粉尘影响下煤矸图像识别准确率。

4.2 煤矸像素混研率试验结果

混研率数据是实现放煤口智能控制的核心数据。图像分割可以准确计算综放工作面放煤口的煤矸混流含研率, 为放煤口的智能控制提供重要支持。 R_i 为煤矸图像混研率 (Image Gangue Mixed Rate, Rigm) 指从综放工作面放煤口放出并落在刮板输机上煤流中的研石表面积 (投影面积) 与煤矸表面积的比值^[32], 计算式为

$$R_i = \frac{P_g}{P_c + P_g} \times 100\% \quad (18)$$

式中: P_c 为煤的投影面积, m^2 ; P_g 为研的投影面积, m^2 。

为了最大化顶煤采出率, 获取放煤口的混研率数

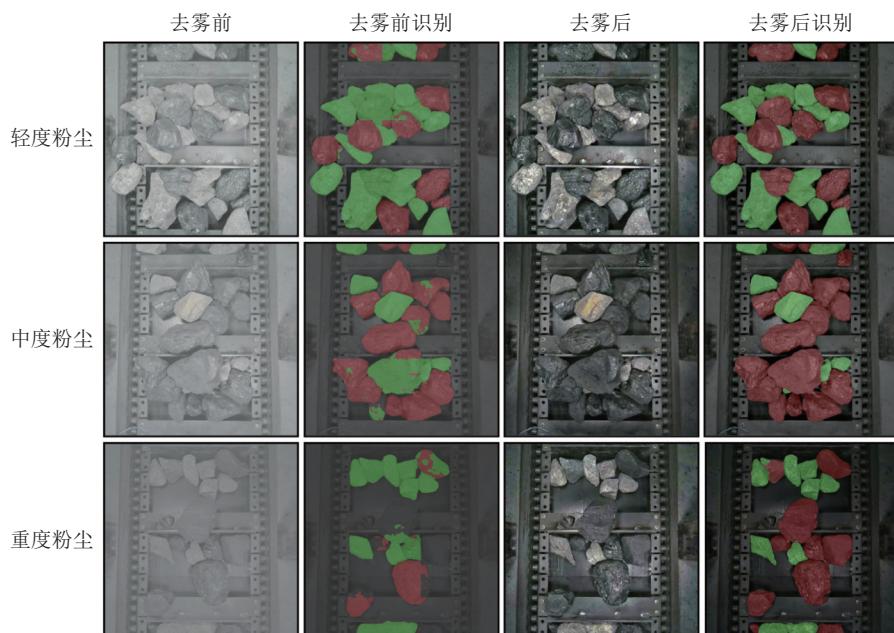


图 15 不同粉尘浓度对煤矸图像识别的影响

Fig.15 Effect of different dust concentrations on the recognition of coal gangue images

表 5 不同粉尘浓度对煤矸图像识别结果对比

Table 5 Comparison of image recognition results of gangue with different dust concentrations

粉尘浓度	原图像识别准确度/%		去雾增强后图像识别准确度/%	
	煤	矸石	煤	矸石
轻度	80.51	84.46	95.32	96.19
中度	74.59	76.54	92.38	91.04
重度	63.22	70.81	86.84	85.67

据,笔者基于 FPN-ASPP-U-Net 模型对煤矸图像的分割结果,实现混矸率的精确计算。

依据放顶煤模拟平台放煤情况计算真实混矸率,

验证依据煤矸图像分割后得出的混矸率。放煤开始后,整个放煤过程如图 16 所示,顶煤放出后共经历了初始放煤、初始见矸、煤矸混流、大量见矸 4 种状态。使用一个完整放煤步距的采出率、混矸率为样本进行后续研究使用。

将训练好的 FPN-ASPP-U-Net 模型移植到放顶煤模拟平台的煤矸图像采集系统中,应用煤矸图像分割模型进行在线分割并输出分割结果,在一次完整放煤中其输出分割结果如图 16 所示。

输出分割结果对其中像素进行计算,以图 16 为例,图中红色像素点为煤块,绿色像素点为矸石,依据式(4)对其进行计算得出像素点的混矸率。该模型平

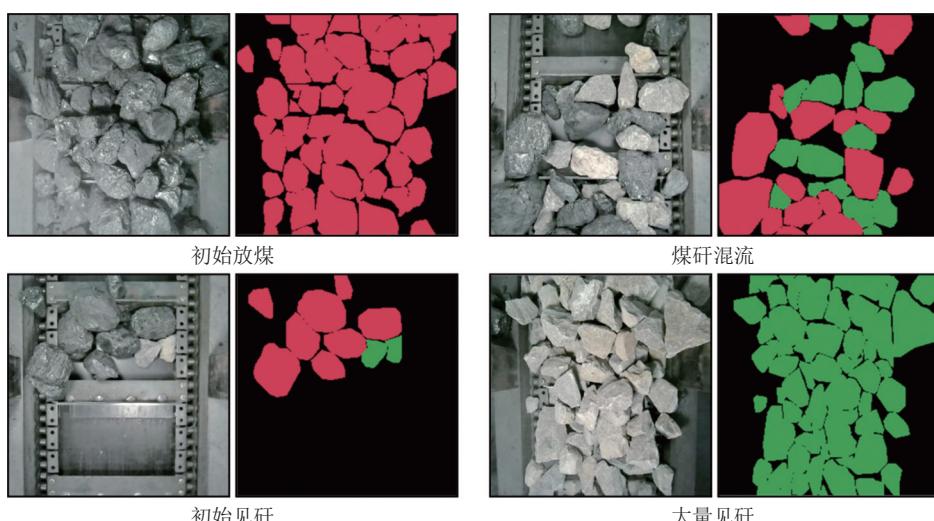


图 16 煤矸图像分割结果

Fig.16 Segmentation results of coal gangue image rate of coal discharge process

均1 s可以处理43张照片,为进一步提高其容错率,通过分析5 s内的混矸率的平均值作为此时的混矸率,为进一步判断本文提出的混矸率计算方法的适用性,进行3次完整的周期放煤的混矸率(真实混矸率与预测混矸率)变化的过程如图17所示,其中真实混矸率计算基础为该阶段获取的煤矸图像进行人工标注后的实际分割标签。

如图17所示,在开始放煤后,混矸率呈现逐渐增

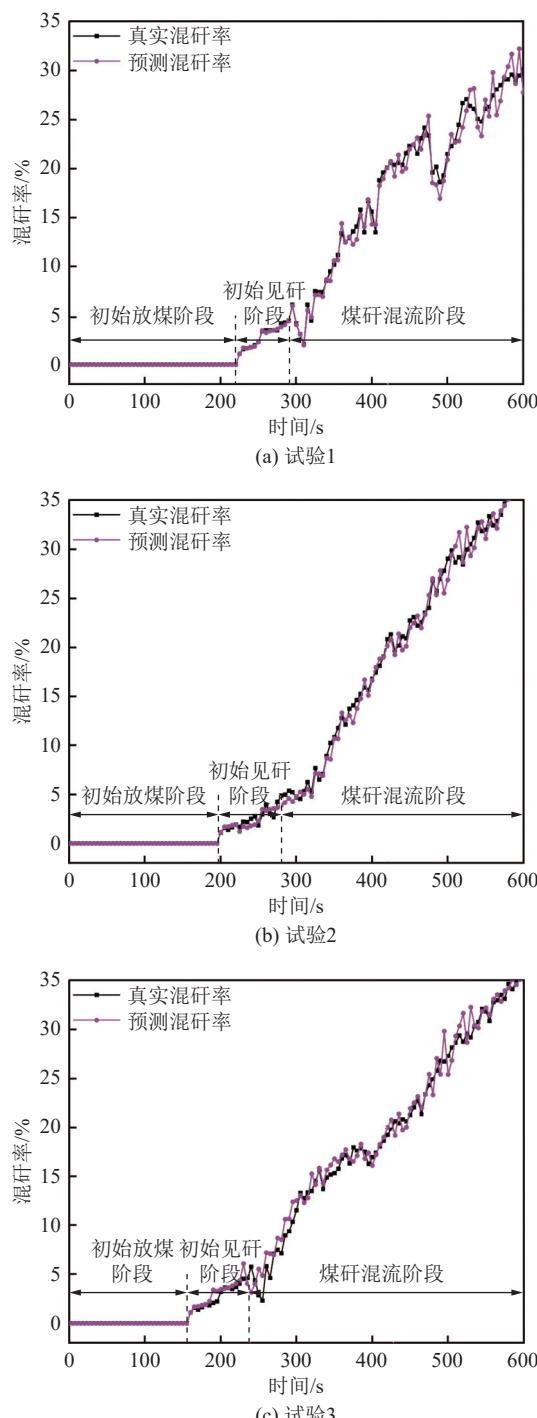


图17 混矸率随时间的变化曲线

Fig.17 Curve of gangue mixing rate with time

加的趋势。具体而言,初始放煤阶段持续时间160~220 s,此时混矸率接近零;随后进入初始见矸阶段,持续时间85~95 s,此阶段混矸率在5%以下;之后进入煤矸混流阶段,混矸率迅速增加,在试验进行至415~425 s,混矸率达到20%。

进一步对比真实混矸率与预测混矸率,3组试验的平均误差率分别为4.81%、4.08%、5.23%,总的平均误差为4.71%。

将混矸率20%设置为放煤口关闭的阈值,则以真实或预测混矸率为判断标准时,放煤口在400~425 s之间关闭,验证了所采用方法能够准确计算混矸率。

4.3 煤矸图像分割现场应用设计

实验室应用过渡到现场应用一直是工程科学领域的难题。本节基于前文研究结果,设计了煤矸图像井下实时分割技术方案。

1) 系统硬件设计。选择Pytorch 1.9.0版本;显卡为NVIDIA GeForce RTX 4060;CUDA版本为11.1、cuDNN框架;图像采集设备选择工业防爆高速相机,图像采集帧率最高可达500帧/s,实际帧率依据软件在井下实际的识别速度进行动态调整;根据矿井混矸率要求设置混矸率阈值,通过通信模块发送停止放煤、关闭放煤口、开启放煤口的控制指令。

2) 图像采集视角位置确定。高速摄像机安装在支架上,具体位置参考实验室安装位置B,为保障整个综放工作面识别的综合识别效果,每个高速摄像机采集3个支架区域内的煤矸图像。

3) 煤矸图像智能识别软件。将本研究的去雾算法与煤矸分割算法封装成集成系统“煤矸图像智能识别软件”并与高速摄像机及支架电液控通信模块连接,考虑到现实应用的实时性与识别过程的连续性,结合软硬件的性能,高速摄像机的采集频率设置为5张/s,由表4可知,软件的图像处理速度为41.1帧/s,且提升了硬件配置,因此可满足井下图像实现快速识别。

软件界面。如图18所示,软件左侧为功能界面



图18 软件界面

Fig.18 Software interface

选择区域;右侧上方红框内为识别显示区域;右侧下方绿框内为功能操作区域。

功能介绍。煤矸图像智能识别软件具备“视频采集”、“图像截取”、“混矸率分析”。视频采集。煤矸图像智能识别软件与高速摄像机连接,软件可直接获取高速摄像机视角下的煤矸图像。图像截取。高速摄像机会按照设定帧率逐帧截取煤矸图像并自动存入软件中的“待读文件夹”,并标记图像的截取时间。混矸率分析。软件自动识别“待读文件夹”中的煤矸图像,计算图像中的煤矸像素占比作为混矸率,当混矸率达到设置的阈值时,软件反馈通信模块停止放煤。

4) 图像识别现场应用。在夏阔坦矿业公司榆树田煤矿 110501 综放工作面进行煤矸图像分割识别,采集的煤矸图像主要为煤矸混流阶段,煤矸图像截取与分割效果如图 19 所示,本文算法实现了煤矸图像



(a) 识别应用1



(b) 识别应用2



(c) 识别应用3

图 19 煤矸图像识别应用效果

Fig.19 Coal gangue image recognition application effect

识别从实验室迁移到现场应用。

5 结 论

1) 基于放顶煤工作面现场,搭建了放顶煤模拟平台并建立了煤矸图像采集系统,参照 PASCAL VOC 数据集的格式构建了共含有 9 436 张图像煤矸混合图像数据集,为煤矸图像分割提供了训练数据。

2) 以 U-Net 图像分割模型为基础,在其跳跃连接部分添加 FPN 模块(增强 U-Net 模型对不同尺度信息的感知能力),解码器部分加入 ASPP 模块(充分利用网络在不同深度上学习到的信息),建立了 FPN-ASPP-U-Net 模型,并通过消融试验和不同模型之间的对比实验,验证了 FPN 和 ASPP 模块对于 U-Net 模型的提升以及 FPN-ASPP-U-Net 模型的优越性,最终对于煤矸图像分割的 M_1 、 M_{F1} 和 M_A 分别为 95.65%、97.44% 和 97.29%,单张煤矸图像处理时间为 0.024 s。

3) 对于粉尘影响下的难识别图片。提出双暗通道结合与高斯加权结合的去雾改进法,研究了不同粉尘浓度对煤矸图像识别准确度的影响,去雾前后在轻度、中度、重度粉尘影响下,煤的识别准确度分别提高了 14.81%、17.79%、23.62%,矸石的识别准确度分别提高了 11.73%、14.50%、14.86%。

4) 以 FPN-ASPP-U-Net 煤矸图像分模型为基础,得出了使用煤、矸石投影面积的煤矸图像混矸率计算方法,在实验室检测了其应用效果,真实混矸率与预测混矸率比对得出平均误差率仅为 4.71%,可准确计算混矸率。将本研究算法封装成集成系统后在夏阔坦矿业公司榆树田煤矿 110501 综放工作面收集的煤矸混流图像进行试验,验证了所采用方法能够精准分割综放面现场的煤矸图像。

参考文献(References):

- [1] 谢和平,吴立新,郑德志. 2025 年中国能源消费及煤炭需求预测[J]. 煤炭学报, 2019, 44(7): 1949–1960.
XIE Heping, WU Lixin, ZHENG Dezhi. Prediction on the energy consumption and coal demand of China in 2025[J]. Journal of China Coal Society, 2019, 44(7): 1949–1960.
- [2] 康红普,李全生,张玉军,等. 我国煤矿绿色开采与生态修复技术发展现状及展望[J]. 绿色矿山, 2023, 1(1): 1–24.
KANG Hongpu, LI Quansheng, ZHANG Yujun, et al. Development status and prospect of greenmining and ecological restoration technology of coal mines in China[J]. Journal of Green Mine, 2023, 1(1): 1–24.
- [3] 王虹. 综采工作面智能化关键技术研究现状与发展方向[J]. 煤炭科学技术, 2014, 42(1): 60–64.
WANG Hong. Development orientation and research state on intelli-

- gent key technology in fully-mechanized coal mining face[J]. *Coal Science and Technology*, 2014, 42(1): 60–64.
- [4] 武强, 刘宏磊, 曾一凡, 等. 我国绿色矿山建设现状与存在问题及对策建议[J]. *绿色矿山*, 2023, 1(1): 25–32.
WU Qiang, LIU Honglei, ZENG Yifan, et al. Situation, challenges, and proposed strategies for green mine construction in China[J]. *Journal of Green Mine*, 2023, 1(1): 25–32.
- [5] 鲍久圣, 张可琨, 王茂森, 等. 矿山数字孪生 MiDT: 模型架构、关键技术及研究展望[J]. *绿色矿山*, 2023, 1(1): 166–177.
BAO Jiusheng, ZHANG Kekun, WANG Maosen, et al. Mine Digital Twin: Model architecture, key technologies and research prospects[J]. *Journal of Green Mine*, 2023, 1(1): 166–177.
- [6] 王国法, 范京道, 徐亚军, 等. 煤炭智能化开采关键技术创新进展与展望[J]. *工矿自动化*, 2018, 44(2): 5–12.
WANG Guofa, FAN Jingdao, XU Yajun, et al. Innovation progress and prospect on key technologies of intelligent coal mining[J]. *Industry and Mine Automation*, 2018, 44(2): 5–12.
- [7] 王国法, 刘峰, 孟祥军, 等. 煤矿智能化(初级阶段)研究与实践[J]. *煤炭科学技术*, 2019, 47(8): 1–36.
WANG Guofa, LIU Feng, MENG Xiangjun, et al. Research and practice on intelligent coal mine construction[J]. *Coal Science and Technology*, 2019, 47(8): 1–36.
- [8] 张宁波, 鲁岩, 刘长友, 等. 综放开采煤研自动识别基础研究[J]. *采矿与安全工程学报*, 2014, 31(4): 532–536.
ZHANG Ningbo, LU Yan, LIU Changyou, et al. Basic study on automatic detection of coal and gangue in the fully mechanized top coal caving mining[J]. *Journal of Mining & Safety Engineering*, 2014, 31(4): 532–536.
- [9] 宋选民, 朱德福, 王仲伦, 等. 我国煤矿综放开采 40 年: 理论与技术装备研究进展[J]. *煤炭科学技术*, 2021, 49(3): 1–29.
SONG Xuanmin, ZHU Defu, WANG Zhonglun, et al. Advances on longwall fully-mechanized top-coal caving mining technology in China during past 40 years: theory, equipment and approach[J]. *Coal Science and Technology*, 2021, 49(3): 1–29.
- [10] 王国法, 徐亚军, 张金虎, 等. 煤矿智能化开采新进展[J]. *煤炭科学技术*, 2021, 49(1): 1–10.
WANG Guofa, XU Yajun, ZHANG Jinhu, et al. New development of intelligent mining in coal mines[J]. *Coal Science and Technology*, 2021, 49(1): 1–10.
- [11] 葛世荣, 张帆, 王世博, 等. 数字孪生智采工作面技术架构研究[J]. *煤炭学报*, 2020, 45(6): 1925–1936.
GE Shirong, ZHNAG Fan, WANG Shibo, et al. Digital twin for smart coal mining workface: Technological frame and construction[J]. *Journal of China Coal Society*, 2020, 45(6): 1925–1936.
- [12] 孙继平, 陈浜. 基于 CLBP 和支持向量诱导字典学习的煤岩识别方法[J]. *煤炭学报*, 2017, 42(12): 3338–3348.
SUN Jiping, CHEN Bang. Coal-rock recognition approach based on CLBP and support vector guided dictionary learning[J]. *Journal of China Coal Society*, 2017, 42(12): 3338–3348.
- [13] 伍云霞, 田一民. 基于字典学习的煤岩图像特征提取与识别方法[J]. *煤炭学报*, 2016, 41(12): 3190–3196.
WU Yunxia, TIAN Yimin. Method of coal-rock image feature extraction and recognition based on dictionary learning[J]. *Journal of China Coal Society*, 2016, 41(12): 3190–3196.
- [14] 田慧卿, 魏忠义. 基于图像识别技术的煤岩识别研究与实现[J]. *西安工程大学学报*, 2012, 26(5): 657–660.
TIAN Huiqing, WEI Zhongyi. The research and implementation of coal and rock identification based on image recognition technology[J]. *Journal of Xi'an Polytechnic University*, 2012, 26(5): 657–660.
- [15] IWASZENKO S, RÓG L. Application of deep learning in petrographic coal images segmentation[J]. *Minerals*, 2021, 11(11): 1265.
- [16] LIU Y, ZHANG Z L, LIU X, et al. Efficient image segmentation based on deep learning for mineral image classification[J]. *Advanced Powder Technology*, 2021, 32(10): 3885–3903.
- [17] LIU C Z, LI M C, ZHANG Y, et al. An enhanced rock mineral recognition method integrating a deep learning model and clustering algorithm[J]. *Minerals*, 2019, 9(9): 516.
- [18] 曹现刚, 刘思颖, 王鹏, 等. 面向煤研分拣机器人的煤研识别定位系统研究[J]. *煤炭科学技术*, 2022, 50(1): 237–246.
CAO Xiangang, LIU Siying, WANG Peng, et al. Research on coal gangue identification and positioning system based on coal-gangue sorting robot[J]. *Coal Science and Technology*, 2022, 50(1): 237–246.
- [19] 郭永存, 王希, 何磊, 等. 基于 TW-RN 优化 CNN 的煤研识别方法研究[J]. *煤炭科学技术*, 2022, 50(1): 228–236.
GUO Yongcun, WANG Xi, HE Lei, et al. Research on coal and gangue recognition method based on TW-RN optimized CNN[J]. *Coal Science and Technology*, 2022, 50(1): 228–236.
- [20] LI D Y, WANG G F, ZHANG Y, et al. Coal gangue detection and recognition algorithm based on deformable convolution YOLOv3[J]. *IET Image Processing*, 2022, 16(1): 134–144.
- [21] ALFARZAEI M S, NIU Q, ZHAO J Q, et al. Coal/gangue recognition using convolutional neural networks and thermal images[J]. *IEEE Access*, 2020, 8: 76780–76789.
- [22] 徐志强, 吕子奇, 王卫东, 等. 煤研智能分选的机器视觉识别方法与优化[J]. *煤炭学报*, 2020, 45(6): 2207–2216.
XU Zhiqiang, LÜ Ziqi, WANG Weidong, et al. Machine vision recognition method and optimization for intelligent separation of coal and gangue[J]. *Journal of China Coal Society*, 2020, 45(6): 2207–2216.
- [23] 张释如, 黄综浏, 张袁浩, 等. 基于改进 YOLOv5 的煤研识别研究[J]. *工矿自动化*, 2022, 48(11): 39–44.
ZHANG Shiru, HUANG Zongliu, ZHANG Yuanhao, et al. Coal and gangue recognition research based on improved YOLOv5[J]. *Journal of Mine Automation*, 2022, 48(11): 39–44.
- [24] 何凯, 程刚, 王希, 等. 基于 CED-YOLOv5s 模型的煤研识别方法研究[J]. *工矿自动化*, 2024, 50(2): 49–56, 82.
HE Kai, CHENG Gang, WANG Xi, et al. Research on coal gangue recognition method based on CED-YOLOv5s model[J]. *Journal of Mine Automation*, 2024, 50(2): 49–56, 82.
- [25] 崔斌, 陈林, 亓玉浩, 等. 基于改进 YOLO v4 的煤研石识别检测技术研究[J]. *煤炭工程*, 2023, 55(12): 161–166.
CUI Bin, CHEN Lin, QI Yuhao, et al. Coal gangue detection technology based on improved YOLO v4[J]. *Coal Engineering*, 2023,

- 55(12): 161–166.
- [26] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]: Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015. Cham: Springer, 2015: 234–241.
- [27] 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). Piscataway, NJ: IEEE, 2017: 936–944.
- [28] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834–848.
- [29] 于营, 王春平, 付强, 等. 语义分割评价指标和评价方法综述[J]. *计算机工程与应用*, 2023, 59(6): 57–69.
- YU Ying, WANG Chunping, FU Qiang, et al. Survey of evaluation metrics and methods for semantic segmentation[J]. *Computer Engineering and Applications*, 2023, 59(6): 57–69.
- [30] 何柯辰, 刘奇, 邓小波, 等. 基于双重暗通道结合与高斯加权的去雾改进算法[J]. 半导体光电, 2021, 42(5): 754–759.
- HE Kechen, LIU Qi, DENG Xiaobo, et al. Improved image dehazing based on combination of double dark channels and Gaussian weighting[J]. *Semiconductor Optoelectronics*, 2021, 42(5): 754–759.
- [31] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[C]/2009 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2009: 1956–1963.
- [32] 王家臣, 潘卫东, 张国英, 等. 图像识别智能放煤技术原理与应用[J]. *煤炭学报*, 2022, 47(1): 87–101.
- WANG Jiachen, PAN Weidong, ZHANG Guoying, et al. Principles and applications of image-based recognition of withdrawn coal and intelligent control of draw opening in longwall top coal caving face[J]. *Journal of China Coal Society*, 2022, 47(1): 87–101.