

引用格式:郭帅. 矿石块度检测系统在溜井装矿环节的应用[J]. 有色设备, 2025, 39(2): 56-61.

GUO Shuai. Application of ore block identification system in ore chute loading[J]. Nonferrous Metallurgical Equipment, 2025, 39(2): 56-61.

矿石块度检测系统在溜井装矿环节的应用

郭 帅

(中国恩菲工程技术有限公司, 北京 100038)

[摘 要] 本文针对有轨运输无人驾驶溜井自动装载环节大块多、易卡斗等工况, 基于器视觉库 OpenCV 和 YOLO (You Only Look Once) 训练模型的应用设计, 构建了一套能够实现矿石块度计算、矿石块度数量及时间分布统计、超大块度实时报警及查询等功能的矿石块度识别系统, 实现了对溜井放矿矿石块度的检测与管理, 确保了有轨运输无人驾驶工况下的放矿作业设备安全, 同时减轻了人工监视劳动强度, 为矿山无人化系统的实施和数字化转型提供借鉴。

[关键词] 块度识别; 图像识别; 井下有轨运输; 智能矿山; 矿石; 金属矿山; 检测

[中图分类号] TD65 **[文献标志码]** A **[文章编号]** 1003-8884(2025)02-0056-06

DOI: 10.19611/j.cnki.cn11-2919/tg.2025.02.007

0 引言

在金属矿山矿石通过有轨运输转运环节中, 溜井转运作为重要环节起着承上启下的作用, 然而, 由于地下金属矿山生产工艺的影响, 溜井内时常会有超大、超长块度的矿石溜下, 在增加溜井堵塞风险的同时, 也会造成给矿装车环节矿石卡斗、洒落、装车高度超高等情况, 轻则需要人工处理, 重则造成直流接触网等设备损坏, 对生产连续性极为不利^[1-3]。

随着人工智能技术、先进传感、高速网络传输等技术的发展和应用, 通过基于高清视频的视觉识别、AI 学习算法等技术在矿石装载过程中自动识别和统计逐渐成熟。国内研究中, 何文轩等^[4]提出了一种基于深度学习的矿石块度检测方法, 针对传送带矿石块度进行识别; 曲伟霞等^[5]设计特征提取网络与特征融合技术, 采用 Faster-RCNN 算法, 实现了上部溜井倒矿阶段的巨石检测、异物检测、车牌识别等功能; 陈立军等^[6]提通过 U-net 分割模型及 OpenCV 图像处理技术, 通过最小外形矩形法确定了爆堆块度尺度信息; 曹士杰等^[7]提出了一种基于改进 YOLOv5 的实例分割网络模型 Rock-YOLOv5,

分别从通道注意力机制与空间注意力机制两方面对原始 YOLO 算法进行改进, 构建出石块图像数据集。上述学者针对不同工艺环节的矿石块度检测, 进行了相关研究。

本文针对有轨运输无人驾驶溜井自动装载环节大块多、易卡斗等问题, 基于现今流行的 AI 深度学习语言 Python, 采用机器视觉库 OpenCV 进行数据流的获取, 并运用主流图像识别技术框架 YOLO 进行模型训练、图像识别, 进行数据比对, 识别大颗粒矿石并提供对外接口。此外, 后台管理页面, 采用成熟的 Web 服务框架 Flask, 配合前端框架 Vue、Element-UI 搭建管理后台操作界面, 实现溜井放矿矿石块度的检测与管理。

1 井下溜井装矿环节工艺概况

国内金属地下矿山一般在有轨运输中段的上部盘区, 采用铲运机将矿石或废石装入溜井, 通过溜井底部振动给矿机装入矿车, 再由电机车牵引矿车通过有轨运输方式下放到矿石仓, 最后由破碎机破碎后提升至地表。

在上述流程中, 由于爆破工艺的差异以及矿石

[收稿日期] 2024-11-16

[项目基金] 五矿集团科创基金项目“有轨运输无人驾驶系统研发”。

[第一作者] 郭帅(1992—), 男, 陕西渭南人, 硕士, 工程师, 主要从事智能矿山相关工作。

物理性质的不同,铲运机运输的矿石块度通常表现出较大的不均匀性。尽管在溜井上方通常安装有格筛以实现矿石的预筛分,但在实际生产中,因格筛破损或无法有效拦截过长矿石,导致溜井中仍可能存在大块矿石。随着智能矿山技术的快速发展,少人化和无人化成为矿山工艺优化的重要趋势,并在矿石流的各个工序中逐步落地实施。有轨运输环节的无人驾驶技术已经在多个矿山应用^[8]。然而,在有轨运输无人化的场景中,自动装载工序对矿石块度的均匀性提出了更高的要求。如果在自动装载过程中频繁发生矿石卡斗或需人工干预清理大块矿石的情况,将对运输系统的连续性和整体生产效率造成显著影响。

在上述工艺无人化趋势的情况下,有轨运输环节的溜井矿石块度自动识别技术可以及时发现并提醒大块的出现,联锁工控系统停止装载流程,防止在大块出现后未发现或未及时处理对矿车和架空线等

运输设备产生后续破坏,同时,检测系统还能针对大块的出现位置和频率及块度大小进行统计,进而反馈并为出矿环节的工艺控制提供参考。

2 矿石块度检测系统架构

2.1 矿石块度检测技术路线

矿石块度检测系统通过在装矿溜井处安装摄像头,通过视频监控服务器将多个视频流传输到后端服务器,服务器中部署的识别软件通过 OpenCV 对图像进行逐帧处理、检测矿石轮廓,再通过 YOLO 算法对块度进行深度学习,提高识别和计算的准确率,最终系统与工控系统采用 OPC 协议进行通讯,将系统管理信息和告警统计等信息进行传输,系统采用内嵌 WEB 界面进行可视化显示,生产过程中管理人员或者工艺操作人员对报警进行处理,后台管理者也可通过该平台对块度参数报警进行设定和修改。矿石块度检测系统架构如图 1 所示。

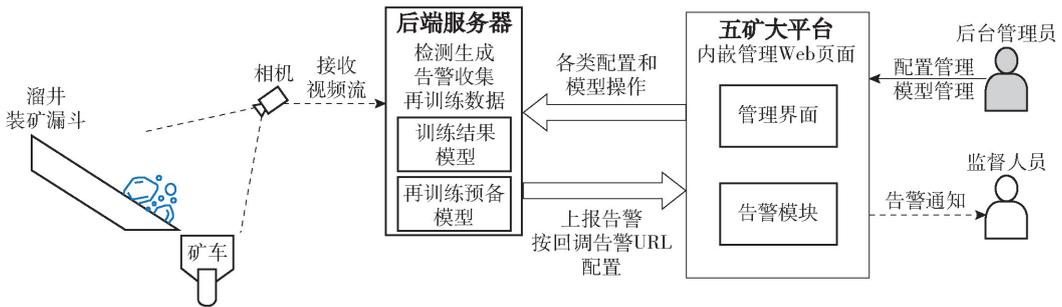


图 1 矿石块度检测系统架构

Fig. 1 Block identification system architecture

本研究构建的矿石块度检测系统,采用 Flask 框架作为 Web 应用的核心架构,通过页面配置实现数据的整合与监控设备的联动,同时负责控制和管理告警阈值等关键信息。在实时监控过程中,监控进程负责采集实时画面,并筛选出高精度识别的画面帧,作为后续深度学习训练的样本。当累积到足够的样本后,主服务端将自动触发再学习任务,进而自动执行后续的训练过程。该系统根据绑定的设备数量,支持水平扩展,并具备集群化处理能力。系统既可独立运行,也可通过 IFRAME 技术实现与其他系统的无缝集成。

2.2 模型训练

在模型训练过程中,本研究采用了 YOLO (You Only Look Once) 算法。YOLO 算法是一种基于深度学习的实时目标检测算法,其网络结构属于一种特

殊的卷积神经网络。该算法具有多项显著特点:实时性能好;端到端的训练与预测模式能够显著缩短训练时间;多尺度检测能力能够有效识别不同尺寸的目标;全局信息的捕捉能够增强模型的适应性;目标类别的独立性(将多种类目标检测整合至单一模型中)。YOLO 算法的核心在于将目标检测问题转化为一个全局回归问题,通过单一前向传播过程同时实现分类与定位。该算法在检测速度方面展现出显著优势,同时维持了较高的检测精度,特别适合于实时目标检测任务。在 YOLO 模型的训练过程中,首先从视频流中提取矿石图像,确保包含不同粒度的矿石场景,随后利用 LabelImg 工具进行图像标注;接着,将数据集划分为训练集(占 70% ~ 80%)、验证集(占 10% ~ 20%)和测试集(占 10%),通过调整 batch、epochs 和 weights 指令,对训练的批量大

小、迭代轮数、权重等参数进行优化,利用验证集对模型性能进行评估,关注模型在验证集上的精度、召

回率、mAP 等关键指标;最终,使用测试集对模型的泛化能力进行验证。系统模型的训练流程如图 2 所示。

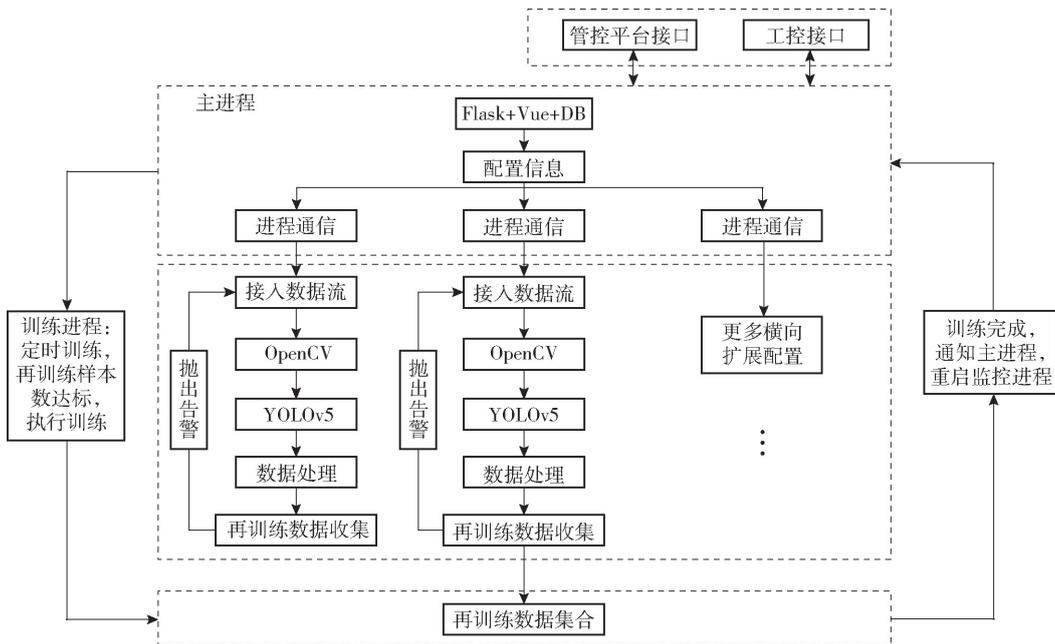


图 2 系统模型训练流程
Fig. 2 System model training process

3 矿石块度检测系统部署应用

GPU 计算硬件设备选用 RTX4090/12G 作为核心计算硬件,其强大的图形处理能力为模型的推理计算提供了坚实的基础。该 GPU 能够高效处理复杂的模型运算任务,特别是在处理图像数据相关的模型时,其高显存容量和先进的计算架构可显著提升运算速度。

采用 TensorRT 对模型进行优化和推理加速,有效减少模型推理所需的时间^[9]。其工作原理在于对模型结构进行分析与重构,在 YOLO 模型的推理过程中, TensorRT 能够加速目标检测的各个环节,从特征提取到边界框预测等,将模型中的一些计算操作进行融合、优化,从而提高计算效率,使得模型能够在更短的时间内完成对输入数据的处理并输出准确的结果。

训练初始权重 YOLO 模型采用离线方式,在模型训练过程中,无需实时连接外部网络获取数据或依赖在线平台的服务,离线训练方式不仅确保了数据的安全性,还避免了因网络波动或在线平台故障对训练过程的干扰。通过在内网环境下利用本地计算资源进行多轮次的模型训练,逐步优化模型的权

重参数,使其能够适应矿山有轨运输环节中的矿石块度识别任务。

训练完成后的模型以离线方式部署于检测服务器上,将模型转换为与 TensorRT 兼容的格式,并根据服务器的 GPU 特性进行进一步的优化调整。然后,将优化后的模型文件部署到检测服务器的指定目录下,并配置相应的运行参数和环境变量,确保模型能够在服务器启动时正确加载并运行。检测服务器在内网环境下独立运行,接收来自溜井放矿矿石块度的图像数据,利用部署的模型进行实时分析与处理,并将结果反馈给相关的控制系统或监控平台。

另外,考虑到现场工况及网络传输质量等情况,部署集成可考虑通过以下 3 种方式。

1) 边缘设备部署:边缘设备是指具备一定计算能力的硬件设备,通常位于数据生成源附近,如矿石溜井、监控摄像头、自动化控制设备等。边缘设备部署在深度学习应用中,尤其是在实时视频分析和目标检测等场景中,具有显著优势,如减少延迟、降低带宽消耗、提高数据安全性,然而,也面临着计算能力、网络连接、资源限制和维护难度等挑战。通过优化深度学习模型、利用硬件加速和设计高效的系统架构,可以最大化边缘设备的优势,并将其应用于矿

石块度识别等实时监控任务中。

2) 云端部署: 云端提供了强大的计算能力、存储空间和管理功能, 适合大规模数据处理和模型训练, 特别适应于硬件投资有限, 但多路并发(如多溜井同时装载等)计算资源要求高的场景。通过将深度学习模型和数据存储放在云端, 可以大幅提升矿石块度识别系统的可扩展性和灵活性。同时, 云端部署面临着网络延迟、数据安全和存储成本等挑战, 这要求开发者在设计时充分考虑这些问题并进行优化。

3) 工业集成: 在工业集成部署方式中, 将检测结果集成到矿山监控系统是一个关键环节, 尤其是在矿石块度识别系统中, 通过使用消息队列和通信协议, 如 MQTT 和 Kafka 等, 可以实现高效、实时的设备数据传输、处理与监控。这些协议在矿山监控系统中的应用, 能够确保数据的即时性、可靠性和高效性, 实现智能化、自动化操作。

3.1 块度检测功能实现

矿石块度检测系统基于视觉目标检测算法模型, 实现对矿石大小(基于设置的目标参数)进行机器学习后生成识别模型。系统根据设置的矿石大小参数, 识别大于等于目标值的矿石块, 并对识别出的矿石块进行标号和打框, 计算打框的面积, 形成统计数据提供给应用层。详细功能具体如下。

1) 矿石块度自定义设置: 矿石块度检测系统提供参数设置界面, 管理界面可以根据不同时期的视觉识别要求, 进行块度目标的自定义设置。基于设置的大块目标, 进行自动识别。对识别的大块矿石进行打框和标记编号。通过对大块矿石的标记编号, 实现大块矿石的计数, 计数与视频中的标记大块矿石和矿石出现时间关联, 为进一步的统计分析提供基础数据来源。

2) 矿石面积计算: 软件基于设置的大块目标, 进行自动识别。对识别的大块矿石进行打框, 通过红框覆盖的像素来自动换算成矿石真实的面积。该功能提供标记矿石面积记录, 为进一步的矿石面积分布统计提供数据源。

3) 矿石块度数量及时间分布统计: 软件基于矿石视觉检测算法提供的大块矿石标记、数量和矿石面积等数据, 为用户提供大块数量查询和统计功能、大块面积分布统计功能、基于大块检测到的时间及大块放矿点的记录统计各放矿点的大块数与时间分布。同时, 根据采集数据找到需要进一步分析的放矿点,

对其发现的大块矿石面积分布统计。用户通过选择放矿点及确定需要查询的时间范围, 统计该放矿点大块的面积分布情况, 找到相对占比较高的放矿点。

4) 超大块度实时报警: 软件基于检测到的大块矿石信息, 如放矿点位置、发现大块矿石的时间、大块矿石标记、大块矿石数量、大块矿石面积等, 推送发现大块矿石的报警信息。

5) 历史查询: 软件系统提供对大块矿石报警信息的查询, 支持按放矿点和时间维度查询报警信息。

6) 系统连锁: 系统通过数据接口, 支持与工控系统上位机或者 PLC 进行数据通讯。报警信息或大块矿石检测信息通过 MODBUS-RTU/MODBUS-TCP 协议, 上传给工控系统上位机, 上位机在接收到信息后推送报警信息给无人驾驶系统, 无人驾驶控制系统立即连锁相应给矿机停止工作。系统同时可接收无人驾驶系统下发的报警屏蔽指令, 对停止生产或已知故障点屏蔽报警信息。视觉检测系统提供标准的 API 接口, 以供其他系统对检测数据的调取。

3.2 矿石块度检测系统开发难点

开发基于深度学习的矿石块度识别系统具有挑战性, 主要难点集中在数据收集、模型训练、系统部署及实际应用环境的复杂性。系统开发和实施过程中可能会遇到以下难点。

3.2.1 数据采集与标注

矿石块度的形态、颜色、纹理和反射率等特性因环境条件的不同而表现出显著差异。这些差异可能源于金属种类、岩石类型和破碎方式等多种因素, 导致矿石在形态上具有高度的多样性。深度学习模型的泛化能力在很大程度上依赖于大量标注精确且多样化的数据, 以捕捉这些特征变化。如果缺乏足够的高质量标注数据, 模型的泛化能力可能受到显著限制。

在标注过程中, 矿石块度的标注需要达到像素级的精度, 尤其是针对不规则形状的矿石块, 标注工作既费时又容易出错。此外, 多种拍摄环境下的图像可能受到噪声的干扰, 例如阴影、光照变化或部分遮挡等问题, 进一步增加了标注难度。同时, 不同尺寸矿石块在数据集中的分布可能不均衡, 某些尺寸或类别的矿石样本较少会导致模型对这些类别的预测性能较差, 甚至完全无法识别。

3.2.2 模型训练

YOLO 算法在检测小目标时存在显著局限性, 尤其在图像分辨率较低的情况下。由于 YOLO 算法

将图像划分为固定大小的网格,并通过每个网格预测目标的位置和类别,小目标可能被多个网格共享或忽略,进而导致检测精度下降。YOLO 算法定位精度(即边界框回归的准确性)通常低于其他算法,例如 Faster R-CNN。在某些情况下,YOLO 算法预测的边界框可能偏离目标的实际位置。

此外,虽然 YOLO 算法可以在小型数据集上进行训练,但要实现高检测精度,通常需要大量标注数据,以帮助模型学习目标的多样化特征。在目标种类繁多或背景复杂的场景下,YOLO 对数据量的需求尤为明显,数据不足可能显著限制模型性能。

3.2.3 计算资源与实时性

深度学习模型的运行通常需要高计算资源配置支持,特别是在处理视频流分析和实时推理任务时,计算资源配置的需求尤为显著。在低硬件资源配置(如边缘计算设备)环境中,实现高效实时推理仍然是一个重大挑战。在实际测试中,使用高性能 GPU 和 CPU 对 48 路并发视频流进行处理时,受限于计算资源,系统出现了明显的卡顿现象,平均延迟约为 1.5 s。针对该问题,除增加计算资源外,目前的解决方案主要是通过减少并发视频流的检测通道数量,以确保系统稳定性和实时性。然而,这种方法可能限制系统的扩展性和应用范围。

针对上述问题,矿石块度检测系统在部署后需要进行持续的调优,以确保其识别的准确性和实时性。

3.3 块度检测系统调优及应用

鉴于矿山采矿环境的复杂性,在开发阶段难以获取足够的高质量训练样本,也无法全面模拟实际生产环境。因此,能够在生产运行过程中动态采集数据并持续优化模型,将显著提升系统的告警与检测精度。

在初始开发中,使用工业领域广泛应用的目标检测模型 YOLO 系列算法,能够提供基础的检测精度,通常保底精度为 0.5。为了进一步提升模型的识别性能并实现精度目标值 0.9,可通过下列多种技术手段进行优化^[10]。

1) 数据增强:利用旋转、裁剪、亮度调整等方法扩展样本多样性。

2) 多尺度训练:在不同分辨率下训练模型,提高对多尺度目标的检测能力。

3) 迁移学习:在大规模公开数据集上预训练模

型,并迁移至特定矿山场景进行微调。

4) 模型融合:结合多种模型的预测结果,以提升整体检测性能。

5) 正负样本平衡:调整样本分布,避免类别不平衡对模型学习的影响。

6) 模型优化技术:如知识蒸馏、剪枝等,提升模型的推理效率和性能。

7) 后处理操作:优化非极大值抑制(NMS)等策略,减少检测误报。

通过综合运用上述技术,并结合实际场景需求和硬件资源约束,可以有效提高模型在复杂矿山环境中的检测精度,确保系统满足块度识别的生产需求。

矿山生产与矿石转运过程对块度识别的需求涉及多个环节,包括提升系统、爆破后的矿堆、胶带运输等。因此,本系统在设计中充分考虑了扩展性。通过扩大采样范围、增加标注样本量并对多目标进行训练,可支持更多类型的检测任务,满足多样化生产场景的需求。

此外,为便于后续优化,管理后台提供用户友好的重新训练功能界面。在生产运行中,系统能够同时执行数据采集和检测任务。当后台提示已收集到足够数量的样本时,管理员可以通过管理界面启动模型重新训练流程,自动生成优化后的检测模型,以适应动态变化的生产环境。这种“生产与训练并行”的设计,有助于系统持续优化检测能力,并满足多场景矿山应用的实际需求。

4 结论

本文针对矿山井下有轨运输无人驾驶溜井自动装载环节大块多、易卡斗等问题,研究了矿石块度检测系统的技术路线、部署以及调优方式,并得出如下结论。

1) 系统通过应用图像识别算法 YOLO 及 Open-VC 及现场部署,对矿山轨运输工艺环节矿石块度进行识别,实现了溜井口及矿车内大块的报警和数据统计。

2) 该系统的实施拓展了图像识别技术在矿山生产智能化转型中的应用,能够确保有轨运输无人驾驶工况下的放矿作业设备安全、减轻人工监视劳动强度、提高管理水平。

3) 系统的应用可扩展到竖井提升、胶带运输等其他矿石转运场景,为智能矿山的无人化实践提供借鉴参考。

[参考文献]

- [1] 徐涛,郭武英. 地下金属矿山大块产生原因以及处理措施[A]. 中国金属学会. 第十四届中国钢铁年会论文集—1. 矿业工程[C]. 中国金属学会:中国金属学会, 2023:6. DOI:10.26914/c.cnkihy.2023.055018.
- [2] 范阿永. X射线分选机在某钨矿选矿厂的分选试验[J]. 有色矿冶,2021,37(3):23-26.
- [3] 李振武,何建新,沈建波. 深埋煤层运输巷变形特征及支护优化研究[J]. 中国矿山工程,2022,51(5):48-53.
- [4] 何文轩,胡健,柳小波,等. 矿石块度视觉识别判断方法[J]. 中国矿业,2021,30(6):100-105.
- [5] 曲伟霞,潘伟,郑飞,等. 黄金矿山溜井运输 AI 视觉技术分析研究[J]. 金属矿山,2023(4):174-179.
- [6] 陈立军,蔡国强,张文斌. 基于深度学习技术的爆堆块度识别方法研究[J]. 爆破,2024,41(1):196-201,220.
- [7] 曹士杰,张竹林. 基于改进 YOLO v5 的矿石石块实例分割算法[J]. 兰州工业学院学报,2023,30(6):19-25.
- [8] 郭帅,郝毅,周永伟. 矿山有轨运输电机车双机牵引技术及无人化应用研究[J]. 有色设备,2024,38(4):9-15.
- [9] 刘善明,余新阳,欧阳魁. 面向筛面复杂背景的矿山异物视觉检测方法[J]. 计算机技术与发展,2024,34(5):196-204.
- [10] 邹知炜,孙文浩,陈松. YOLO 目标检测后处理算法的优化和硬件加速[J]. 微电子学与计算机,2024,41(4):31-37.

Application of ore block identification system in ore chute loading

GUO Shuai

(China ENFI Engineering Corporation, Beijing 100038, China)

Abstract: This paper aiming at the working conditions of large ore blocks and easy jamming in the automatic loading process of unmanned rail transportation, constructs an ore block size recognition system based on the application design of machine vision library OpenCV and YOLO training model. The system can realize the functions of ore block size calculation, ore block size quantity and time distribution statistics, real-time alarm and query of super large blocks, etc., realize the detection and management of ore block size in the chute, ensure the safety of ore discharge equipment under the working conditions of unmanned rail transportation, and reduce the labor intensity of manual monitoring, providing reference for the implementation of unmanned mine system and digital transformation.

Keywords: ore size identification; image recognition; underground rail transportation; mine intelligence; ore; metal mine; detection ▲

(上接第 55 页)

gas flow field was simulated using the RNG $k-\varepsilon$ turbulence model. The particle deposition characteristics of water-cooled flue and insulated flue were investigated, as well as the effect of flue gas flow velocity on the particle deposition in the flue. It was found that the deposition rate of the water-cooled flue was significantly lower than that of the insulated flue, and the use of the water-cooled flue could effectively reduce the particle deposition in the flue; with the increase of the flue gas flow velocity, the particle deposition rate was reduced and the optimal flow velocity of the flue gas was 7 m/s.

Keywords: water-cooled flue; two-phase flow; particle deposition; numerical simulation; submerged arc furnace; ferronickel ▲