基于干式磁选机的钛铁矿分选关键指标预测①

谢家豪[1]，刘洋[1,2]，马崇振[1]，曾尚林[1]，刘恒发[1]，祁生月[2]，胡康龙[2]，黄涛[3]，祁玲[2]，张文科[2]
（1.长沙矿冶研究院有限责任公司，湖南 长沙 410012；2.青海西矿信息技术有限公司，青海 西宁 810000；3.中铁十九局集团矿业投资有限公司，北京 100161）

摘　要：针对干式磁选工艺中矿石品位与回收率预测精度不高的问题，提出一种基于 XGBoost 与 Transformer 融合的预测模型框架。该方法通过 XGBoost 提取局部特征并利用叶节点信息实现特征增强，提升输入数据的表达能力；随后，Transformer 利用多头自注意力机制挖掘特征间的全局依赖关系，强化模型的预测性能。针对钛铁矿干式磁选的预测结果表明，融合模型在预测精度与泛化能力方面均优于支持向量回归（SVR）、XGBoost、BP 神经网络及标准 Transformer。

关键词：干式磁选；机器学习；预测模型；品位预测；回收率预测；XGBoost；Transformer；特征增强；钛铁矿
中图分类号：TD924；TP311　　**文献标志码**：A　　doi：10.3969/j.issn.0253-6099.2026.03.021
文章编号：0253-6099（2026）03-0156-04

Prediction of Key Indices of Ilmenite Separation Based on Dry Magnetic Separator

XIE Jiahao[1], LIU Yang[1,2], MA Chongzhen[1], ZENG Shanglin[1], LIU Hengfa[1], QI Shengyue[2], HU Kanglong[2], HUANG Tao[3], QI Ling[2], ZHANG Wenke[2]
(1. *Changsha Research Institute of Mining and Metallurgy Co., Ltd., Changsha* 410012, *Hunan*, *China*; 2. *Qinghai Xikuang Information Technology Co., Ltd., Xining* 810000, *Qinghai*, *China*; 3. *China Railway* 19*th Bureau Group Mining Investment Co., Ltd., Beijing* 100161, *China*)

Abstract: Aiming at the problems of accuracy in prediction of ore grade and recovery in dry magnetic separation process, a prediction model framework integrating XGBoost and Transformer was proposed. In this method, XGBoost is used to extract local features and enhance features via leaf node information, improving the representation ability of input data. Subsequently, Transformer employs a multi-head self-attention mechanism to explore global dependencies among features and strengthen the prediction performance of the model. The prediction results of dry magnetic separation of ilmenite show that the constructed integrated model outperforms SVR, XGBoost, BP neural network and standard Transformer in terms of prediction accuracy and generalization ability.

Key words: dry magnetic separation; machine learning; forecasting model; grade prediction; recovery prediction; XGBoost; Transformer; feature enhancement; ilmenite

随着工业智能化水平不断提升，选矿作为矿产资源开发中的关键环节，正逐步向高效、智能与绿色方向发展。干式磁选[1]具有无需用水、流程简洁、能耗较低等优势，在磁性矿物的预处理与预选中得到广泛应用。然而，由于矿石原料成分复杂、工艺流程涉及多个关键参数，磁选品位与回收率受到诸多因素影响，存在预测困难、控制精度低[2]等问题。传统的建模方法如 BP 神经网络[3]、支持向量回归（SVR）[4]等在面对非线性强、特征关系复杂的数据时，常难以兼顾预测精度与泛化能力。近年来，集成学习与深度学习技术的发展为选矿建模提供了新的解决思路。基于此，本文提出一种 XGBoost[5]与 Transformer[6]融合的预测模型框架，充分发挥 XGBoost 在局部特征提取与建模方面的优势以及 Transformer 在全局关系建模方面的能力，以提升矿石品位与回收率预测的准确性与稳定性。该方法可为干式磁选工艺参数的智能优化提供新的技术路径。

① **收稿日期**：2025-11-28
基金项目：国家重点研发计划（2021YFC2902703）
作者简介：谢家豪（2000—），男，湖南衡阳人，硕士，主要研究方向为矿物加工及选冶自动化。E-mail：1983911124@qq.com
通信作者：刘洋（1983—），男，湖南岳阳人，博士，正高级工程师，主要研究方向为矿物加工及选冶智能化建设。E-mail：liuyang0730@qq.com

1　研究方法

干式磁选机是一种基于磁场分离原理设计的矿物分选设备,主要由磁选筒、磁系系统、给料装置以及卸矿装置组成,设计紧凑,操作简便,适用于中低品位矿石的分选,在提升资源利用效率和减少环境影响方面具有较大潜力[7]。

干式磁选主要依赖于矿物颗粒在磁场中的磁性差异来实现磁性矿物与非磁性矿物的分离。矿石首先通过给料装置均匀进入磁场作用区,磁性矿物在磁力作用下被吸附在旋转的磁选筒表面,非磁性矿物则因缺乏足够的磁力支持,沿原轨迹滑落至尾矿出口。随着磁选筒的旋转,已吸附的磁性矿物被带入磁场较弱的区域,在重力和离心力的作用下脱离筒壁,并通过卸矿装置收集为磁性产品。在分选过程中,磁场强度、磁场梯度、分选筒转速以及给料速度等参数共同影响分选效率[8],合理调整这些参数可有效提高磁性矿物的分选指标和效率[9]。

本文基于历史实验数据构建了一个包含 139 个样本的小型数据集。该数据集整理并挖掘了企业的生产记录、实验报告与技术文档,提取了钛铁矿干式磁选过程中涉及的关键工艺参数,包括磁场强度、处理量、原矿品位以及相应的重要生产指标。在数据预处理过程中,发现部分字段存在缺失情况,尤其是分矿板和温度字段缺失较为严重,可能是实验记录不完整所致,因此决定剔除这两类数据。在进行统计分析后,选取钛精矿品位为预测目标之一;统计分析发现,样本中产率与回收率存在高度相关性,因此决定舍去产率而选取回收率作为预测目标之一。

基于上述分析,将钛精矿品位、回收率作为预测目标,磁场强度、处理量、分选筒转速、原矿品位作为输入特征。钛铁矿实验数据集统计分析结果见表 1。

表 1　钛铁矿实验数据集统计分析结果

Table 1　Statistical analysis of experimental dataset of ilmenite

统计值	磁场强度/T	处理量/($t \cdot h^{-1}$)	分选筒转速/($r \cdot min^{-1}$)	品位/%		回收率/%
				原矿	精矿	
最小值	1 500	2.0	26.0	3.99	5.29	1.51
最大值	11 000	6.5	172.0	48.12	58.38	98.93
平均值	6 839	4.0	87.6	35.60	46.20	64.20
标准差	1 872	1.3	42.6	10.40	6.50	22.80

2　XGBoost-Transformer 融合框架介绍

提出了一种基于 XGBoost-Transformer 的回归预测模型,以提高钛精矿品位、回收率的预测精度。该方法首先利用 XGBoost 进行特征增强,即通过 XGBoost 训练得到叶节点索引,再通过 One-Hot 编码形式转换为新的高维稀疏特征,并与原始特征拼接,通过梯度提升决策树提取输入变量与目标变量之间的非线性关系,生成基于决策路径的特征表示;随后,借助 Transformer 编码器进一步建模输入特征之间的复杂交互关系,利用多头自注意力机制捕捉全局依赖,从而提升预测能力。XGBoost-Transformer 模型流程如图 1 所示。

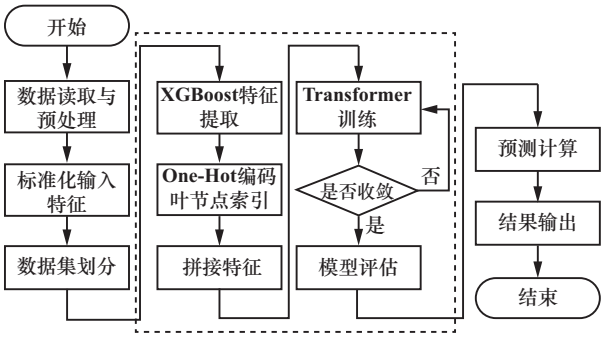


图 1　XGBoost-Transformer 模型流程

Fig. 1　Flowchart of XGBoost-Transformer model

2.1　XGBoost 原理介绍

XGBoost[10]是一种基于梯度提升框架的高效、可扩展的机器学习算法,主要用于分类、回归等监督学习任务,尤其在处理结构化表格数据时表现优异。XGBoost 以梯度提升树作为基础模型,能在较小样本的数据集上进行高效的非线性特征学习,并自动选择最具代表性的特征分割点。

在 XGBoost 训练过程中,每棵决策树的生成遵循以下迭代公式:

$$F_t(x) = F_{t-1}(x) + \gamma h_t(x) \tag{1}$$

式中:$F_t(x)$为第 t 轮的累计预测值;$F_{t-1}(x)$为上一轮模型的预测结果;$h_t(x)$为本轮新加入的弱学习器(回归树);γ 为步长系数(学习率)。

XGBoost 通过最小化目标函数来优化每棵树的结构,其目标函数定义如下:

$$L(t) = \sum_{i=1}^{n} l(y_i, \hat{y}_i^{(t-1)} + h_t(x_i)) + \Omega(h_t) \tag{2}$$

式中:$l(y_i, \hat{y}_i)$为损失函数,衡量真实值 y_i 与预测值 $\hat{y}_i$ 之间的误差;$\Omega(h_t)$是对模型复杂度的正则化项,以防止过拟合。

为增强 XGBoost 提取的特征表达能力,采用叶节点索引进行 One-Hot 编码,将样本的决策路径转换为高维稀疏特征。最终,对 XGBoost 生成的特征与原始数据进行拼接,形成扩展特征矩阵供 Transformer 模型输入。

2.2 Transformer 原理介绍

在提取和增强特征后,采用 Transformer 编码器进一步建模输入特征之间的关系。Transformer 最早被提出用于自然语言处理任务[11],但近年来其在表格数据建模方面同样展现出卓越性能。Transformer 的核心思想是通过多头自注意力机制计算各特征之间的全局依赖关系,突破了传统神经网络和卷积网络只能处理局部信息的局限性。Transformer 编码器的结构[12]包括输入层、多头自注意力机制、前馈神经网络、归一化层、池化层和输出层。其工作流程为:输入层通过线性映射将原始特征矩阵转换为固定维度向量;多头自注意力机制通过查询、键、值计算特征间相关性,生成注意力权重以捕捉复杂关系;前馈神经网络以两层全连接网络和 ReLU 激活进行非线性变换,结合残差连接优化梯度传播;归一化层采用层归一化和 Dropout 稳定数据分布,加速收敛并防止过拟合;池化层通过全局平均池化生成固定维度特征向量;最终,输出层通过全连接层线性变换输出钛精矿品位和回收率的预测值。

3 预测方案

3.1 模型构建总体过程

构建的 XGBoost-Transformer 模型主要包括数据预处理、特征增强、特征建模和模型评估 4 个环节。

1) 数据预处理:首先从数据集中提取核心特征和目标变量,对输入变量进行标准化,以消除特征量纲差异,确保模型训练的稳定性。数据随后划分为训练集和测试集,并通过数据加载器以批量方式输入模型。

2) 特征增强:采用 XGBoost 提取增强特征。具体来说,训练 XGBoost 以目标变量作为监督信号,并提取叶节点索引特征;接着对这些索引进行 One-Hot 编码,并与原始标准化特征拼接,以丰富模型的输入信息,提高特征表达能力。

3) 特征建模:采用 Transformer 编码器处理增强后的输入数据。Transformer 的多头自注意力机制能够学习输入变量之间的全局关系,FFN 进一步进行特征变换,LayerNorm 及 Dropout 防止梯度消失与过拟合,最终通过全局池化层提取稳定的特征向量,并映射至输出层得到预测值。

4) 模型评估:采用均方误差(MSE)和决定系数(R^2)作为性能评价指标,并通过预测值与真实值的散点图评估模型的拟合效果。同时,绘制损失曲线以分析训练的收敛性。整体流程从数据处理、特征增强到 Transformer 计算,确保了模型能够有效地学习回归任务的复杂模式,提高预测的准确性和稳定性。

3.2 数据预处理与标准化

从原始数据集中提取磁场强度、处理量、分选筒转速和原矿品位作为输入变量,钛精矿品位与回收率作为预测目标。数据预处理中,填充或剔除缺失值,检测异常值,以确保数据完整性。考虑到模型对输入数据尺度的敏感性,首先对特征变量进行了标准化处理,使每个特征的均值为 0、标准差为 1,从而提高模型的训练效率并加快收敛速度。标准化公式为:

$$X_{\text{std}} = \frac{X - \mu}{\sigma} \tag{3}$$

式中:X 为原始数据(一个特征的值);μ 为该特征的均值;σ 为该特征的标准差;X_{std}为标准化后的数据。

数据处理完成后,将数据集划分为训练集(80%)和测试集(20%),划分方式采用随机抽样,并固定随机种子,以保证实验结果的可复现性。训练集用于模型训练,测试集用于模型的泛化能力评估。

3.3 模型训练与评估

3.3.1 模型训练

模型训练过程中,使用均方误差(MSE)作为损失函数,采用 Adam 优化器进行模型参数的优化,学习率设定为 1×10^{-4},并在优化过程中使用 L2 正则化以减少过拟合的风险。为了进一步提升模型的泛化能力,训练过程中还应用了 Dropout 技术。训练过程中,使用批量训练对模型进行优化,通过 200 个 epoch 的迭代,逐步优化模型参数,减少训练损失。

3.3.2 模型优化与评估

预测模型关键超参数配置如表 2 所示。训练完成后,使用测试集评估模型性能,并采用 MSE 和 R^2 作为指标。MSE 用于衡量预测误差,MSE 的值越小,预测效果越好;R^2 用于衡量拟合度,R^2 越接近 1,拟合度越高。分析损失曲线时发现,模型在约 100 次迭代后收敛,说明模型具有较好的泛化能力。

3.4 对比模型选择

为评估 XGBoost-Transformer 模型的性能优势,通过对比实验,选取了 SVR、XGBoost 以及深度学习模型 BP 神经网络和标准 Transformer 作为基准模型。实验基于同一数据集和评估指标,分析各模型的预测效果,以确定最优模型。

4 结果与分析

4.1 模型预测结果分析

在测试集上绘制的真实值与预测值散点图如图 2 所示。大多数预测结果接近理想对角线分布,说明模型较好地识别了工艺参数与目标变量之间的内在关系,具备良好的拟合效果与预测能力。

表 2　预测模型关键超参数配置

Table 2　Configuration of key hyperparameters of forecasting model

超参数	优化配置	说明及理由
学习率	1×10^{-4}	进一步降低学习率,确保训练平稳,避免震荡
权重衰减	1×10^{-3}	明显增加 L2 正则化力度,强力抑制过拟合
批次大小	8	小批量训练,更有利于模型泛化
XGBoost 树的数量	20	减少树数量,避免模型复杂度过高
XGBoost 树的最大深度	2	降低树深度,限制模型容量
XGBoost 学习率	0.03	进一步减小学习率,稳定训练过程
随机种子	42	保证结果复现
Transformer 嵌入维度	32	大幅减小维度,减少参数量
Transformer 层数	1	保持单层,避免过拟合
注意力头数	1	头数最小化,降低模型复杂度
Dropout 比率	0.3	强化正则化
损失函数	MSELoss	适合回归任务
优化器	Adam	保持 Adam 优化器
训练周期	200	增加训练周期,确保充分训练
标准化	StandardScaler	标准化输入,提升训练稳定性

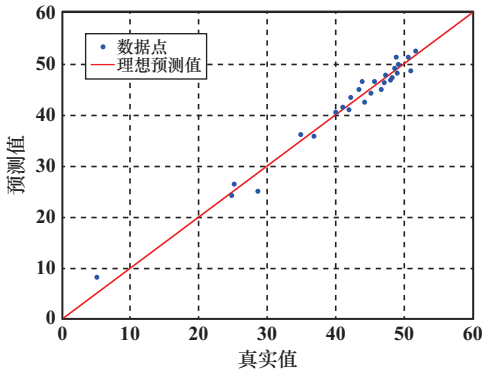


图 2　XGBoost-Transformer 融合模型预测结果

Fig. 2　Prediction results of XGBoost-Transformer fusion model

4.2　不同模型实验分析

不同模型预测结果对比如表 3 所示。结果表明:XGBoost-Transformer 融合模型在品位和回收率预测任务中均取得极优表现。其中,品位预测的 MSE 为 1.893,R^2 为 0.951;回收率预测的MSE为 1.737,R^2 为 0.948,上述结果均显著优于传统模型(如 SVR、XGBoost、BP 神经网络)和标准 Transformer。该融合模型在小样本条件下具有更强的特征表达与学习能力,能有效提升干式磁选工艺参数预测的精度与稳定性。

表 3　不同模型预测结果对比

Table 3　Comparison of prediction results of different models

模型	品位		回收率	
	MSE	R^2	MSE	R^2
SVR	3.736	0.853	3.923	0.831
XGBoost	3.760	0.851	3.835	0.834
BP 神经网络	3.567	0.867	3.234	0.851
标准 Transformer	2.544	0.932	2.431	0.929
XGBoost-Transformer	1.893	0.951	1.737	0.948

5　结语

1) 针对干式磁选过程中钛铁矿精矿品位与回收率预测精度不足的问题,提出了一种融合 XGBoost 与 Transformer 的预测模型。该模型首先利用 XGBoost 进行特征增强,提升特征表达能力,随后结合 Transformer 建模全局特征依赖关系,实现了更为准确且稳定的预测。实验结果表明,所提融合模型在预测性能方面优于 SVR、XGBoost、BP 神经网络以及标准 Transformer,展现出较好的泛化能力。

2) 尽管该模型在预测钛铁矿精矿品位和回收率方面取得了一定效果,但受限于样本数量较少,Transformer 即使在 XGBoost 特征增强的辅助下,性能提升仍有限。未来可考虑引入更适用于小样本学习的经典模型,进一步提升预测精度,从而更有效地辅助干式磁选工艺优化与控制。

参考文献(References):

[1] 邓长久,聂础辉,胡昊,等. 基于 PLC 的干式磁选机控制系统设计与应用[J]. 自动化与仪表, 2024,39(12):133-137.
DENG Changjiu, NIE Chuhui, HU Hao, et al. PLC-based dry magnetic separator control system design and application[J]. Automation & Instrumentation, 2024,39(12):133-137.

[2] 刘潇倩,任祥君,易凡,等. 新型离心干式磁选机预选细粒磁铁矿石粉料的分选机理与试验[J]. 中南大学学报(自然科学版), 2024,55(11):4080-4089.
LIU Xiaoqian, REN Xiangjun, YI Fan, et al. Separation mechanism and experimental verification of a novel centrifugal dry magnetic separator for preconcentrating fine magnetite ore powder[J]. Journal of Central South University (Science and Technology), 2024,55(11):4080-4089.

[3] 张万帆,任力生,王芳. 基于 SO-BP 神经网络的温室环境预测模型研究[J]. 中国农机化学报, 2024,45(8):94-99.
ZHANG Wanfan, REN Lisheng, WANG Fang. Research on greenhouse environment prediction model based on SO-BP neural network[J]. Journal of Chinese Agricultural Mechanization, 2024,45(8):94-99.

[4] DING B R, WANG Q, MA Y, et al. Prediction of compressive strength of concrete for high-performance concrete using two combined models, SVR-AVOA and SVR-SSA[J]. Multiscale and Multidisciplinary Modeling, Experiments and Design, 2024,7(2):961-974.

[5] WU H T, ZHANG Z L, DANIEL DIAS. Prediction on compression indicators of clay soils using XGBoost with Bayesian optimization[J]. Journal of Central South University, 2024,31(11):3914-3929.

(下转第 164 页)

研究进展[J]. 有色金属(选矿部分), 2025(1):33-47.
HUAN Yan, WEI Zhicong, XIE Haiyun, et al. Research progress on flotation depression of typical magnesium silicate gangue minerals[J]. Nonferrous Metals (Mineral Processing Section), 2025(1):33-47.

[2] 刘栖巧,车宇航,陈伟,等. 辉钼矿与滑石浮选药剂研究进展[J]. 金属矿山, 2024(2):56-68.
LIU Qiqiao, CHE Yuhang, CHEN Wei, et al. Research progress in the flotation reagent of molybdenite and talc[J]. Metal Mine, 2024(2):56-68.

[3] 陈帆帆,郑灿辉,卜显忠. 快速浮选分离滑石与辉钼矿动力学研究[J]. 矿冶工程, 2024,44(5):70-74.
CHEN Fanfan, ZHENG Canhui, BU Xianzhong. Flotation kinetics study for efficient separation of talc and molybdenite by flash flotation[J]. Mining and Metallurgical Engineering, 2024,44(5):70-74.

[4] 吴奕彤,焦芬,魏茜,等. 低品位高滑石型钼矿高效分离工艺研究[J]. 矿冶工程, 2024,44(2):43-46.
WU Yitong, JIAO Fen, WEI Qian, et al. Efficient separation process for low-grade high-talc molybdenum ore[J]. Mining and Metallurgical Engineering, 2024,44(2):43-46.

[5] 杨东. 反浮选提升铜精矿品质的研究与实践[J]. 世界有色金属, 2020(9):54-55.
YANG Dong. Research and practice of improving copper concentrate quality by reverse flotation[J]. World Nonferrous Metals, 2020(9):54-55.

[6] 陆夏羿,吴志强,陈建华,等. 滑石表面多糖类抑制剂作用机理的密度泛函理论和分子动力学研究[J]. 中南大学学报(自然科学版), 2024,55(12):4431-4441.
LU Xiayi, WU Zhiqiang, CHEN Jianhua, et al. Density functional theory and molecular dynamics studies on mechanism of polysaccharide depressants on talc surface[J]. Journal of Central South University (Science and Technology), 2024,55(12):4431-4441.

[7] 孙立田,陈旭波,陈雁南,等. 瓜尔胶对秘鲁特罗莫克铜矿中滑石的抑制效果评价[J]. 石油化工应用, 2018,37(7):61-65.
SUN Litian, CHEN Xubo, CHEN Yannan, et al. Evaluation of the inhibitory effect of guar gum on talc in tromoke copper mine in Peru[J]. Petrochemical Industry Application, 2018,37(7):61-65.

[8] 肖舜元. 白钨选矿回水在高滑石钼矿选矿中的应用研究[J]. 矿冶工程, 2020,40(6):55-58.
XIAO Shunyuan. Recycling of scheelite beneficiation backwater in flotation of high talc type molybdenum ore[J]. Mining and Metallurgical Engineering, 2020,40(6):55-58.

[9] 张曙光,简胜,唐鑫,等. 某含钼低品位硫化铜矿综合回收钼的选矿研究[J]. 矿冶工程, 2024,44(1):48-51.
ZHANG Shuguang, JIAN Sheng, TANG Xin, et al. Comprehensive recovery of molybdenum resource from low-grade molybdenum-bearing copper sulfide ore[J]. Mining and Metallurgical Engineering, 2024,44(1):48-51.

[10] 刘呈祥,宗巴. 斑岩型铜钼矿矿石性质及选矿工艺优化研究[J]. 世界有色金属, 2024(15):100-102.
LIU Chengxiang, ZONG Ba. Study on ore properties and beneficiation process optimization of porphyry copper-molybdenum ore[J]. World Nonferrous Metals, 2024(15):100-102.

[11] 刘春龙. 多宝山铜钼矿铜钼分离工艺优化研究[J]. 福建冶金, 2019,48(1):1-4.
LIU Chunlong. Study on optimization of copper-molybdenum separation technology on Duobaoshan copper and molybdenum ore[J]. Fujian Metallurgy, 2019,48(1):1-4.

引用本文:邓红,王星. 某高滑石型复杂铜钼矿选矿试验研究[J]. 矿冶工程, 2026,46(3):160-164.
DENG Hong, WANG Xing. Beneficiation test of high-talc complex copper-molybdenum ore[J]. Mining and Metallurgical Engineering, 2026,46(3):160-164.

(上接第159页)

[6] 陈月强,伍磊,黄桦. 基于改进Transformer模型的短期风电功率预测[J]. 电工技术, 2024(22):24-28.
CHEN Yueqiang, WU Lei, HUANG Hua. Modified transformer model-based short-term power forecasting of wind generations[J]. Electric Engineering, 2024(22):24-28.

[7] 邓长久. 干式磁选机智能控制系统的设计与应用[D]. 岳阳:湖南理工学院, 2024.
DENG Changjiu. Design and application of intelligent control system for dry magnetic separator[D]. Yueyang: Hunan Institute of Science and Technology, 2024.

[8] TANG D D, WANG F W, DAI H X, et al. Influence of separation chamber shape in dry magnetic separator on the dispersion and separation of multiple magnetites[J]. Minerals Engineering, 2021, 171: 107130.

[9] LI H X, ZHOU E H, SHEN L, et al. Dynamical characteristics and vibration behavior of the novel composite dry separator[J]. Vibroengineering Procedia, 2022,40:1-6.

[10] 陈泽生,周敏,冯李春,等. 基于XGBoost和粒子群优化算法的DGA恶意域名识别[J]. 通信学报, 2024,45(增刊2):27-32.
CHEN Zesheng, ZHOU Min, FENG Lichun, et al. DGA malicious domain name identification based on XGBoost and particle swarm optimization algorithm[J]. Journal on Communications, 2024,45(S2):27-32.

[11] 王若晨,钟汉斌. 基于Transformer的生物质流化床快速热解瞬时流率预测[J]. 当代化工研究, 2024(22):49-51.
WANG Ruochen, ZHONG Hanbin. Predicting instantaneous mass flow rates of biomass fast pyrolysis in a fluidized bed by transformer[J]. Modern Chemical Research, 2024(22):49-51.

[12] 刘文胜,荣娜,李宏伟,等. 基于SCSC-Swin Transformer的电力系统暂态稳定预测方法[J]. 电子测量技术, 2024,47(22):120-128.
LIU Wensheng, RONG Na, LI Hongwei, et al. Power system transient stability prediction method based on SCSC-Swin Transformer[J]. Electronic Measurement Technology, 2024,47(22):120-128.

引用本文:谢家豪,刘洋,马崇振,等. 基于干式磁选机的钛铁矿分选关键指标预测[J]. 矿冶工程, 2026,46(3):156-159.
XIE Jiahao, LIU Yang, MA Chongzhen, et al. Prediction of key indices of ilmenite separation based on dry magnetic separator[J]. Mining and Metallurgical Engineering, 2026,46(3):156-159.