真空筛分多孔介质床流动阻力系数 预测及影响因素分析

聂玲^{1,2} 马卫国^{2*} 阳婷² (1. 长江大学 计算机科学学院 荆州 434023; 2. 长江大学 机械工程学院 荆州 434023)

Prediction of Flow Resistance Coefficient and Analysis of Influencing Factors during Vacuum Screening of Porous Media Beds

NIE Ling^{1,2}, MA Weiguo^{2*}, YANG Ting²

School of Computer Science, Yangtze University, Jingzhou 434023, China;
 School of Mechanical Engineering, Yangtze University, Jingzhou 434023, China)

Abstract Investigating fluid flow characteristics during vacuum screening is crucial for revealing its underlying mechanisms. However, the filter bed formed by solid particles retained by the screen during vacuum screening is difficult to describe using microstructures and is often assumed to be a porous media bed. To accurately describe the fluid flow characteristics of the porous media bed and further investigate the performance during vacuum screening, this study predicted the flow resistance coefficient of the porous media bed based on experimental and machine learning methods. The study analyzed the feature importance ranking results of the BP neural network, random forest, and XGBoost models, identifying the sensitivity order of factors affecting the flow resistance coefficient of the porous media bed as air flow rate > particle bed > particle ratio > particle layer thickness > screen mesh. Ultimately, utilizing the genetic algorithm (GA) with the XGBoost prediction model as the fitness function for multi-objective optimization, a multi-objective optimization model was established, yielding the optimal vacuum screening process parameters and flow resistance coefficient. This study provides a new method for the study of the vacuum screening resistance coefficient, and the results are of great significance for analyzing the vacuum screening mechanism.

Keywords Porous media beds, Vacuum screening, Machine learning, Resistance coefficient, Influence factor

摘要 探究真空筛分流体流动特性对于揭示真空筛分机理至关重要。然而,真空筛分过程中筛网截留的固体颗粒形成 的过滤床难以采用微观结构描述,通常假设为多孔介质床。为了精确描述多孔介质床的流体流动特性,深入研究真空筛分性 能,文章基于实验与机器学习方法预测真空筛分多孔介质床流动阻力系数,分析了 BP 神经网络,随机森林和 XGBoost 模型特 征重要性排序结果,识别出影响多孔介质床流动阻力系数因素的敏感性顺序为气流速度>颗粒床>颗粒配比>颗粒层厚度>筛 网目数。最后,采用遗传算法 GA,以 XGBoost 预测模型作为多目标优化的适应度函数,建立真空筛分多孔介质床多目标优化 模型,得到最优真空筛分工艺参数和流动阻力系数。文章为真空筛分流动阻力系数的研究提供了一种新方法,研究结果对揭 示真空筛分机理具有重要意义。

关键词 多孔介质床 真空筛分 机器学习 阻力系数 影响因素 中图分类号: TH117.2 文献标识码: A doi: 10.13922/j.cnki.cjvst.202404008

收稿日期:2024-04-09 基金项目:国家自然科学基金项目(52100135);湖北省教育厅科学研究计划资助项目(D20221304) *联系人:E-mail:mwg-jh@yangtzeu.edu.cn 真空筛分是一种以筛网和滤饼为过滤介质,真 空作用产生的压差和空气穿过滤饼携带液体并置 换滤饼孔隙中的液体实现固液分离的方法^[1]。真空 筛分被广泛应用于医药、化工、环保等行业,具有广 阔的工程应用背景^[2-5]。在研究真空筛分过滤问题 时,流体在岩屑、砂石等形成的多孔介质床中的迁 移特性是进行相关研究的基础。多孔介质床流动 阻力系数是进行其迁移特性数值分析的关键参数。 因此,建立真空筛分多孔介质床的流动阻力系数预 测模型,并确定影响流动阻力系数的因素及其敏感 性,对于揭示真空筛分机理具有重要意义。

目前许多学者基于经典模型^[6]——Ergun 方程, 对多孔介质阻力系数的影响因素进行了研究。刘 洋等^[7]将铜网假设为固结型多孔介质,采用理论分 析和实验方法研究影响铜网阻力系数的因素,研究 结果表明,流体速度和铜网目数对阻力系数有影响。 杨中庚^[8] 基于颗粒分型理论, 构建了多孔介质床绕 流阻力模型,分析了多孔介质床内部的流动特性, 揭示了流体速度、孔隙率、颗粒当量直径等物性参 数对流动阻力的影响规律。陈竹筠等^[9]采用广泛应 用的 Ergun 模型,并考虑误差影响因子,探讨了玉米 层高度、风速和孔隙率等因素对玉米层通风阻力的 影响规律。毛迪凡^[10]采用理论分析与模型试验相 结合的研究方法,对等径球粒立方体排列多孔介质 床进行研究,提出了改进型 Ergun 公式。研究结果 表明,流体速度,介质床孔隙率和颗粒粒径对多孔 介质床流动阻力有影响。马培勇等[11]利用冷态实 验方法,探究了气流在泡沫陶瓷中的流动特性,并 采用 Ergun 方程对流动阻力进行了预测。研究结果 表明,气流速度、泡沫陶瓷孔密度对流动阻力存在 影响。吴国忠等[12] 对多孔介质床内油水流动阻力 系数进行了研究,研究结果表明,多孔介质内颗粒 床对其阻力特性存在影响。上述文献表明,目前国 内外对多孔介质流体流动的研究主要采用理论与 实验方法,建立基于微观结构参数的数学模型,探 讨流体流速、颗粒床、多孔介质孔隙率和多孔介质 微观结构参数等因素对多孔介质流动特性的影响 规律。然而,由于多孔介质的孔隙特征参数难以精 确测量,理论分析的方法存在一定的局限性,难以 适用于实际工程问题。

相比于理论方法建立的多孔介质床阻力系数 计算模型,机器学习算法具有明显的优势,可以利 用数据驱动的方式建立多孔介质阻力系数预测模 型,无需依赖物理假设和先验知识[13-14]。为此,部分 学者采用数据驱动的机器学习算法,诸如支持向量 机、神经网络和多元回归等,对多孔介质阻力系数 进行了研究。李佳等[15]通过人工神经网络、支持向 量机等机器学习算法对多孔介质的阻力系数进行 了预测,研究结果表明,多孔介质孔隙特征参数对 多孔介质渗透率存在影响。王依诚等[16]利用卷积 神经网络算法成功建立了一个高效的数字岩心阻 力系数快速预测模型,其预测精度达到了0.92。研 究结果表明,数字岩心的孔隙特征参数对阻力系数 有影响。AB Zolotukhin 等^[17]采用人工神经网络准 确地预测了多孔介质储层样品的阻力系数。研究 发现流体速度以及多孔介质的孔隙率等参数对多 孔介质阻力系数存在影响。Al Khalifah 等^[18]采用 人工神经网络和遗传算法对英格兰南部波特兰地 层的致密碳酸盐岩渗透率进行了预测,研究结果表 明,致密碳酸盐岩的孔隙度、特征孔喉直径等参数 对渗透率有影响。这些基于数据驱动的机器学习 算法预测多孔介质床阻力系数的研究需要获取难 以测量的多孔介质孔隙特征参数,并且只关注了模 型的预测性能,而忽略了影响多孔介质床阻力系数 的因素敏感性。此外,真空条件下多孔介质床流体 流动特性的研究鲜有报道。然而,工程实际中更多 需要揭示影响多孔介质床内流体流动特性的相关 因素的影响规律,当前研究涉及较少。根据文 献 [13-18] 的研究, 业界学者在预测多孔介质阻力系 数时,普遍倾向于采用数据驱动的机器学习算法。 鉴于数据驱动机器学习算法在机器学习领域的显 著优势^[19],本研究拟采用实验与数据驱动机器学习 算法相结合的方法,以大量多孔介质床阻力系数的 实验数据为基础,研究真空筛分多孔介质内流体流 动特性的因素敏感性,无需依赖复杂的孔隙特征参 数,旨在揭示影响真空筛分多孔介质内流体流动特 性的因素敏感性,并对影响真空筛分多孔介质床流 动阻力系数的敏感性工艺参数进行优化。

本文自行搭建了真空筛分装置,采用石英砂颗 粒作为过滤物料,建立不同的实验条件,获得了95 组真空筛分多孔介质床阻力系数实验数据,分析了 三种机器学习模型,即 BP 神经网络,随机森林和 XGBoost (eXtreme Gradient Boosting)模型特征重要 性结果,识别出了影响真空筛分多孔介质床阻力系 数因素的敏感性顺序;并采用遗传算法 GA^[20],以 XGBoost的预测模型作为多目标优化的适应度函数, 建立真空筛分多孔介质床流动阻力系数多目标优 化模型,得到多孔介质真空筛分最优工艺参数和流 动阻力系数。研究旨在为真空筛分多孔介质床阻 力系数的研究提供一种新方法,对分析真空筛分机 理具有重要意义。

1 实验研究

1.1 实验装置

本文设计并搭建了如图 1(a) 所示的实验装置。 该装置由真空系统和筛分过滤系统两部分构成,真 空系统由真空泵、真空罐以及其他连接和辅助设备 组成,用于提供和维持真空环境,筛分过滤系统由 物料筒和泥浆搅拌罐组成,用于进行物料的过滤和 搅拌,物料筒示意图如图1(b)所示,实验工作流程 如图1(c)所示。

实验中用到的工具和仪器包括:最大气流量为 315 m³/h 的 3RB350-1 型漩涡真空泵一个;总容积 为 300 L 的 Q235B 材质 DN600-300 型真空罐一个; 总高为 180 mm,内径为 200 mm 的 Q235 材质物料 筒一个;中国安平县星火金属网厂生产的有效过滤 面积为 0.03 m² 的 100 目、150 目和 200 目的 API 金 属丝编织筛网各 3个;控制阀若干;量程 35~ 380 m³/h 的 CKLUGD-D50-TD-C 涡街流量计一个; 由 80 目、100 目、120 目、200 目的 304 不锈钢筛网 组成的标准分样筛 1套;量程为 0.01~500 g的酷贝 i-2000 数字电子秤一个;烧杯和量杯若干。



图1 真空筛分过滤实验装置。(a)实验装置图,(b)物料筒二维示意图,(c)实验流程图

Fig. 1 Vacuum screening filtration experimental apparatus. (a) Experimental apparatus, (b) two-dimensional schematic diagram of material cylinder, (c) experimental procedure

1.2 实验设计理论模型

实验管段中多孔介质床内流体的流速和压降 满足一定的关系,其速度-压降关系表达式^[21]如下:

$$\Delta p = Av + Bv^2 \tag{1}$$

式(1)中,A与B为拟合系数; Δp 为压降, pa; v为 流速, m/s。

拟合实验数据确定A与B,然后可计算得到实验 管段中多孔介质床的粘性阻力系数和惯性阻力系 数,其计算公式^[22]为:

粘性阻力系数
$$D = \frac{A}{\mu\Delta l}$$
 (2)

惯性阻力系数
$$C_2 = \frac{2B}{\rho\Delta l}$$
 (3)

式中, μ 为动力黏度, pa.s; Δl 为多孔介质区域的厚度, m; ρ 为工质密度, kg/m³; *D*为粘性阻力系数; *C*₂为惯 性阻力系数。

1.3 实验方案

为了探明颗粒配比、颗粒层厚度、筛网目数、 气流速度和颗粒床对真空筛分多孔介质床粘性阻 力系数和惯性阻力系数的影响,本文基于1.2 所述 的理论模型,计算出不同实验条件下真空筛分多孔 介质床的粘性阻力系数和惯性阻力系数。真空筛 分多孔介质床阻力系数实验分为干颗粒实验和湿 颗粒实验两个阶段,制定的实验方案如下。

(1)实验物料调配:开始实验前使用四种目数 的标准分样筛筛分满足实验要求尺寸的石英砂颗 粒,按照表1所示的实验设计比例配置颗粒物试样 并充分混合,得到石英砂颗粒混合样本^[23]。将其中 一份样本不加水,作为干颗粒样本;另一份样本加 入适量清水进行充分浸泡,得到湿颗粒样本。

(2)实验过程:称取不同质量的颗粒样本(干颗 粒或湿颗粒),平铺在物料筒的筛网上,测量颗粒层

表 1	颗粒粒径混合比例
Tah 1	Particle size mixing ratio

að.	1 1	Part	icie	size	mixing	g ratio

颗粒配比	颗粒粒径					
	75~120 μm	120~150 μm	150~180 μm			
比例1	10%	40%	50%			
比例 2	20%	30%	50%			
比例 3	20%	40%	40%			
比例 4	30%	20%	50%			
比例 5	30%	40%	30%			

高度 L 并记录; 然后开启真空泵, 并调节真空罐内 真空度达到设定值, 开始计时并记录数据。每一次 实验在真空度达到设定值并稳定 5 秒后, 记录气流 量和真空度。每组实验在相同条件下重复 3 次, 记 录数据取平均值。

(3)数据处理:基于记录的数据采用拟合方法 得到拟合系数A和B,基于多孔介质床结构参数和流 体介质物性参数,采用式(2)和(3)可计算出不同实 验条件下真空筛分多孔介质床的粘性阻力系数和 惯性阻力系数。

1.4 实验与理论误差分析

每组实验重复三次取平均值,采用式(2)和(3) 计算得到 95 组多孔介质床阻力系数实验数据,表 2 为部分粘性阻力系数和惯性阻力系数实验数据,其 中颗粒配比取值比例 1~比例 5 分别用 1,2,3,4,5 表 示,颗粒床取值 0 表示干颗粒,取值 1 表示湿颗粒。

表 2 部分真空筛分多孔介质床粘性阻力系数和惯性阻力系数 Tab. 2 Partial particle layer viscous drag coefficient and inertial drag coefficient

样本	颗粒	颗粒层	筛网	雨始庄	气流	拟合	拟合	粘性阻力	惯性阻力	拟合
编号	配比	厚度/mm	目数	积型水	速度/ (m/s)	参数 A	参数 B	系数/ (m ⁻²)	系数 /(m ⁻¹)	优度
1	1	3.5	100	0	1.162	6390.9	2532.7	7.76E+10	6.75E+05	0.9986
2	2	5.3	150	0	0.862	14521.8	3297.0	9.10E+10	8.12E+05	0.9982
3	3	7.1	200	0	0.636	2613.8	3362.6	1.08E+11	9.51E+05	0.9953
4	4	8.8	100	0	0.552	24664.8	7889.8	1.22E+11	9.28E+05	0.9987
5	5	10.6	150	0	0.484	50034.3	6547.6	1.48E+11	1.31E+06	0.9541
6	1	3.5	200	0	1.178	5244.0	1831.8	8.28E+10	7.17E+05	0.9983
7	2	5.3	100	0	0.868	11064.1	4394.1	8.70E+10	7.91E+05	0.9952
8	3	7.1	150	0	0.656	23674.9	3521.0	1.10E+11	9.06E+05	0.9992
1	1	1	1	1	I			I	I	
91	1	3.5	100	1	0.910	17088.1	4507.7	1.02E+11	1.14E+06	0.9698
92	2	5.3	150	1	0.819	14763.9	5771.3	1.59E+11	2.78E+06	0.9837
93	1	7.1	100	1	0.565	32842.7	8146.4	1.34E+11	2.59E+06	0.9429
94	2	8.8	150	1	0.689	25243.5	7196.9	1.96E+11	4.57E+06	0.9602
95	1	10.6	100	1	0.442	37347.1	6830.8	1.73E+11	4.50E+06	0.9933

为了验证本文计算得到的多孔介质床流动阻 力系数的可靠性,以100目筛网、颗粒层厚度为 3.5 mm、颗粒床为干颗粒、颗粒配比分别为1~5 为 例,将实验研究计算得到的流动阻力系数与 Ergun 方程理论^[6]计算值进行对比分析,对比结果如图 2 所示。根据图示结果分析可知,粘性阻力系数和惯 性性阻力系数与理论计算值最大相对误差未超过 为9%,在允许接受的范围内,因此本文通过实验数 据拟合得到的流动阻力系数具有可靠性。

1.5 实验结果讨论

(1)筛网目数对流动阻力系数的影响

图 3 展示了不同筛网目数下多孔介质床粘性 阻力系数和惯性阻力系数的变化关系。实验中,颗 粒配比为比例 3,颗粒层厚度 7.1 mm,筛网目数分别 为 100 目,150 目和 200 目,颗粒床为干颗粒。从图 3 可知,无论是粘性阻力系数还是惯性阻力系数,都 随着筛网目数的增加而增加。粘性阻力系数随着 筛网目数从 100 目增加到 200 目,增加了 5.50%;惯 性阻力系数增加了 5.06%。这是因为筛网目数增加 时,筛网的孔隙直径减小,增加了流体透过多孔介 质床的阻力,相应的粘性阻力系数和惯性阻力系数 亦增加。



图2 流动阻力系数实验与理论对比

Fig. 2 Comparison between experimental and theoretical results of flow resistance coefficient







(2)颗粒层厚度对流动阻力系数的影响

图 4 展示了不同颗粒层厚度下多孔介质床粘 性阻力系数和惯性阻力系数的变化关系。实验中 颗粒配比为比例 3, 筛网目数为 150 目, 颗粒床为干 颗粒, 颗粒层厚度从 3.5 mm 增加到 10.6 mm。从 图 3 可知, 粘性阻力系数和惯性阻力系数均随着颗 粒层厚度的增加而增加。粘性阻力系数随着颗粒 层厚度从 3.5 mm 增加到 10.6 mm, 增加了约 31.94%, 惯性阻力系数增加了约 33.08%。这表明, 随着颗粒 层厚度的增加, 流体透过多孔介质床的阻力增加了, 相应的粘性阻力系数和惯性阻力系数亦增加。

(3)颗粒配比对流动阻力系数的影响

图 5 展示了不同颗粒配比下多孔介质床粘性 阻力系数和惯性阻力系数的变化关系。实验中,筛 网目数为 150 目,颗粒层厚度为 7.1 mm,颗粒床为



Fig. 4 Effect of particle thickness on flow resistance coefficient





干颗粒,颗粒配比从比例1增加到比例5。从图4 可知,颗粒配比为比例5时,粘性阻力系数最大;而 颗粒配比为比例1时,粘性阻力系数最小。惯性阻 力系数随颗粒配比的变化与粘性阻力系数呈现相 同的变化趋势。这是因为颗粒配比为比例5的石英 砂混合物中75~120 μm和120 μm~150 μm的石英 砂含量最高,颗粒配比为比例1的石英砂混合物中 75~120 μm的石英砂含量最低。细石英砂颗粒成分 的增加,石英砂混合物的孔隙率减小,流体透过多 孔介质床的阻力也增大,相应的粘性阻力系数和惯 性阻力系数亦增加。

(4)颗粒床对流动阻力系数的影响

图 6 展示了不同颗粒床下多孔介质床粘性阻 力系数和惯性阻力系数的变化关系。实验中,筛网 目数为 150 目,颗粒层厚度为 7.1 mm,颗粒配比为 比例 2,颗粒床分别为干颗粒和湿颗粒。从图 5 可

相关系数热力图如图7所示。

以发现,颗粒床为湿颗粒时,多孔介质床的粘性阻力系数显著高于干颗粒的情况。例如,颗粒床为湿颗粒时,多孔介质床的粘性阻力系数比颗粒床为干颗粒时高出约94.27%。惯性阻力系数的变化趋势与粘性阻力系数一致。







通过对实验结果进行讨论,发现颗粒配比、颗 粒层厚度、筛网目数、颗粒床对多孔介质床流动粘 性阻力系数和惯性阻力系数有不同程度的影响,但 是并不能判断影响真空筛分多孔介质床因素的敏 感性。机器学习模型特征重要性可以反映特征对 目标变量的影响大小,即特征在模型中的贡献度。 因此,本研究将采用机器学习特征重要性方法对多 孔介质床粘性阻力系数和惯性阻力系数因素敏感 性进行分析。

2 多孔介质床流动阻力系数影响因素分析

2.1 影响因素相关性分析

实验测试了筛网目数、颗粒层厚度、颗粒配比、 颗粒床和气流速度分别对多孔介质床粘性阻力系 数和惯性阻力系数的影响,但是不能揭示各影响因 素的相关性。常用的数据相关性分析方法有皮尔 逊相关系数法。皮尔逊(Pearson)相关系数是衡量 两个连续变量之间线性相关性的常用指标,它可以 在数值范围 [-1,1]之间取值,Pearson 相关系数的 绝对值越接近于 1,表明两个变量之间的线性关系 越强;反之,绝对值越接近于 0,则表明两个变量之 间的线性关系越弱或不存在。依据表 2 所示的 95 组实验数据在 Anaconda 平台采用 Python 语言进行



Pearson 相关系数分析,各影响因素之间的 Pearson

Fig. 7 Correlation coefficient heatmap of input factors

从图 7 可以发现,颗粒配比、颗粒层厚度、筛网 目数、颗粒床和气流速度之间的相关系数绝对值均 小于 0.5,说明这五个因素之间的线性相关性较弱。

2.2 阻力系数因素敏感性识别

根据 2.1 皮尔逊相关性分析的结果,即颗粒配 比、颗粒层厚度、筛网目数、颗粒床和气流速度之 间并不存在较强的线性相关性,可以将这五个参数 作为机器学习模型的输入,真空筛分多孔介质床的 粘性阻力系数和惯性阻力系数作为输出。

由于机器学习模型特征重要性可以反映特征 对目标变量的影响大小。BP神经网络^[24]一种模仿 人类大脑接收和处理信息的算法,它们在许多领域 形成了最先进的基础,给定足够的输入数据和计算 能力来训练更高级的架构,BP神经网络可以学习数 据中复杂的非线性模式。随机森林是一种以决策树 为基学习器的并行式集成学习算法,能够多样性和不 平衡数据,具有较高的准确性和鲁棒性。XGBoost^[25] 采用梯度下降的思想迭代地训练一系列决策树模 型,并通过加权组合这些模型的预测结果来获得最 终的预测,它通过并行化和正则化来提高训练速度, 并且在许多竞赛中表现出色。鉴于以上三种算法 各自的优势和特性,因此本文采用这三种机器学习 算法分析了各影响因素的特征重要性排名,结果如 表3所示。

根据表 3, BP 神经网络、随机森林和 XGBoost 模型的特征重要性排序可以看出, 三种模型排位前 三的特征重要性具有一致性,即气流速度、颗粒床 和颗粒配比均排在前三位,这三个特征的特征重要 性取值均在 0.18 以上,而排在后两位的特征是颗粒 层厚度和筛网目数。因此,影响真空筛分多孔介质 床阻力系数的因素敏感性顺序为气流速度>颗粒 床>颗粒配比>颗粒层厚度>筛网目数。

表 3 模型特征重要性排名对比

Tab. 3 Comparison of the importance ranking of each model feature

桂尔		特征重要性值	
村正	BP 神经网络	随机森林	XGBoost
气流速度	0.4134	0.3798	0.3701
颗粒床	0.2567	0.2653	0.2705
颗粒配比	0.1865	0.1859	0.1844
颗粒层厚度	0.1115	0.1254	0.1043
筛网目数	0.0319	0.0445	0.0707

3 流动阻力系数优化

3.1 优化模型

为使真空筛分多孔介质床流动阻力系数达到 优化区间内的全局最优水平,采用 XGBoost 与遗传 算法(GA)相结合的方法对真空筛分多孔介质床流 动阻力系数进行优化研究。优化模型中气流速度V、 颗粒床B、颗粒配比R、颗粒层厚度Th、筛网目数M 为优化变量;粘性阻力系数D和惯性阻力系数C₂为 优化目标,D和C₂越小表示真空筛分多孔介质床流 动性能越好。优化模型如下式(4)所示:

式中: (V_{\min}, V_{\max}) 、 (B_{\min}, B_{\max}) 、 (R_{\min}, R_{\max}) 、 (Th_{\min}, Th_{\max}) 、 (M_{\min}, M_{\max}) 分别为气流速度V、颗粒 床 B、颗粒配比 R、颗粒层厚度 Th、筛网目数 M的 约束区间。具体优化参数约束区间如表 4 所示。

$$f(X)_{\min} = \operatorname{Min}[D(X), C_{2}(X)]$$

$$X = (V, B, R, Th, M)$$

$$s.t = \begin{cases} V_{\min} \leq V \leq V_{\max} \\ B_{\min} \leq B \leq B_{\max} \\ R_{\min} \leq R \leq R_{\max} \\ Th_{\min} \leq Th \leq Th_{\max} \\ M_{\min} \leq M \leq M_{\max} \end{cases}$$
(4)

为获得优化模型式(4)的决策解,首先利用 XGBoost构建预测粘性阻力系数 D 和惯性阻力系数 C₂以及优化参数的映射关系模型,以 D 和C₂最小为 目标,确定参数优化模型,并采用 GA 进行优化求解。

715	<i>n</i>	N/L/L	_		<u></u>
	12 77	- 75/17 4/2	1 ++ 1	1	
	u 100			1.	ини
126	rL			· ·	

Tab 4	Optimization	parameter	constraints	interval
140.1	Optimization	purumeter	constraints	inter vur

表 4

参数名称	Symbol	约束区间	单位
气流速度	V	0.2~3	m/s
颗粒床	В	0,1	-
颗粒配比	R	1,2,3,4,5	-
颗粒层厚度	Th	3~11	mm
筛网目数	М	100,150,200	-

3.2 GA优化原理与流程

遗传算法(GA)是一种模拟自然进化过程的优 化算法,它将优化问题的解空间映射为染色体编码 空间,通过迭代地执行选择、交叉和变异等操作,实 现染色体信息的交换和更新,从而逐步逼近最优解。 由于 GA 算法的具有简单易行,收敛速度快,较好的 全局搜索能力等特点,本文将遗传算法和 XGBoost 相结合,训练好的 XGBoost 预测结果将作为个体的 适应度,然后通过 GA 算法寻找数据的全局最优值, 优化流程如图 8 所示。



图8 XGBoost-GA 优化流程图 Fig. 8 Flow chart of XGBoost-GA optimization

3.3 流动阻力系数预测模型与优化分析

3.3.1 预测模型建立

采用 XGBoos 建立粘性阻力系数 D 及惯性阻 力系数 C₂预测模型,模型样本数据共 95 组,采用随 机抽样的方法选取训练集和测试集,训练集样本 75 组,测试集样本 25 组。为减小误差,采用 Min-Max 归一化方法对数据进行归一化处理。为提高 模型预测精度,采用网格搜索(Grid Search CV)方法 对 XGboost 模型进行超参数进行优化。同时,利用 网格搜索方法内置的交叉验证方法对模型的性能 进行评估,从而选择最优的超参数。XGBoost 和 GA 算法参数设置如表 5 所示。

表 5 XGBoost-GA 参数设置 Tab. 5 XGBoost-GA parameters

模型	参数	值
	迭代次数	200
	树最大深度	3
XGBoost	学习率	0.1
	最小样本权重	2
	L1 正则化项的权重	0.001
	种群大小	100
	迭代次数	1000
GA	交叉概率	0.4
	变异概率	0.2

模型预测精度是真空筛分多孔介质床流动阻 力系数参数优化的前提。以决定系数 R²、均方根误 差为评价指标,对 XGBoost 模型的预测结果进行分 析,结果见表 6。由表 6 可知, XGBoost 模型,在粘 性阻力系数训练集上 R²达到了 99.74%,在测试集 上 R²达到了 98.71%;在惯性阻力系数训练集上 R² 均在 98% 以上;说明 XGBoost 模型在回归应用中具 有良好的性能。

表 6 XGBoost 预测结果

Гał). (5 X	GBoost	pred	liction	1 resu	lts
-----	------	-----	--------	------	---------	--------	-----

评价指标 -	粘性阻	力系数	惯性阻力系数		
	训练集	测试集	训练集	测试集	
R^2	0.9974	0.9871	0.9812	0.9845	
RMSE	0.0015	0.0018	0.0035	0.0026	

3.3.2 优化结果分析

利用遗传算法 GA 进行多目标的迭代优化,将 训练好的 XGBoost 预测模型作为多目标优化的适 应度函数,经过 1000 次迭代,获得 20 组真空筛分多 孔介质流动阻力系数遗传算法寻优的 Pareto 前沿解, 如图 9 所示。图中星号为选取的 Pareto 最优解。

从图 9 可知,在 Pareto 解集中,粘性阻力系数 在[7.16×10¹⁰,7.23×10¹⁰]之间分布,惯性阻力系数在 [6.55×10⁵,6.74×10⁵]之间分布。

从表 7 可知, Pareto 的非劣解集一共 20 组, 为 筛选出 Pareto 的最优解,本文通过熵权-TOPSIS 方 法对遗传算法优化得到的 Pareto 非劣解集进行排序,



排序最高的即为最优解^[26]。该方法是一种结合熵权 法和 TOPSIS 法的多属性决策分析方法。首先,通 过熵权法计算各属性的权重,以反映各属性在决策 中的重要性。然后,利用 TOPSIS 法将标准化后的 属性值进行排序,确定正理想解和负理想解。接着, 计算每个决策方案与正理想解和负理想解的距离, 进而得出每个方案的接近程度。最后,根据接近程 度进行排序,从而找出最优的决策方案。Pareto 的 非劣解集熵权-TOPSIS 评价结果如表 8 所示。

从表 8 可以发现,20 组 Pareto 的非劣解集中排 序第一的是方案 12,结合表 7 可知,多孔介质真空 筛分最优工艺参数为:颗粒配比为 1,筛网目数 100, 颗粒层厚度 3.5 mm,干颗粒床,气流速度 1.20 m/s; 最优粘性阻力系数为 7.176×10¹⁰ m⁻²,惯性阻力系数 为 6.635×10⁵ m⁻¹。

3.3.3 优化结果理论验证

为验证优化所得的真空筛分流动阻力系数的 准确性,本研究将优化后的流动阻力系数与基于 Ergun 方程^[6]的理论计算值进行了对比,分析结果 如图 10 所示。

从图 10 可以发现,优化前粘性阻力系数与惯 性阻力系数相较于理论计算值的误差分别为 8.91% 和 8.58%。然而,经过优化后,粘性阻力系数和惯性 阻力系数与理论计算值的误差显著降低,粘性阻力 系数的误差缩小至 2.06%,而惯性阻力系数的误差 降至 6.73%。这一结果表明,优化后的流动阻力系 数与理论计算值之间的误差更小,从而验证了优化 过程的有效性和准确性,为后续的工程应用提供了 更为可靠的依据。

方案	颗粒配比	颗粒层厚度/mm	筛网目数	颗粒床	气流速度/(m/s)	粘性阻力系数/(m ⁻²)	惯性阻力系数/(m ⁻¹)
1	1	3.5001	100	0	1.2003	7.167E+10	6.557E+05
2	1	3.5001	100	0	1.2004	7.167E+10	6.563E+05
3	1	3.5042	100	0	1.2014	7.168E+10	6.577E+05
4	1	3.5012	100	0	1.2008	7.168E+10	6.573E+05
5	1	3.5012	100	0	1.2011	7.169E+10	6.597E+05
6	1	3.5038	100	0	1.2027	7.169E+10	6.585E+05
7	1	3.5055	100	0	1.2017	7.169E+10	6.583E+05
8	1	3.5032	100	0	1.2012	7.171E+10	6.613E+05
9	1	3.5012	100	0	1.2028	7.171E+10	6.608E+05
10	1	3.5004	100	0	1.2005	7.173E+10	6.624E+05
11	1	3.5023	100	0	1.2014	7.175E+10	6.633E+05
12	1	3.5002	100	0	1.2008	7.176E+10	6.635E+05
13	1	3.5006	100	0	1.2007	7.177E+10	6.637E+05
14	1	3.5004	100	0	1.2008	7.179E+10	6.639E+05
15	1	3.5011	100	0	1.2007	7.184E+10	6.659E+05
16	1	3.5022	100	0	1.2024	7.187E+10	6.664E+05
17	1	3.5043	100	0	1.2006	7.192E+10	6.677E+04
18	1	3.5001	100	0	1.2008	7.197E+10	6.683E+05
19	1	3.5004	100	0	1.2013	7.210E+10	6.694E+05
20	1	3.5012	100	0	1.2006	7.231E+10	6.732E+05

	表 7 Pareto 非劣接解集
Tab. 7	The Pareto non-inferior solution set

表 8 非劣解熵权-TOPSIS 评价结果

Tab. 8	Non-inferior entropy weight TOPSIS evaluation results				
方案	正理想解 距离	负理想解 距离	综合得分 指数	排序	
12	0.0281	0.2535	0.9003	1	
16	0.0649	0.2096	0.7636	2	
6	0.0949	0.2236	0.7020	3	
19	0.1373	0.1591	0.5368	4	
11	0.1398	0.1296	0.4811	5	
5	0.1579	0.1319	0.4552	6	
18	0.1828	0.1453	0.4428	7	
9	0.1828	0.1428	0.4386	8	
14	0.1830	0.1380	0.4300	9	
7	0.1707	0.1280	0.4285	10	
13	0.1924	0.1304	0.4039	11	
4	0.1850	0.1189	0.3914	12	
3	0.1653	0.1059	0.3904	13	
2	0.2194	0.1382	0.3865	14	
10	0.2104	0.1315	0.3847	15	
15	0.1936	0.1182	0.3790	16	
8	0.1663	0.1011	0.3780	17	
1	0.2285	0.1379	0.3763	18	
20	0.2030	0.1132	0.3579	19	
17	0.2279	0.0411	0.1529	20	



图10 流动阻力系数优化值与理论值对比



4 结论

本研究设计搭建了真空筛分实验装置并进行 实验,采用三种机器学习算法,识别出了影响真空 筛分多孔介质床的阻力系数因素敏感性,并采用遗 传算法 GA,以 XGBoost 的预测模型作为多目标优 化的适应度函数,建立真空筛分多孔介质床流动阻 力系数多目标优化模型,得到以下主要结论:

(1)搭建了真空筛分实验装置,在不同的实验 条件下获得了 95 组多真空筛分多孔介质床阻力系 数实验数据,经分析数据具备较强的稳定性。但是 由于本文实验研究中并未考虑介质粘度对真空筛 分多孔介质床的影响,因此,在将该模型应用于涉 及不同介质粘度的真空筛分多孔介质床情况时,可 能会存在一定的偏差。

(2)分析了 BP 神经网络、随机森林和 XGBoost 三种模型的特征重要性排序结果,识别了影响真空 筛分多孔介质床阻力系数因素的敏感性。研究发 现影响真空筛分多孔介质床阻力系数的因素敏感 性顺序为气流速度>颗粒床>颗粒配比>颗粒层厚 度>筛网目数。

(3)采用遗传算法 GA, 以 XGBoost 预测模型作 为多目标优化的适应度函数, 建立真空筛分多孔介 质床流动阻力系数多目标优化模型, 得到多孔介质 真空筛分最优工艺参数为颗粒配比为 1, 筛网目数 100, 颗粒层厚度 3.5 mm, 干颗粒床, 气流速度 1.20 m/s; 最优粘性阻力系数为 7.176×10¹⁰ m⁻², 惯性 阻力系数为 6.635×10⁵ m⁻¹。

参考文献

- [1] Wu S L, Li X D, Jiang P M, et al. Dewatering characteristics of waste slurry from pipe jacking based on improved vacuum filtration method[J]. Tunnelling and Underground Space Technology, 2022, 130: 104727
- [2] Höfgen E, Kühne S, Peuker U A, et al. A comparison of filtration characterisation devices for compressible suspensions using conventional filtration theory and compressional rheology[J]. Powder Technology, 2019, 346: 49–56
- [3] Nguyen C V, Nguyen A V, Doi A, et al. Advanced solidliquid separation for dewatering fine coal tailings by combining chemical reagents and solid bowl centrifugation[J].
 Separation and Purification Technology, 2021, 259: 118172
- [4] Rögener F. Filtration technology for beer and beer yeast treatment[J]. IOP Conference Series: Earth and Environmental Science, 2021, 941(1): 012016
- [5] Li B Y, Dobosz K M, Zhang H T, et al. Predicting the performance of pressure filtration processes by coupling computational fluid dynamics and discrete element methods[J]. Chemical Engineering Science, 2019, 208: 115162
- [6] Ergun S. Fluid flow through packed columns[J]. Chemi-

cal Engineering Progress, 1952, 48(2): 89-94

- [7] Liu Y, Zhao L X, Zhou L D, et al. Research on the fluid resistance pressure drop characteristics based on porous jump model[J]. Machine Tool & Hydraulics, 2022, 50(7): 17–26 (刘洋, 赵立新, 周龙大, 等. 基于多孔跃迁模型的流体阻力压降特性研究 [J]. 机床与液压, 2022, 50(7): 17–26 (in Chinese))
- [8] Yang Z G. Flow characteristics of porous media[D]. Baotao: Inner Mongolia University of Science & Technology, 2019 (杨中庚. 多孔介质流动特性研究 [D]. 包头: 内蒙 古科技大学, 2019 (in Chinese))
- [9] Chen Z J, Wan L, Che G, et al. Correction of Ergun model based on maize ventilation resistance test[J]. Journal of Agricultural Mechanization Research, 2019, 41(11): 172-177,184 (陈竹筠, 万霖, 车刚, 等. 基于玉米通风阻 力试验的 Ergun 模型修正 [J]. 农机化研究, 2019, 41(11): 172-177,184 (in Chinese))
- [10] Mao D F. The improvement of the porous media seepage equation[D]. Wuhan: China University of Geosciences, 2012 (毛迪凡. 孔隙介质渗流基本方程的改进 [D]. 武 汉: 中国地质大学, 2012 (in Chinese))
- [11] Ma P Y, Tang Z G, Cai W D. An experimental study and modeling on the flow resistance of airflow through foam ceramic[J]. Natural Gas Industry, 2010, 30(11): 97–101 (马培勇, 唐志国, 蔡万大. 气流通过泡沫陶瓷的流阻实 验与模型研究 [J]. 天然气工业, 2010, 30(11): 97–101 (in Chinese))
- [12] Wu G Z, Xing Y Q, Lü Y, et al. Experimental analysis of resistance coefficient of oil and water flow in porous media[J]. Experimental Technology and Management, 2016, 33(10): 34–37 (吴国忠, 邢永强, 吕妍, 等. 多孔介质内 油水流动阻力系数实验分析 [J]. 实验技术与管理, 2016, 33(10): 34–37 (in Chinese))
- [13] Liu X M, Liu W, Li L N, et al. Optimal design of vacuum interrupter based on improved neural network and genetic algorithm[J]. Chinese Journal Vacuum Science and Technology, 2020, 40(4): 359–364 (刘晓明, 刘威, 李龙 女,等. 基于改进神经网络和遗传算法的真空灭弧室优 化设计 [J]. 真空科学与技术学报, 2020, 40(4): 359–364 (in Chinese))
- [14] Chen Z L, Liang S, Li G H, et al. Comparative study on comprehensive properties prediction of DLC thin films based on different neural networks[J]. Chinese Journal of Vacuum Science and Technology, 2023, 43(8): 665-673 (陈志立, 梁帅, 李国浩, 等. 基于不同神经网络的 DLC 薄膜综合性能预测的对比研究 [J]. 真空科学与技术学

第 10 期

报, 2023, 43(8): 665-673 (in Chinese))

- [15] Li J. A machine learning-based approach for permeability prediction of porous media[D]. Hangzhou: Zhejiang University, 2019 (李佳. 基于机器学习的多孔介质渗透 率预测研究 [D]. 杭州: 浙江大学, 2019 (in Chinese))
- [16] Wang Y C, Jiang H Q, Yu F W, et al. Researches on the pore permeability prediction method of 3D digital cores based on machine learning[J]. Petroleum Science Bulletin, 2019, 4(4): 354–363 (王依诚, 姜汉桥, 于馥玮, 等. 基于机器学习的数字岩心孔渗预测方法研究 [J]. 石油科学 通报, 2019, 4(4): 354–363 (in Chinese))
- [17] Zolotukhin A B, Gayubov A T. Machine learning in reservoir permeability prediction and modelling of fluid flow in porous media[J]. IOP Conference Series: Materials Science and Engineering, 2019, 700(1): 012023
- [18] Al Khalifah H, Glover P W J, Lorinczi P. Permeability prediction and diagenesis in tight carbonates using machine learning techniques[J]. Marine and Petroleum Geology, 2020, 112: 104096
- [19] Zhou Z H. Machine learning[M]. Beijing: Tsinghua University Press, 2016 (周志华. 机器学习 [M]. 北京: 清华 大学出版社, 2016 (in Chinese))
- [20] Ileberi E, Sun Y X, Wang Z H. A machine learning based credit card fraud detection using the GA algorithm for feature selection[J]. Journal of Big Data, 2022, 9(1): 24
- [21] Wu J S, Yu B M. A fractal resistance model for flow through porous media[J]. International Journal of Heat and Mass Transfer, 2007, 50(19-20): 3925–3932

- [22] Tan Y W, Guo L, Gao H L, et al. Deep coupled joint distribution adaptation network: a method for intelligent fault diagnosis between artificial and real damages[J].
 IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3507212
- [23] Ma W G, Li C, Nie L. Analysis of negative pressure screening blockage based on EDEM-Fluent coupling method[J]. Journal of Yangtze University (Natural Science Edition), 2022, 19(2): 72-79 (马卫国, 李晨, 聂玲. 基于 EDEM-Fluent 耦合方法的负压筛分堵塞分析 [J]. 长江大学学报(自然科学版), 2022, 19(2): 72-79 (in Chinese))
- [24] Sagi O, Rokach L. Explainable decision forest: transforming a decision forest into an interpretable tree[J]. Information Fusion, 2020, 61: 124–138
- [25] Jiang S F, Wu T J, Peng X, et al. Data driven fault diagnosis method based on XGBoost feature extraction[J]. China Mechanical Engineering, 2020, 31(10): 1232–1239 (姜少飞, 邬天骥, 彭翔, 等. 基于 XGBoost 特征提取的数据驱动故障诊断方法 [J]. 中国机械工程, 2020, 31(10): 1232–1239 (in Chinese))
- [26] Liu X J, Chen J P, Zhang Y C, et al. Design optimization of heating-pad with hot-air path in square-grid shape for road surface deicing: a simulation study[J]. Chinese Journal of Vacuum Science and Technology, 2019, 39(8): 725-731 (刘晓静, 陈佳萍, 章易程, 等. 基于热流场仿真 的井状通路暖气垫的结构优化 [J]. 真空科学与技术学 报, 2019, 39(8): 725-731 (in Chinese))