基于PSO-SVM的尾砂仓储浓密机放砂稳定性分析*

袁子淇[1,2,3]，黄腾龙[1,2,3]，林敏[4]，杨双有[4]，陈久吾[4]

（1.长沙矿山研究院有限责任公司， 湖南 长沙 410012；
2.金属矿山安全技术国家重点实验室， 湖南 长沙 410012；
3.湖南省矿山固废综合利用工程技术研究中心， 湖南 长沙 410012；
4.安徽庐江龙桥矿业股份有限公司， 安徽 合肥 231551）

摘要：为提高充填效率，实现尾砂仓储浓密机的连续稳定放砂，结合矿山的实际情况以及静态、动态絮凝沉降的试验结果，采用粒子群算法（PSO）优化支持向量机（SVM）回归分析方法，建立了放砂稳定性预测模型，并利用混合加点法更新预测模型，通过寻优算法确定出最优参数，实现尾砂仓储浓密机放砂稳定性预测。以东辛庄铁矿为例，完成了基于PSO-SVM的浓密机结构参数及放砂参数的最优方案，并进行工业试验验证。结果表明，泥层高度以及泥层高度、放砂浓度、浓密时间的联合作用对放砂稳定性的影响最大，PSO-SVM预测模型预测放砂稳定性的精度较好，相对误差为1.36%。研究结果能为浓密机外形参数和放砂参数的选择提供理论依据，能有效提高浓密机的放砂稳定性。

关键词：浓密机；稳定放砂；粒子群；支持向量机；优化

中图分类号：TD853.34 **文献标识码**：A **文章编号**：1005-2763(2025)01-0095-08

Analysis of Desanding Stability of Tailings Storage Thickener Based on PSO-SVM

YUAN Ziqi[1,2,3], *HUANG Tenglong*[1,2,3], *LIN Min*[4], *YANG Shuangyou*[4], *CHEN Jiuwu*[4]

(1.Changsha Institute of Mining Research Co., Ltd., Changsha, Hunan 410012, China;
2.State Key Laboratory of Metal Mine Safety Technology, Changsha, Hunan 410012, China;
3.Hunan Mining Solid Waste Comprehensive Utilization Engineering Technology Research Center, Changsha, Hunan 410012, China;
4.Anhui Lujiang Longqiao Mining Co., Ltd., Hefei, Anhui 231551, China)

Abstract: In order to improve the filling efficiency and realize the continuous and stable desanding of the tailings storage thickener, combined with the actual situation of the mine and the test results of static and dynamic flocculation and sedimentation, the particle swarm optimization (PSO) algorithm was used to optimize the support vector machine (SVM) regression analysis method. The prediction model of desanding stability was established, and the prediction model was updated by the hybrid point addition method. The optimal parameters were determined by the optimization algorithm to realize the prediction of desanding stability of the tailings storage thickener. Taking Dongxinzhuang Iron Mine as an example, the optimal scheme of thickener structure parameters and desanding parameters based on PSO-SVM was completed and verified by industrial tests. The results show that the mud layer height and the combined effect of mud layer height, sand concentration and thickening time have the greatest influence on the stability of desanding. The PSO-SVM prediction model has a good accuracy in predicting the desanding stability, with a relative error of 1.36%. The research results can provide a theoretical basis for the selection of thickener shape parameters and desanding parameters, and can effectively improve the desanding stability of thickener.

Key words: Tickener, Stable desanding, Particle swarm, Support vector machine, Optimization

0 引言

随着我国经济高速发展，矿产资源需求与日俱增。开采所产生的大量固废不管是地表排放还是堆存都会对环境产生重要影响。因此，国家对固废资源化的重视程度不断增加[1-2]。膏体充填是处理矿山尾废的重要手段，而浓密技术是实现膏体充填的重要环节。通过浓密技术将废弃尾矿制备成高浓度

* **收稿日期**：2024-05-09
基金项目：湖南省高新技术产业科技创新引领计划项目(2022GK4057)；长矿院科创基金项目(ZX23J070)
作者简介：袁子淇(2000—)，女，四川成都人，硕士研究生，主要研究方向为机械设计与金属矿山充填技术。E-mail：yuanzz7@126.com

料浆,与胶凝材料搅拌后形成膏体并输送至井下采空区,提高尾废的利用率[3-5]。尾砂仓储浓密机作为尾砂浓密的关键设备,其放砂浓度的高低、放砂的稳定性和连续性,都是保证充填系统正常有序工作的核心指标。对于细尾砂,料浆容易在浓密机内发生板结,底流浓度难以稳定,对充填料浆浓度产生不利影响。因此,开展连续放砂浓度稳定性的研究,对于保障充填系统稳定运行和提高充填体质量具有十分重要的意义。

近年来,许多学者针对浓密设备稳定连续放砂的问题开展了研究。吴再海[6]改进了造浆喷嘴的布置,通过试验和流体仿真,证明了底部造浆系统对放砂稳定性的提升。李树磊等[7]改进了造浆喷嘴,从而提高了活化造浆的效率,使放砂更连续。部分学者通过控制算法,对底流浓度进行动态调控。袁兆麟等[8]通过算法控制底流泵转速和絮凝剂泵转速,维持底流浓度的稳定。贾润达等[9]建立了底流浓度预测模型,通过调整底流流量使浓度稳定。除此之外,也有学者研究了浓密过程参数和浓密机结构对底流浓度的影响。吴爱祥等[10]通过离心试验,探究了底流浓度随储砂高度变化的函数,说明泥层高度是影响高浓度稳定放砂的重要因素。王新民等[11]利用遗传算法(GA)优化支持向量机(SVM),对浓密机底部锥角和浓密机桶高进行底流浓度的预测。王勇等[12]针对深锥浓密机,根据试验得出高径比与底流浓度之间的数学模型,通过浓密机的合理结构控制底流浓度。

综上,在有关提高底流浓度浓密机理方面的研究已取得了较大的成果,然而以往研究较少涉及提高底流浓度稳定性的参数优化分析。本文综合考虑尾砂仓储浓密机桶高、底部锥角两个结构参数,放砂浓度、放砂流量、浓密时间 3 个放砂工艺参数,基于粒子群优化的支持向量机回归(PSO-SVR)算法,建立了尾砂仓储浓密机的底流浓度稳定性预测模型,并通过寻优算法,在多因素条件下优化浓密机的性能,确保优化后的系统稳定可靠,同时为浓密机外形参数和放砂参数选择提供理论依据。

1 PSO 优化 SVM 预测模型

1.1 SVM 的基本原理

VAPNIK[13]提出了 SVM 线性分类器,适用于小样本学习,其结构简单、鲁棒性好。支持向量回归(Support Vector Regression,SVR)是 SVM 的一种运用。SVR 通过找到合适的参数来描述超平面,使所有的数据到这个面的距离最近,即所有数据的类内方差最小。对于高维问题,SVR 同样以 VC 维(VC-dimension)理论为基础,利用核技巧进行升维,把问题转换为约束条件下的凸二次规划问题,求得全局最优解[14]。给定样本集$\{(\boldsymbol{x}_1^{(1)},\boldsymbol{x}_2^{(1)},\cdots,\boldsymbol{x}_n^{(1)},y_1),(\boldsymbol{x}_1^{(1)},\boldsymbol{x}_2^{(1)},\cdots,\boldsymbol{x}_n^{(1)},y_2),\cdots,(\boldsymbol{x}_1^{(1)},\boldsymbol{x}_2^{(1)},\cdots,\boldsymbol{x}_n^{(1)},y_m)\}$,其中包含的样本具有 n 维特征,共 m 个实数目标输出。目标是通过线性映射 $\boldsymbol{x}_i=\phi(\boldsymbol{x}_i)(i=1,2,\cdots,n)$,找到权值矢量 $\boldsymbol{w}\in\boldsymbol{R}^n$,偏置值 $b\in\boldsymbol{R}$,使特征函数 $T(\boldsymbol{x})=\boldsymbol{w}^{\mathrm{T}}\phi(\boldsymbol{x})+b$ 到所有样本的距离最小,即求:

$$f(\boldsymbol{x})=\min_{\omega,b,\xi,\xi^*}\frac{1}{2}\boldsymbol{w}^{\mathrm{T}}\boldsymbol{w}+C\sum_{i=1}^{n}(\xi_i+\xi_i^*) \tag{1}$$

$$\text{s.t.}\begin{cases}y_i-\boldsymbol{w}^{\mathrm{T}}\phi(\boldsymbol{x}_i)-b\leqslant\varepsilon+\xi_i\\ \boldsymbol{w}^{\mathrm{T}}\phi(\boldsymbol{x}_i)+b-y_i\leqslant\varepsilon+\xi_i^*\\ \xi_i,\xi_i^*\geqslant 0,i=1,\cdots,n\end{cases} \tag{2}$$

式中:C 为惩罚因子;ξ_i、ξ_i^*、ε 为松弛变量。

使用拉格朗日乘子法,利用 SVM 的对偶性,并使用核函数代替最优分类中的内积运算,以提高其运算精度。原问题转化为:

$$f(\boldsymbol{x})=\min_{\alpha,\alpha^*}\frac{1}{2}\sum_{i,j=1}^{n}(\boldsymbol{\alpha}_i-\boldsymbol{\alpha}_i^*)(\boldsymbol{\alpha}_j-\boldsymbol{\alpha}_j^*)\boldsymbol{Q}_{ij}+\varepsilon\sum_{i=1}^{n}(\boldsymbol{\alpha}_i+\boldsymbol{\alpha}_i^*)-y_i\sum_{i=1}^{n}(\boldsymbol{\alpha}_i-\boldsymbol{\alpha}_i^*) \tag{3}$$

$$\text{s.t.}\begin{cases}\sum_{i=1}^{n}(\boldsymbol{\alpha}_i-\boldsymbol{\alpha}_i^*)=0\\ 0\leqslant\boldsymbol{\alpha}_i,\boldsymbol{\alpha}_i^*\leqslant C,i=1,\cdots,n\end{cases} \tag{4}$$

式中:$\boldsymbol{\alpha}_i$、$\boldsymbol{\alpha}_i^*$ 为对应向量 $\boldsymbol{x}_i$ 的支持向量;$j=1,2,\cdots,m$,表示第 j 个粒子;$\boldsymbol{Q}_{ij}$ 为核函数,$\boldsymbol{Q}_{ij}=K(\boldsymbol{x}_i,\boldsymbol{x}_j)=\phi(\boldsymbol{x}_i)\,\phi(\boldsymbol{x}_j)$。得到支持向量机 SVR 的预测模型为:

$$T(\boldsymbol{x})=\sum\nolimits_{i\in\boldsymbol{SV}}(\boldsymbol{\alpha}_i-\boldsymbol{\alpha}_i^*)K(\boldsymbol{x}_i,\boldsymbol{x})+b \tag{5}$$

式中:$\boldsymbol{SV}$ 为标准支持向量。

本文选择高斯核函数(Radial Basis Kernal,RBF)作为 SVM 的非线性映射函数:

$$K(\boldsymbol{x}_i,\boldsymbol{x}_j)=\boldsymbol{e}^{-\gamma\|\boldsymbol{x}_i-\boldsymbol{x}_j\|^2} \tag{6}$$

式中:$\boldsymbol{e}$ 为单位向量;γ 为宽度系数。

其函数值的大小反映了两向量的相似度大小,其中宽度系数 $\gamma>0$,γ 的大小决定了 RBF 对相似度的判断标准,因此实际应用中应当选择合适的 γ 值。

1.2 PSO 优化原理

PSO 算法由 KENNEDY 等受到鸟群觅食行为启发而建立[15-18]。通常假设在 n 维空间中,有 m 个粒子,则其中第 k 个粒子的飞行速度 $\boldsymbol{V}_k=(v_{k1},$

v_{k2}, …, v_{kn})(k=1,2,…,m),在第 t 代的第 k 个粒子向 t+1 代进化时,下一代的飞行速度和方向为:

$$v_{ij}(t+1)=\omega v_{kl}(t)+c_1 r_1(t)[p_{kl}(t)-x_{kl}(t)]+c_2 r_2(t)[p_{gq}(t)-x_{kl}(t)] \quad (7)$$

$$x_{kl}(t+1)=x_{kl}(t)+v_{kl}(t+1) \quad (8)$$

式中:l、g、q 代表第 l、g、q 个粒子,l、g、j 均为 1,2,…,m;ω 为惯性权重因子,通常取 0.5～0.8,表示粒子保持目前方向的概率;c_1 为个体的学习系数;c_2 为全局的学习系数,通常取 0.1～2[19];r_1、r_2 为在区间(0,1)上均匀分布的随机数;p_{kl} 为个体的最好位置,即个体极值;p_{gq} 为全局的最优位置,即全局极值。

1.3 PSO 算法优化 SVM 步骤

通过 PSO 寻优 SVM 的算法流程如图 1 所示,主要步骤为:

(1) 对数据进行归一化,将数据导入算法;

(2) 从样本集中随机选出支持向量作为训练集 X,剩下的样本作为测试集 Y;

(3) 初始化 PSO 算法的相关参数,设定粒子群初始的 ω(1)、c_1(1.5)、c_2(1.7),种群最大数量 S(10)和最大进化次数 K(100);

(4) 随机初始化种群速度的个体最优和全局最优位置;

(5) 训练 SVM,将训练结果经 5 折交叉验证,得到平均分类准确率,作为各个粒子的适应度函数值;

(6) 比较粒子当前适应度值与全局最优值,从而更新极值;

(7) 检查是否满足结束条件,如果满足进行步骤(8),若不满足重复步骤(5)至步骤(7);

(8) 获取全局最优值、全局最优位置,即得到最佳参数组合;

(9) 输出分类准确率,采用均方根误差 RMSE 和拟合度 R^2,评定模型的预测精度。

1.4 基于 PSO-SVM 放砂浓度稳定性预测模型建立的流程

针对尾砂仓储浓密机的底流放砂浓度稳定性,提出了浓密机外形和放砂参数的预测和优化框架:

(1) 确定优化目标和参数;

(2) 设计进行正交试验,生成初始样本集;

(3) 训练得到初始 SVR 预测模型;

(4) 利用混合加点法拓展样本点,不断更新迭代直到模型精度满足要求,得到最终的 SVR 预测模型;

(5) 根据实际应用场景确定参数的上下限,利用寻优算法,得到最优的参数组合方案。

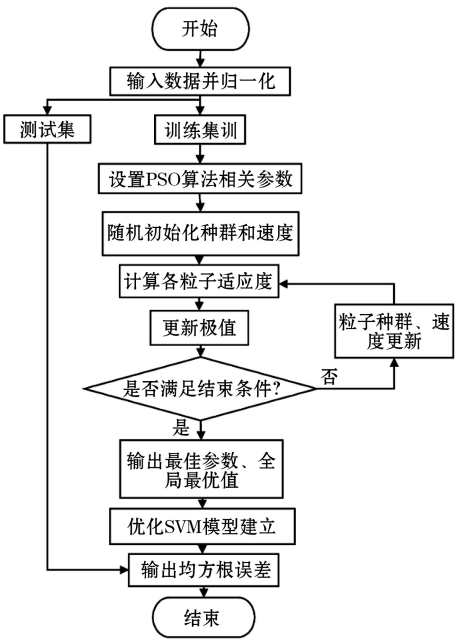


图 1 PSO-SVM 算法流程

Fig.1 PSO-SVM algorithm flowchart

2 PSO-SVM 放砂浓度稳定性预测模型建立

2.1 参数选择

建立放砂浓度稳定性预测模型所需的参数主要包括指标参数和特征参数。

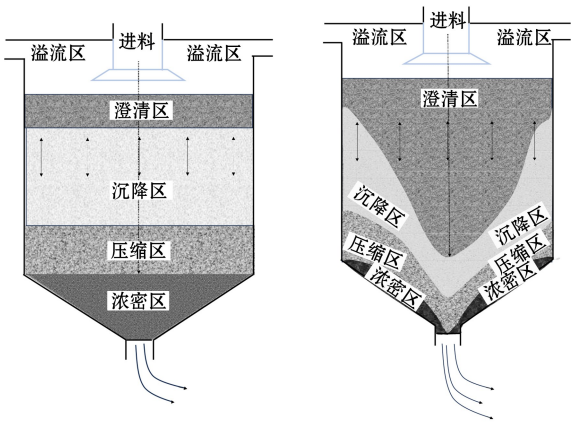
2.1.1 指标参数选择

进行动态连续进放砂浓密试验,记录数据,计算出底流质量浓度的标准偏差 σ,利用标准偏差 σ 的大小来反映尾砂仓储浓密机放砂浓度的稳定性。

2.1.2 特征参数

在最佳的尾砂进料浓度和絮凝剂添加状态下,深锥浓密机的外部结构参数(主要是高度和锥角)是影响底流浓度变化的主要因素。此外,浓密时间也是影响放砂浓度稳定性的关键因素。由于尾砂在澄清区和沉降区的时间可以忽略,可以认为浓密时间就是从尾砂到达临界压缩浓度开始到从排料口排出的时间[20]。图 2 为浓密机工作状态,从图中可以看出,如果放砂流量过大,入料料浆没有充分的时间絮凝沉降,就无法对浓密区进行及时补充,导致泥层失去平衡形成两边高、中间低的斜坡,锥部的料浆由于受高压出现板结,如图 2(b)所示。如果放砂流量过小,泥层高度不断升高导致底流浓度过高,底部料浆也可能出现板结,并且可能产生跑混的现象。

因此,选择尾砂仓储浓密机泥层高度、底部锥角、放砂浓度、放砂流量、浓密时间作为特征参数,建立尾砂仓储浓密机的底流浓度稳定性预测模型。



(a) 进出料平衡状态　　(b) 失稳状态

图 2　浓密机工作状态

Fig.2　Working condition of thickener

2.2　正交试验

根据选取的泥层高度 H、底部锥角 θ、放砂质量浓度 C_2、放砂流量 Q_2、浓密时间 t_x 等 5 个特征参数,设计 $L_{25}(5^5)$正交试验。划分因素水平见表 1,每组进行 7 h 的连续进放砂试验,对放砂浓度进行跟踪监测并计算底流浓度的标准偏差 σ。将正交试验的结果作为初始样本,见表 2。

表 1　正交试验因素水平

Table 1　Orthogonal test factor level

水平	泥层高度 H/m	放砂质量浓度 C_2/%	放砂流量 Q_2/(m³/h)	浓密时间 t_x/h	底部锥角 θ/(°)
1	10	64.5	84.7	6.1	0
2	12	65.0	83.5	6.3	30
3	14	66.0	81.4	7.1	45
4	16	67.0	79.3	8.0	60
5	20	67.5	78.2	8.4	70

表 2　正交试验数据

Table 2　Orthogonal test data

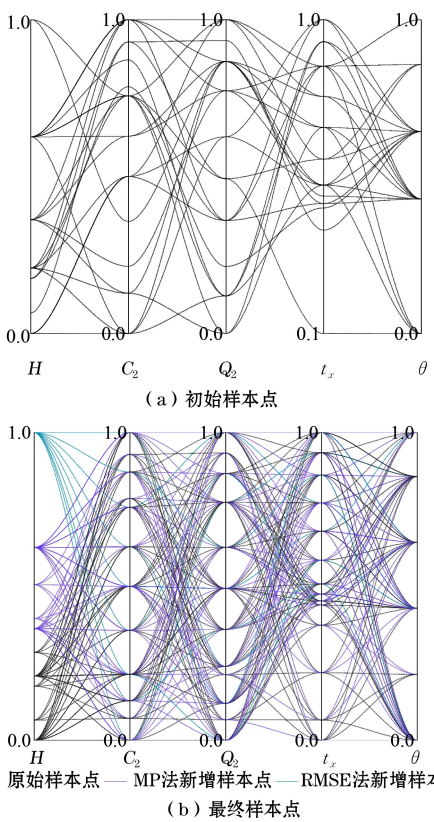
序号	泥层高度 H/m	放砂质量浓度 C_2/%	放砂流量 Q_2/(m³/h)	浓密时间 t_x/h	底部锥角 θ/(°)	标准偏差 σ
1	10	64.5	84.7	6.1	0	2.30
2	10	65.0	81.4	8.0	70	6.77
3	10	66.0	78.2	6.3	60	5.25
4	10	67.0	83.5	8.4	45	4.90
5	10	67.5	79.3	7.1	30	3.83
6	12	64.5	78.2	8.0	45	2.34
7	12	65.0	83.5	6.3	30	2.27
8	12	66.0	79.3	8.4	0	3.06
9	12	67.0	84.7	7.1	70	10.46
10	12	67.5	81.4	6.1	60	4.81
11	14	64.5	79.3	6.3	70	4.04
12	14	65.0	84.7	8.4	60	3.04
13	14	66.0	81.4	7.1	45	0.04
14	14	67.0	78.2	6.1	30	2.59
15	14	67.5	83.5	8.0	0	3.27
16	16	64.5	81.4	8.4	30	4.09
17	16	65.0	78.2	7.1	0	6.84
18	16	66.0	83.5	6.1	70	3.56
19	16	67.0	79.3	8.0	60	2.56
20	16	67.5	84.7	6.3	45	3.01
21	20	64.5	83.5	7.1	60	4.65
22	20	65.0	79.3	6.1	45	7.18
23	20	66.0	84.7	8.0	30	8.47
24	20	67.0	81.4	6.3	0	4.99
25	20	67.5	78.2	8.4	70	1.47

2.3　SVR 模型建立

2.3.1　更新样本点

建立高精度预测模型往往需要更大的样本数据,但由于设计参数多,试验时间长,且锥角参数受试验设备所限制,随机性较差。为获取更大的样本数据,采用混合加点法,逐步为初步样本引入新样本点,更新迭代模型,提高模型精度[21-22]。

图 3 为样本更新前后的对比图,可以看出,经过 6 次更新后的 SVR 模型,样本点由 25 个扩充到 106 个。



(a) 初始样本点

(b) 最终样本点

图 3　样本点示意

Fig.3　Sample point schematic

训练集的 R^2 由 0.845 增加到0.997,均方根误

差 *RMSE* 由 1.982 m/s 下降到 0.103 m/s,平均绝对误差 *MAE* 由 2.103 m/s 下降到 0.103 m/s;预测集的 R^2 由 0.327 增加到0.981,*RMSE* 由 2.513 m/s 下降到 0.143 m/s,*MAE* 由 2.984 m/s 下降到 0.079 m/s,模型精度得到大幅提高。

2.3.2 最终 SVR 模型

更新后建立的最终 SVR 模型获得了最佳参数及评估参数,见表 3,预测结果如图 4 所示。由图 4 可知,对于训练集,大部分样本相对误差在 0.5%之内,平均相对误差为 0.45%;对于预测集,大部分样本的相对误差在 3%之内,平均相对误差为 1.38%,预测精度较理想。

表 3 基于 RBF 的 SVR 模型最佳参数

Table 3 Best parameters of SVR based on RBF

C	γ	R^2	*RMSE*
66.53 1	7.902 9	0.981 1	0.143 5

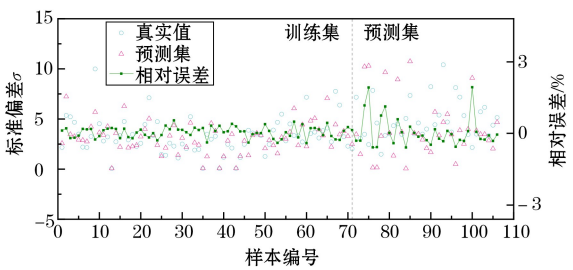


图 4 最终 SVR 模型的预测结果

Fig.4 The final prediction results of the SVR model

2.4 参数方差分析

探究各参数交互作用对 σ 的影响程度,对模型进行方差分析,*F* 值为组间均方与组内均方的比值,统计得到各参数 *F* 值的占比情况,如图 5 所示。由图 5 可知,SVR 模型中影响从大到小依次为泥层高度 *H*(贡献率为 28.1%),*H*、C_2、t_x 的联合作用(贡献率为 14.2%),C_2、Q_2 的联合作用(贡献率为 14.1%),C_2 的单独作用(贡献率为13.8%),Q_2 的单独作用(贡献率为 13.5%),剩余的贡献较小。

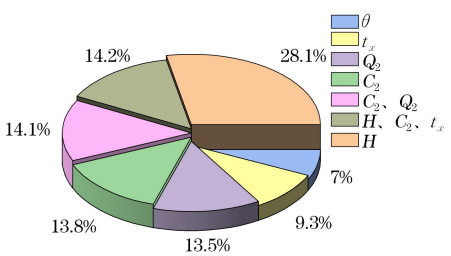


图 5 *F* 值占比分布

Fig.5 *F*-value percentage distribution

3 特征参数优化

3.1 优化问题描述

要获得连续稳定的底流,需要确定合理的浓密机泥层高度与锥角,并且平衡浓密时间与放料浓度、流量,以维持合理的泥层高度。优化问题可看作当优化变量的上下界为设计约束条件时,找到最优的参数,使放砂浓度的标准偏差 σ 达到最小值。优化变量的上下限确定步骤如下。

(1) 确定合理的放砂浓度 C_2。考虑料浆输送性能和充填体强度,设计浓密机的充填浓度范围。

(2) 计算确定合理的放砂流量 Q_2。

$$Q_2=\frac{W}{C_2\rho_2 st} \tag{9}$$

$$\rho_2=\frac{1}{\frac{C}{\rho_s}+1-C} \tag{10}$$

式中:Q_2 为放砂流量,m^3/h;*W* 为矿山的充填能力,t/d;*s* 为浓密机数量,台;*t* 为每天有效充填时间,h/d;ρ_s为砂浆的容重,t/m^3;ρ_2 为经过重力压缩后底流砂浆的密度,t/m^3;

(3) 确定合理的浓密时间 t_x。通过动态浓密试验,获得达到底流浓度 C_2 所需要的浓密时间 t_x。

(4) 确定合理的浓密机底部锥角 θ 和泥层高度 *H*。根据经验设计浓密机底部锥角 θ,并设计相应的动态浓密试验设备。忽略底部放砂锥桶的体积,将参数代入式(11)求得泥层高度 *H*。

$$H=\frac{V_x}{\pi D^2}+\frac{1}{3}D\tan\theta \tag{11}$$

$$V_x=\frac{4\rho_2 C_2 t_x Q_2}{(\rho_1+\rho_2)(C_1+C_2)} \tag{12}$$

式中:*D* 为通过动态浓密试验得到浓密机的设计直径,m;C_1 为临界压缩浓度;ρ_1 由式(9)求得,为临界压缩密度,t/m^3;V_x为浓密机的有效体积,m^3。

得到各优化变量的上下限,优化样本集为 $\boldsymbol{x}=\{x_1,x_2,\cdots,x_w\}$,其中包含的样本具有 *w* 维特征,样本经过 SVR 预测结果为 $T(\boldsymbol{x})$,进而优化问题可以描述为:

$$\begin{cases}\min\ S(\boldsymbol{x})=T(\boldsymbol{x}),\\ \text{s.t.}\quad \min\ \boldsymbol{x}_{w,\min}\leqslant\boldsymbol{x}_i\leqslant\boldsymbol{x}_{w,\max}\end{cases} \tag{13}$$

3.2 优化方法

文章采用 MultiStart 方法,对构建的 SVR 模型

进行全局寻优。MultiStart 方法是 MATLAB 提供的一种全局优化策略,通过从多个随机或系统生成的初始点出发进行多次局部优化,将所有局部极值点进行比较,可以有效避免陷入局部最小值,找到最值解即为全局最优解[23]。

4 工程实例

4.1 实例应用

东辛庄铁矿设计采用充填采矿法。充填系统设计年最大用尾砂总量为 86.19 万 t,最大日用尾砂量为2 611.78 t。在采用两台浓密机的情况下进行 24 h 连续作业,充填有效时间为 14 h,要求浓密机的尾砂处理能力不小于 93.28 t/h。由动态絮凝沉降试验结果,根据 Kynch 理论和 T-F 算法[24]计算,浓密机面积不小于 78.52 m^2,浓密机设计直径 $D=10$ m。

根据特征参数优化情况,确定设计参数取值范围见表 4。

表 4 特征参数取值范围

Table 4 Value range of characteristic parameters

参数	放砂质量浓度 C_2/%	浓密时间 t_x/h	放砂流量 Q_2/(m^3/h)	底部锥角 θ/(°)	泥层高度 H/m
下限	64.5	6.1	78.2	0	10
上限	67.5	8.4	89.4	70	20

进一步将优化问题描述为:

$$\begin{cases} \min T(\boldsymbol{x}),\boldsymbol{x}=\{C_2,t_x,Q_2,\theta,H\} \\ \text{s.t.}\quad 64.5\%\leqslant C_2\leqslant 67.5\% \\ 6.1\text{ h}\leqslant t_x\leqslant 8.4\text{ h} \\ 78.2\text{ m}^3/\text{h}\leqslant Q_2\leqslant 89.4\text{ m}^3/\text{h} \\ 0°\leqslant\theta\leqslant 70° \\ 10\text{ m}\leqslant H\leqslant 20\text{ m} \end{cases} \tag{14}$$

应用 MultiStart 方法对建立的 PSO-SVM 预测模型进行寻优,得到了优化方案下的参数优化结果,见表 5。从表中可以看出,优化方案中的最优参数下浓密机放砂浓度稳定性预测值为 0.821,说明料浆整体的浓度波动控制在±1.5%,能满足实际充填要求。由于优化方案是由模型寻优得到的最优方案,得到的参数精度较高,在实际工业应用时难以控制,因此将优化方案根据实际情况进行调整得到应用方案,确定应用方案为进行工业试验的放砂最优方案。根据应用方案,东辛庄铁矿最佳泥层高度 13.8 m,并根据经验取澄清区和沉降区高度为 2.2 m,最终设计浓密机外形参数为:桶高 16 m,直径 10 m,底部锥角 45°。

表 5 放砂方案

Table 5 Desanding programs

方案	泥层高度 H/m	放砂质量浓度 C_2/%	Q_2/(m^3/h)	锥角 θ/(°)	浓密时间 t_x/h	标准偏差 σ 预测值	标准偏差 σ 试验值
初始方案	14.50	67.00	90.00	45.0	6.10	—	2.78
优化方案	13.85	65.82	85.34	46.2	6.84	0.821	—
应用方案	13.80	66.00	85.00	45.0	6.80	—	0.81

4.2 试验结果分析

根据初始方案与应用方案分别进行 7 h 连续进放砂试验,每隔 10 min 取样并测量,记录料浆质量浓度大小,统计料浆质量浓度波动情况如图 6 所示。

由图 6 可知,根据初始方案进行放砂,由于泥层高度较高,最初放砂浓度较高,前 3 h 内充分的重力压缩,料浆浓度整体呈现上升趋势。3 h 之后由于浓密时间不足,放砂流量过大,浓密层砂浆的补充不足,浓度整体呈现下降趋势。由于泥层呈现不平衡状态,浓度波动大,致使底流砂浆不均匀,出砂状态见图 7(a),高浓度砂浆结团放出,因此在第 31, 34, 60 次取样时测量浓度陡增,而其余时间的料浆质量浓度偏低,大大影响了充填质量。该方案总体的放砂质量浓度波动在±5%,整体的放砂质量浓度标准偏差为 2.78。

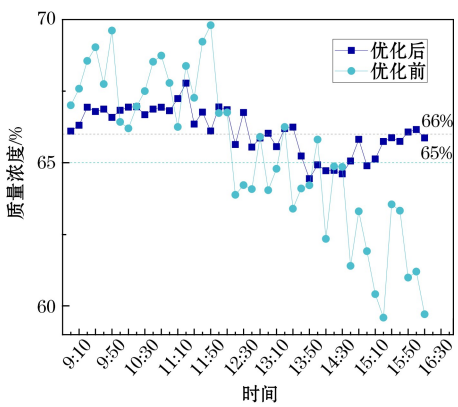


图 6 优化前后料浆质量浓度变化情况

Fig.6 The change of slurry mass concentration before and after optimization

在优化后的应用方案放砂条件下,由于前期的浓密压缩,料浆在前 3 h 浓度整体也呈现上升趋势,由于泥层高度合理,料浆最初放砂浓度适宜,前期料浆浓度并没有大幅度上升。3～5 h 的浓度整体呈

略微下降趋势,说明最初进入浓密机的料浆已经基本放出。由于浓密时间足够,放砂流量合理,浓密层的料浆得到适时补充,因此浓度波动控制在合理范围内,5 h 后料浆浓度呈现略微上升的趋势,又回到最初的放砂浓度。优化后的方案料浆稳定均匀出流,放砂状态如图 7(b)所示,总体料浆质量浓度波动控制在±1.5%,放出的砂浆连续均匀,出料稳定可靠,放砂浓度标准偏差为 0.81,放砂浓度稳定性大幅度提升。另外,将表 5 应用方案得到的浓度标准偏差试验值与表 5 优化方案的浓度标准偏差预测值进行对比,得到预测的相对误差仅 1.36%,说明 PSO-SVM 的预测结果较可靠。



(a) 优化前 (b) 优化后

图 7 优化前后放砂情况对比

Fig.7 Comparison of desanding before and after optimization

5 结论

(1) 基于 PSO 和 SVM 理论建立了尾砂仓储浓密机放砂浓度稳定性预测模型。在正交试验产生的初始样本构建的 SVR 模型的基础上,通过混合加点法更新模型,减小预测误差,提高模型预测精度。结果证实模型对于放砂浓度标准偏差预测效果良好,能有效用于浓密机放砂浓度稳定性的预测问题。

(2) 提出了浓密机稳定放砂的参数优化方法。根据高精度 SVR 模型,利用全局寻优算法,搜索最佳的放砂参数组合。结果表明,经优化后的放砂方案大大提高了放砂浓度的稳定性。

(3) 以东辛庄铁矿的尾砂仓储浓密机为例,开展了放砂浓度稳定性优化分析,得到最优的浓密机结构参数和放砂参数为:浓密机桶高 16 m,底部锥角 45°,泥层高度 13.8 m,满足浓密时间 6.8 h 后开始放砂,放砂流量为 85 m^3/h,优化后平均放砂质量浓度为 66%,料浆质量浓度波动控制在±1.5%,整体的放砂质量浓度标准偏差为 0.81。

(4) 在构建的 SVR 模型中,各个参数及其交互作用对放砂浓度稳定性有不同程度的影响,其中,泥层高度以及泥层高度、放砂浓度、浓密时间的联合作用对放砂浓度稳定性的影响最大。在进行放砂参数设计优化时应重点关注泥层高度的影响。

参考文献(References):

[1] 梁新民,刘明权,张爱民,等.无废、无尾生态智能矿山建设模式探讨[J].中国矿山工程,2022,51(2):66-71.
LIANG Xinmin, LIU Mingquan, ZHANG Aimin, et al. Discussion on construction model of waste-free, tailings-free, ecological and intelligent mine[J]. China Mining Engineering,2022,51(2):66-71.

[2] 蔚美娇,孔祥云,黄劲松,等.我国尾矿固废处置现状及建议[J].化工矿物与加工,2022,51(1):34-38.
WEI Meijiao, KONG Xiangyun, HUANG Jinsong, et al. Status of disposal of tailings as a solid waste and suggestions in China[J]. Industrial Minerals & Processing,2022,51(1):34-38.

[3] 朱起作,段庆豹,刘建国,等.高寒地区金属非金属矿山采空区充填技术研究[J].矿业研究与开发,2023,43(12):59-64.
ZHU Qizuo, DUAN Qingbao, LIU Jianguo, et al. Research on filling technology of goaf in metal and non-metal mines in alpine region[J]. Mining Research and Development,2023,43(12):59-64.

[4] 杨纪光,齐兆军,寇云鹏,等.某金矿充填用分级细尾砂浓密试验研究与应用[J].矿业研究与开发,2021,41(10):27-32.
YANG Jiguang, QI Zhaojun, KOU Yunpeng, et al. Thickening test and application of graded fine tailings for filling in a gold mine[J]. Mining Research and Development,2021,41(10):27-32.

[5] 王少勇,武鹏杰,张敏杰,等.不同进料流量下深锥浓密机给料井流场特性可视化试验研究[J].矿业研究与开发,2024,44(1):19-24.
WANG Shaoyong, WU Pengjie, ZHANG Minjie, et al. Visualization experimental study on flow field characteristics of deep cone thickener feedwell under different feeding flow rates[J]. Mining Research and Development,2024,44(1):19-24.

[6] 吴再海.淹没条件下分散射流对浓密板结料浆的扰动试验研究[J].有色金属工程,2023,13(6):124-132.
WU Zaihai. Experimental study on disturbance of dense slurry by dispersive jet in submerged environment[J]. Nonferrous Metals Engineering,2023,13(6):124-132.

[7] 李树磊,张杰.一种稳定均匀高浓度放砂技术在新城金矿的研发与应用[J].中国金属通报,2020(1):258+260.
LI Shulei, ZHANG Jie. Development and application of a stable and uniform high concentration sand release technology in Xincheng Gold Mine[J]. China Metal Bulletin,2020(1):258+260.

[8] 袁兆麟,何润姿,姚超,等.基于强化学习的浓密机底流浓度在线控制算法[J].自动化学报,2021,47(7):1558-1571.

YUAN Zhaolin, HE Runzi, YAO Chao, et al. Online reinforcement learning control algorithm for concentration of thickener underflow[J]. Acta Automatica Sinica, 2021, 47(7):1558-1571.

[9] 贾润达,李志奇,张树磊,等.基于混合整数线性规划的浓密脱水过程协调优化[J].控制与决策,2024,39(4):1281-1287.
JIA Runda, LI Zhiqi, ZHANG Shulei, et al. Coordinated optimization of thickening-dewatering process based on mixed integer linear programming[J]. Control and Decision, 2024,39(4):1281-1287.

[10] 吴爱祥,杨莹,王贻明,等.深锥浓密机底流浓度模型及动态压密机理分析[J].工程科学学报,2018,40(2):152-158.
WU Aixiang, YANG Ying, WANG Yiming, et al. Mathematical modelling of underflow concentration in a deep cone thickener and analysis of the dynamic compaction mechanism[J]. Chinese Journal of Engineering, 2018, 40(2):152-158.

[11] 王新民,张国庆,赵建文,等.深锥浓密机底流浓度预测与外部结构参数优化[J].重庆大学学报,2015,38(6):1-7.
WANG Xinmin, ZHANG Guoqing, ZHAO Jianwen, et al. Underflow concentration prediction and external structure parameter optimization of deep cone thickener[J]. Journal of Chongqing University,2015,38(6):1-7.

[12] 王勇,那庆,杨军,等.深锥浓密机泥层高度与压力关系研究[J].中国矿业大学学报,2022,51(2):257-262.
WANG Yong, NA Qing, YANG Jun, et al. Research on the relationship between mud height and pressure of deep cone thickener[J]. International Journal of Mining Science and Technology,2022,51(2):257-262.

[13] VAPNIK V N. The nature of statistical learning theory[J]. Springer,1995.

[14] 李召桐.支持向量机发展历程及其应用[J].信息系统工程,2024(3):124-126.
LI Zhaotong. Development history of support vector machines and their applications[J]. China CIO News,2024(3):124-126.

[15] 刘和平,郝辰伟,彭东东,等.基于粒子群优化极限学习机的煤层底板破坏深度预测[J].煤,2024,33(3):51-54.
LIU Heping, HAO Chenwei, PENG Dongdong, et al. Particle swarm optimization extreme learning machine bottom plate failure depth prediction[J]. Coal,2024,33(3):51-54.

[16] 代仕明,李敏,唐金良,等.基于粒子群优化的相关向量机算法的井震联合储层参数预测与不确定性评估[J].石油地球物理勘探,2023,58(6):1436-1445.
DAI Shiming, LI Min, TANG Jinliang, et al. Seismic and well logs integration for reservoir parameter prediction and uncertainty evaluation based on relevance vector machine optimized by particle swarm optimization[J]. Petroleum Geophysical Exploration,2023,58(6):1436-1445.

[17] 窦萌萌,程小辉.基于粒子群模糊 PID 的采煤机自动调高控制系统研究[J].煤炭技术,2024,43(1):241-244.
DOU Mengmeng, CHENG Xiaohui. Research on automatic height adjustment control system of shearer based on particle swarm fuzzy[J]. Coal Technology,2024,43(1):241-244.

[18] 赵任栋,孟宪营,刘永生,等.基于粒子群算法的矿山串级排水系统喂水泵调速技术研究[J].煤炭工程,2023,55(5):86-90.
ZHAO Rendong, MENG Xianying, LIU Yongsheng, et al. Booster pump speed regulation technology of mine cascade drainage system based on PSO[J]. Coal Engineering, 2023. 55(5):86-90.

[19] SHI Y H, EBERHART R C. Empirical study of particle swarm optimization [C]//Congress on Evolutionary Computation. Washington D.C:IEEE,2002.

[20] 王勇,吴爱祥,王洪江,等.深锥浓密机体积确定方法及其应用[J].中国矿业大学学报,2013,42(1):45-49.
WANG Yong, WU Aixiang, WANG Hongjiang, et al. A method to determine deep cone thickener volume and its application[J]. Journal of China University of Mining & Technology,2013,42(1):45-49.

[21] 李正良,彭思思,王涛.基于混合加点准则的代理模型优化设计方法[J].工程力学,2022,39(1):27-33.
LI Zhengliang, PENG Sisi, WANG Tao. A Surrogate-based optimization design method based on hybird infill sampling criterion[J]. Engineering Mechanics,2022,39(1):27-33.

[22] 刘睿,白俊强,邱亚松.基于非支配排序的并行加点方法研究及应用[J].北京航空航天大学学报,2023,49(6):1446-1459.
LIU Rui, BAI Junqiang, QIU Yasong. Research and application of parallel infill sampling method based on non-dominated sorting[J]. Journal of Beijing University of Aeronautics and Astronautics,2023,49(6):1446-1459.

[23] 梅真,张海龙,高毅超,等.基于改进遗传算法的磁流变阻尼半主动控制系统整体优化[J].湖南大学学报(自然科学版),2024,51(5):143-153.
MEI Zhen, ZHANG Hailong, GAO Yichao, et al. Integrated optimization of semi-active control system with magneto-rheological dampers based on an improved genetic algorithm [J]. Journal of Hunan University (Natural Sciences),2024,51(5):143-153.

[24] TALMAGE W P, FITCH E B. Determining thickener unit areas [J]. Industrial & Engineering Chemistry,1955,47(1):38-41.