

基于IDBO-RF模型的矿柱稳定性预测研究

谢成龙^{1,2,3}, 黄敏^{1,2,3}, 高忠^{1,2,3}, 李栋^{1,2,3}, 宋贤良^{1,2,3}, 温晨^{1,2,3}

(1. 低品位难处理黄金资源综合利用国家重点实验室; 2. 紫金矿业集团股份有限公司;
3. 紫金(长沙)工程技术有限公司)

摘要:为提高矿柱稳定性预测的精度,提出了一种改进的蜣螂优化算法(IDBO),用以优化随机森林(RF)分类预测模型。算法改进基于5方面:基于PWLCM混沌映射提升初始种群的质量;在滚球蜣螂位置更新中引入Levy随机游走策略,提高了算法的全局寻优能力;引入自适应边界控制因子权衡算法的全局搜索与局部开发能力,采用正余弦搜索策略改进偷窃蜣螂个体,改善其局部搜索能力,并执行基于混沌因子的越界处理策略,使算法在整个阶段保持种群多样性;采用基准函数进行测试,结果表明IDBO算法具有更强的搜索能力和鲁棒性;利用IDBO算法优化RF树的个数和最小叶子点数,建立IDBO-RF矿柱稳定性预测模型。基于实例分析与现有模型对比,IDBO-RF模型的预测精度达到了90%,预测性能、鲁棒性均优于其他模型。

关键词:矿柱稳定性;稳定性预测;改进蜣螂算法;随机森林;全局搜索;局部开发;预测精度

中图分类号:TD32

文献标志码:A

文章编号:1001-1277(2025)07-0066-06

doi:10.11792/hj20250710

引言

国内金属矿山开采多以空场采矿法为主^[1-2]。矿柱作为覆岩的主要承载结构,其状态直接关系到整个采场的稳定性。矿柱劣化极易引发采空区大面积坍塌,并伴随地表沉陷、矿震等次生灾害,对生产、人员及设备安全造成严重威胁^[3-5],因此准确预测矿柱稳定性具有重要意义。

目前,对于某一特定尺寸下矿柱的稳定性状态判定,常用的手段主要有现场调研、经验公式法、数值模拟及机器学习等。现场调研主要依靠人眼观察其破坏特征,具备一定的滞后性;经验公式法及数值模拟主要通过矿柱安全系数确定矿柱状态,但是经验公式的普适性较低及数值模拟的模型简化问题容易导致计算结果失真,预测精度显著下降。随着人工智能技术的发展,基于支持向量机、随机森林(RF)、BP神经网络等技术被应用于矿柱稳定性预测。罗辉等^[6]通过BP神经网络对矿柱稳定性状态进行分析,但是BP神经网络的精度与数据样本量成正比,且网络结构的选择需要耗费大量时间;ZHOU等^[7]建立了基于支持向量机的矿柱稳定性预测模型,虽然其泛化性好,但仅适用于二分类问题,且易受离群数据的影响;张文革等^[8]将强化学习与机器学习结合,建立了多算法融

合预测模型,然而由于数据不平衡问题,模型精度降低。因此,上述方法对基于存在误差的小样本矿柱稳定性预测问题适用性较低。随机森林由于其强抗干扰能力、优异的泛化性能被广泛应用于多分类问题^[9],但在矿柱稳定性预测领域应用较少。ZHOU等^[10]基于251个矿柱实例,测试了RF在矿柱稳定性的优越性能,但是超参数的选择对预测精度有较大影响;袁小庆等^[11]利用人工萤火虫优化算法,一定程度上提高了RF的分类准确性,但是该算法全局开发和局部探索能力存在一定不足。

蜣螂优化算法(DBO)因其具有搜索速度快、输入参数少等特点被用于RF超参数寻优^[12]。虽然DBO算法已经成功解决了一些类似工程问题,但是也表现出全局开发能力较弱、易陷入局部收敛问题。针对上述局限性,本文提出了一种改进蜣螂优化算法(IDBO)来解决传统DBO算法的不足。

综上,本文提出基于IDBO优化RF的矿柱稳定性预测模型。首先,基于多策略对蜣螂优化算法进行改进,通过IDBO算法对模型的超参数进行优化,以提高其泛化能力和预测精度。通过基准函数测试和实例分析,验证了IDBO算法的寻优能力及IDBO-RF矿柱稳定性预测模型的准确性和有效性。

收稿日期:2025-01-13; 修回日期:2025-02-25

基金项目:国家自然科学基金项目(51804079);福建省自然科学基金项目(2019J05039)

作者简介:谢成龙(1998—),男,助理工程师,硕士,从事采矿技术及机器学习方向的研究工作;E-mail:2412585161@qq.com

1 算法原理

1.1 传统蜣螂优化算法

DBO是一种基于蜣螂“滚球”“繁殖”“觅食”“偷窃”生物行为的元启发式算法。其中,滚球蜣螂、育雏蜣螂、小蜣螂、偷窃蜣螂4类个体的位置更新如式(1)~(4)所示。

$$Y_m(t+1) = \begin{cases} Y_m(t) + \varepsilon \varphi Y_m(t-1) + c |Y_m(t) - Y^w| \text{ rand} \leq \eta \\ Y_m(t) + \tan \theta \times |Y_m(t) - Y_m(t-1)| \text{ rand} > \eta \end{cases} \quad (1)$$

式中: t 为当前迭代次数; $Y_m(t)$ 为迭代 t 次时第 m 个个体的位置信息; ε 为自然系数因子; φ 为偏转系数,取值为 $(0, 0.2]$; c 为 $(0, 1)$ 的随机常数; Y^w 为全局最差个体位置信息; rand 为随机数; η 为行为选择概率; θ 为 $[0^\circ, 180^\circ]$ 中的一个随机角度,且当 θ 取 0° 、 90° 、 180° 时个体位置保持不变。

$$Y_i(m+1) = Y' + r_1 \cdot (Y_i(m) - LB') + r_2 \cdot (Y_i(m) - UB') \quad (2)$$

式中: Y' 为当前局部最优解; r_1 、 r_2 为 $1 \times D$ 的随机独立向量, D 为解的维度; UB' 、 LB' 分别为育雏蜣螂繁殖范围的上、下限。

$$Y_i(m+1) = Y_i(m) + C_1 \cdot (Y_i(m) - LB'') + C_2 \cdot (Y_i(m) - UB'') \quad (3)$$

式中: C_1 为服从标准正态分布的随机向量,大小为 $1 \times D$; C_2 为 $1 \times D$ 的随机向量,为 $[0, 1]$; UB'' 、 LB'' 分别为小蜣螂觅食范围的上、下限。

$$Y_i(m+1) = Y^B + S \times g \cdot (|Y_i(m) - Y'| + |Y_i(m) - Y^B|) \quad (4)$$

式中: Y^B 为全局最优解; S 为常数; g 为大小为 $1 \times D$ 的符合标准正态分布的随机向量。

式(2)、式(3)中的繁殖范围、觅食范围与边界线性控制因子 R 有关:

$$R = \frac{1-t}{\text{Max_iter}} \quad (5)$$

式中: Max_iter 为最大迭代次数。

1.2 随机森林分类

随机森林是一种基于决策树的集成学习算法。其主要利用有放回的抽样方法抽取 l 个样本进行训练,并利用抽取样本建立 l 棵决策树模型,获得 l 个分类结果;最后根据分类结果进行投票确定最终分类,其具有计算速度快且兼具鲁棒性的特点,但有时会出现过拟合现象。

2 改进的蜣螂优化算法

2.1 PWLCM混沌初始化

初始种群质量对算法的运行至关重要,良好的种群分布可以避免算法陷入局部最优^[13]。本文为了提升初始解的质量,采用混沌序列映射至解空间产生初始化种群。目前,主要的混沌序列生成方法包括:Tent映射^[14]、Logistic映射^[15]、PWLCM映射^[16]及Gaussian映射^[17]等。将上述几种映射迭代5 000次后其混沌值分布如图1所示。

由图1可知:上述4种混沌映射均具有遍历性。其中,PWLCM映射序列的分布最均匀且分散程度高,Logistic映射序列的混沌值在 $[0, 0.05]$ 、 $(0.95, 1]$ 分布更为密集。因此,为了保证初始解的质量,采用PWLCM混沌序列映射至解空间进行种群初始化。PWLCM映射如式(6)所示。

$$Z_{k+1} = \begin{cases} Z_k/p & Z_k \in [0, p) \\ (Z_k - p)/(0.5 - p) & Z_k \in [p, 0.5) \\ (1 - p - Z_k)/(0.5 - p) & Z_k \in [0.5, 1 - p) \\ (1 - Z_k)/p & Z_k \in [1 - p, 1) \end{cases} \quad (6)$$

式中: Z 为混沌序列的某个混沌值, $Z_1 = \text{rand}$; k 为混沌序列的迭代次数; p 为控制参数,取0.4。

2.2 Levy随机步长游走机制

传统的DBO算法在全局搜索中采用直线搜索方式,其搜索能力受到一定限制。本文引入Levy随机步长游走机制,滚球蜣螂遇到障碍物不再通过跳舞重新调整方向,而是进行Levy随机游走,这一改进能够允许算法在全局寻优时进行偶尔的大步游走^[18],避免局部最优,改进后滚球蜣螂位置更新如式(7)所示。

$$Y_m(t+1) = \begin{cases} Y_m(t) + \varepsilon \varphi Y_m(t-1) + c |Y_m(t) - Y^w| \text{ rand} \leq \eta \\ Y_m(t) + \delta \text{ Levy}(D) \cdot (Y_m(t) - Y_m(t-1)) \text{ rand} > \eta \end{cases} \quad (7)$$

式中: δ 为步长缩放因子; Levy 为Levy飞行步距。

2.3 自适应边界控制因子

原始的DBO算法采用一种线性控制的边界策略来限制育雏蜣螂和小蜣螂的育雏及觅食范围,但仅用线性参数调节全局开发和局部搜索的效果欠佳。为了能动态调节对全局和局部最优解的接受程度,本文引入一种自适应边界控制因子对控制因子 R 进行改进。改进后的育雏蜣螂和小蜣螂繁殖、觅食范围的控制因子变为:




图1 混沌映射分布图

Fig. 1 Distribution map of chaotic projection

$$R' = 1 - 0.5 \sin(t/\text{Max_iter})^3 \times \pi \quad (8)$$

2.4 融合正余弦搜索的局部搜索改进

为了提高DBO算法的局部搜索能力,在原小偷蜉螂的位置更新中引入正余弦优化算法的循环模式,使得能够更高效地对其周围空间进行开发。融合正余弦搜索的小偷蜉螂位置更新如式(9)所示。

$$Y_m(t+1) = \begin{cases} Y^B + \gamma_1 \sin \gamma_2 \times |\gamma_3 Y_m(t) - Y'| + \gamma_1 \sin \gamma_2 \times |\gamma_3 Y_m(t) - Y^B| & \text{rand} \leq 0.5 \\ Y^B + \gamma_1 \cos \gamma_2 \times |\gamma_3 Y_m(t) - Y'| + \gamma_1 \cos \gamma_2 \times |\gamma_3 Y_m(t) - Y^B| & \text{rand} > 0.5 \end{cases} \quad (9)$$

式中: γ_1 为平衡因子; γ_2 为随机数,且 $\gamma_2 \in [0, 2\pi]$; γ_3 为随机权值,且 $\gamma_3 \in [0, 2]$ 。

2.5 基于混沌因子的越界处理

当个体存在越界行为时,DBO算法以搜索空间的边界取代越界位置,导致个体在边界附近大量集中,种群多样性相应减小。因此,引入混沌因子对越界个体进行处理,使其有几率在解的空间内随机生成,具体为:

$$A_{\text{new}} = \begin{cases} LB + (UB - LB) \times \text{chaos} & p \geq \text{pro} \\ \{\min(A, UB) \max(A, LB)\} & p < \text{pro} \end{cases} \quad (10)$$

式中: A 为存在越界行为的个体; chaos 为混沌因子,由式(6)确定; A_{new} 为执行越界策略后的个体。

2.6 算法复杂度分析

算法的运行时长是判断其性能的重要指标,主要取决于适应度函数的计算次数。假设种群数目为 pop ,最大迭代次数为 T ,则DBO算法的复杂度为 pop (初始化)+ $\text{pop} \times T$ (种群更新阶段)。对于IDBO算法,初始化阶段适应度函数的计算次数为 pop ,种群更新位置时适应度函数的计算次数仍然为 $\text{pop} \times T$,边界改进未增加多余的计算次数,总复杂度为 pop (初始化)+ $\text{pop} \times T$ (种群更新阶段),故算法改进前后计算次数不变,复杂度不变。

3 仿真试验结果与分析

采用23个基准函数中的 $F1 \sim F15$ ^[19]验证IDBO算法性能,参照原始DBO算法^[12]的推荐参数进行设置。为保证测试结果的准确性,分别运行30次,统计平均值,并对目标基准函数找到的最优值进行加粗。运行软件为Matlab R2022a,CPU为AMD Ryzen 7 6800H

with Radeon Graphics,测试结果如表 1 所示。

表 1 基准函数测试结果

Table 1 Benchmark function test results

基准函数	IDBO 算法	DBO 算法
<i>F1</i>	0	2.02×10^{-104}
<i>F2</i>	0	1.51×10^{-55}
<i>F3</i>	0	1.37×10^{-80}
<i>F4</i>	0	7.54×10^{-56}
<i>F5</i>	23.306 79	25.732 26
<i>F6</i>	2.41×10^{-5}	3.9×10^{-4}
<i>F7</i>	8.44×10^{-5}	1.398×10^{-3}
<i>F8</i>	-12 512.17	-8 859.05
<i>F9</i>	0	0
<i>F10</i>	4.44×10^{-16}	8.88×10^{-16}
<i>F11</i>	0	0
<i>F12</i>	6.97×10^{-7}	5.53×10^{-7}
<i>F13</i>	0.009 8	0.593 74
<i>F14</i>	0.998 0	1.064 27
<i>F15</i>	3.1×10^{-4}	6.89×10^{-4}

F1 ~ *F7* 为典型的单峰函数,即仅存在一个全局最优解。由表 1 中 *F1* ~ *F7* 的测试结果可知:DBO 算

法对 *F1* ~ *F4* 的平均最优适应度值等于理论最优值,*F6*、*F7* 的计算值低于 DBO 算法 1 ~ 2 个数量级;对于多峰函数 *F8* ~ *F13*、固维函数 *F14* ~ *F15*,2 种算法均获得了 *F9*、*F11* 的理论最优解,DBO 算法在 *F12* 的表现上优于 IDBO 算法,但差别极小,对于测试函数 *F8*、*F10*、*F13*、*F14*、*F15*,IDBO 算法的测试值更接近于理论最优值。总体而言,多策略的相互融合协作作用,使算法的寻优表现得到了全面提升。

4 基于 IDBO-RF 的矿柱稳定性预测模型构建

4.1 数据集收集

本研究从已发表的文献[20-29]中共收集了 189 个矿柱稳定性数据,主要特征包括矿柱宽度、高度、宽高比、单轴抗压强度、矿柱载荷等。定义破碎严重剥落、接缝存在明显开裂、裂隙宽度大于 10 mm 的矿柱为失效矿柱;矿柱内部发育过程中存在开裂,钻孔变形的矿柱为不稳定矿柱;轻微剥落、无接缝开口、无应力致裂现象的矿柱为稳定矿柱。其中,稳定矿柱、不稳定矿柱、失效矿柱分别编码为 1,2,3。将数据集在 Excel 中进行随机打乱,按照 8:2 的比例划分训练集和测试集,部分原始数据集如表 2 所示。

表 2 部分原始数据集

Table 2 Part of the raw dataset

样本编号	矿柱宽度/m	矿柱高度/m	矿柱宽高比	单轴抗压强度/MPa	矿柱载荷/MPa	矿柱稳定性
1	15	7	2.14	215	29	1
2	18	4	4.5	72	48	1
3	1.9	3.8	0.5	94	58	3
4	30	40	0.75	176	29	1
5	6.3	4	1.58	172	93.5	3
6	2.3	3.8	0.6	94	48	3
7	5.3	4	1.33	172	91.8	3
8	4.6	2.7	1.67	210	72.4	1
9	12.8	7.3	1.73	160	17.4	3
10	12.5	15.2	0.82	160	17.8	3
11	5.3	3.8	1.4	94	48	2
12	3	3	1	210	78.6	2
13	6.1	2.4	2.5	210	54.5	1
14	5.1	4	1.28	172	63.8	2
15	6.1	38	1.6	94	35	1
16	4.6	4	1.15	172	70.8	2
...	...	...	...	...	...	...
181	2.9	38	0.76	94	50	3
182	21	39	0.54	176	26	1
183	6.1	5.5	1.11	210	26.2	1
184	4	2.5	1.6	89	1.1	1
185	11	23	0.48	316	99	3
186	3.5	2.8	1.25	42	11.6	1
187	11	20	0.55	121	69	3
188	10.7	18.3	0.58	215	12.8	3
189	3	3.8	0.8	94	54	2

4.2 模型运行结果分析

为了兼顾运算速度和运行精度,设定种群数为30,滚球蛭螂、育雏蛭螂、小蛭螂、偷窃蛭螂的比例为1:1:1:2;最大迭代次数70;行为选择概率 η 为0.9。采用预测精度作为评价指标,运行IDBO-RF模型,得到树的个数和最小叶子点数分别为157.977 3,1.583 8,经计算,IDBO-RF模型对于稳定、不稳定、失效矿柱的识别精度分别为100 %、66.7 %、94.7 %,平均精度为90 %,其对于不稳定矿柱的识别精度较低;这可能是由于数据库中不稳定矿柱数量较少及界定误差引起的,需进一步丰富数据集中不稳定矿柱的样本数目。具体结果如图2所示。




图2 IDBO-RF矿柱稳定性预测模型

Fig. 2 IDBO-RF pillar stability prediction model

4.3 不同模型运行结果分析

为了进一步验证IDBO-RF模型的预测性能,使用同一数据集在RF模型上进行计算,测试结果如图3所示。




图3 RF矿柱稳定性预测模型

Fig. 3 RF pillar stability prediction model

从图3可以看出:RF模型预测稳定、不稳定、失效矿柱的精度分别为94.7 %、56 %、89.5 %,平均精度82.5 %。上述2种模型对比结果表明:IDBO-RF模型的预测精度提高了7.5 百分点,且对于矿柱的3种状态预测更具优势,可见IDBO算法能够有效提升RF模型的预测精度。

为了横向对比IDBO-RF模型在矿柱稳定性预测的优势,与前人提出的模型进行对比,结果如表3所示。

表3 现有的矿柱稳定性预测模型

Table 3 Existing pillar stability prediction models

模型	预测精度/%			平均精度/%	训练集:测试集	备注
	稳定矿柱	不稳定矿柱	失效矿柱			
FDA ^[5]	50		100	83	9:1	
SVMs ^[5]	100		100	100	9:1	样本数46
GPC ^[26]	75		100	90	8:2	
SVM ^[27]	96	21	96	85	7:3	
GWO-SVM ^[27]	98	57	100	87	7:3	
IDBO-RF	100	66.7	94.7	90	8:2	

从表3可以看出:SVMs的矿柱稳定性预测精度最高,但其将矿柱仅分为稳定与失效2种状态是不合理的;FDA对于稳定矿柱的预测精度最低,同时训练集与测试集的比例应取8:2或7:3为宜^[30];对于三分类的模型,3种模型均取得了满意的预测效果。其中,本文提出的IDBO-RF模型预测精度最高,SVM对于不稳定矿柱的预测精度较差,GWO对SVM寻优后的预测精度得到显著提高。综上,RF可作为矿柱稳定性预测的有效手段,IDBO对RF的超参数寻优表现较好,具备一定的工程应用价值。

5 结 论

1)PWLCM混沌初始化种群、Levy随机步长游走、自适应边界控制等策略,有效提高了原始DBO算法的搜索能力、鲁棒性。

2)通过IDBO算法对RF模型的超参数进行寻优,建立了IDBO-RF矿柱稳定性预测模型,为矿柱稳定性预测提供了一种新方法。

3)测试结果表明,IDBO-RF模型对矿柱稳定性的预测精度达到了90 %,相较于原始RF模型及现有模型更具优势,具备一定的工程应用价值,但仍需进

一步丰富数据库中不稳定矿柱的样本以提高模型的预测精度。

参考文献

- [1] 蔡鑫,黄涯帅,周子龙,等.基于矿柱失稳风险分析的采空区关键矿柱重定义与辨识[J].岩石力学与工程学报,2024,43(1):216-225.
- [2] 朱万成,董航宇,刘溪鸽,等.金属矿山多矿柱承载与失稳破坏研究[J].采矿与岩层控制工程学报,2022,4(4):5-31.
- [3] 张宏荣,张纯锋,付琛,等.丰山铜矿北缘试验采场稳定性研究[J].黄金,2024,45(8):64-67,80.
- [4] 王长军,卢磊芬,秦仕文,等.三贵口铅锌矿矿柱回收对地表沉降影响研究[J].中国矿业,2024,33(3):168-176.
- [5] 何玉龙,王栋毅,李海龙.BMS微震监测系统在深部岩体稳定性监测中的应用[J].黄金,2024,45(4):5-8,17.
- [6] 罗辉,杨仕教,陶干强,等.基于FEM-ANN-MCS动态模糊可靠度的矿柱稳定性分析[J].煤炭学报,2010,35(4):551-554.
- [7] ZHOU J, LI X, SHI X, et al. Predicting pillar stability for underground mine using fisher discriminant analysis and SVM methods [J]. Transactions of Nonferrous Metals Society of China, 2011, 21(12): 2734-2743.
- [8] 张文革,董陵军,王加闯,等.基于机器学习算法及Stacking融合集成模型的矿柱稳定性分析[J].金属矿山,2023(10):67-74.
- [9] 郭慧,刘明艳.基于遗传算法和随机森林的入侵检测方法研究[J].计算机应用与软件,2024,41(1):304-309,314.
- [10] ZHOU J, LI X B, MITRI HANI S. Comparative performance of six supervised learning methods for the development of models of hard rock pillar stability prediction [J]. Natural Hazards, 2015, 79(1): 291-316.
- [11] 袁小庆,吴涛,原勋,等.基于GSO-RF意图识别算法的全身助力外骨骼控制方法研究[J].机械工程学报,2024,60(17):91-101.
- [12] XUE J, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization [J]. The Journal of Supercomputing, 2022:1-32.
- [13] 黄元春,张凌波.改进的鲸鱼优化算法及其应用[J].计算机工程与应用,2019,55(21):220-226,270.
- [14] 游达章,刘珊,张业鹏,等.基于IWOA-ELM的模拟电路故障诊断方法[J].仪表技术与传感器,2024(2):104-110.
- [15] 汪洋,陈俊杰,谢梦雨,等.基于LCASO-BPNN模型的单质硫溶解度预测[J].化学工程,2023,51(12):56-61.
- [16] 田军锋,彭静静,左宪禹,等.基于循环移位和多混沌映射的图像加密算法[J].计算机科学,2020,47(10):327-331.
- [17] 肖义平,赵云峰.基于混沌映射和高斯扰动的改进粒子群算法MPPT控制策略研究[J/OL].电源学报,1-13[2024-12-11].
http://kns.cnki.net/kcms/detail/12.1420.TM.20230224.0938.002.html.
- [18] 印雷,顾德,刘飞.基于改进麻雀搜索算法优化的DV-Hop定位算法[J].传感技术学报,2021,34(5):670-675.
- [19] XIN Y, YONG L, GUANGMING L. Evolutionary programming made faster [J]. IEEE Transactions on Evolutionary Computation, 1999, 3(2):82-102.
- [20] LUNDER P J. Hard rock pillar strength estimation an applied empirical approach [J]. Vancouver: University of British Columbia, 1961.
- [21] VON KIMMELMANN M R, HYDE B, MADGWICK R J. The use of computer applications at BCL Limited in planning pillar extraction and the design of mining layouts [C] // British Geotechnical Association. Design and performance of underground excavations. London: British Geotechnical Association, 1984:53-63.
- [22] SJOBERG J S. Failure modes and pillar behaviour in the Zinkgruvan mine [C] // American Rock Mechanics Association. Proceedings of the 33rd U. S. symposium on rock mechanics. Alexandria: American Rock Mechanics Association, 1992:491-500.
- [23] ESTERHUIZEN G S, DOLINAR D R, ELLENBERGER J L. Pillar strength in underground stone mines in the United States [J]. International Journal of Rock Mechanics and Mining Sciences, 2011, 48(1):42-50.
- [24] POTVIN Y, HUDYMA M, MILLER H. Rib pillar design in open stope mining [J]. CIM BULLETIN, 1989, 82(927):31-36.
- [25] HEDLEY D G F, GRANT F. Stope-and-pillar design for the Elliot lake uranium mines [J]. Bull Can Inst Min Metall, 1972, 65:37-44.
- [26] 赵国彦, 刘建. 基于高斯过程机器学习算法的矿柱稳定性分析[J]. 安全与环境学报, 2017, 17(5): 1725-1729.
- [27] 刘小春, 张小瑞, 刘博. 三鑫金铜矿保安矿柱回收合理充填体强度研究[J]. 黄金, 2024, 45(4): 13-17.
- [28] LI C, ZHOU J, DU K, et al. Stability prediction of hard rock pillar using support vector machine optimized by three metaheuristic algorithms [J]. International Journal of Mining Science and Technology, 2023, 33(8): 1019-1036.
- [29] SAMUI P, KIM D, SITHARAM T G. Support vector machine for evaluating seismic-liquefaction potential using shear wave velocity [J]. Journal of Applied Geophysics, 2011, 73(1):8-15.
- [30] 吴志波, 刘佳鹏, 徐敬元, 等. 基于自组织神经网络与元启发式算法的地表爆破振动预测方法[J]. 黄金, 2024, 45(11): 69-74.

Research on pillar stability prediction based on IDBO-RF model

Xie Chenglong^{1,2,3}, Huang Min^{1,2,3}, Gao Zhong^{1,2,3}, Li Dong^{1,2,3}, Song Xianliang^{1,2,3}, Wen Chen^{1,2,3}

(1. State Key Laboratory of Comprehensive Utilization of Low-grade Refractory Gold Ores;
2. Zijin Mining Group Co., Ltd.; 3. Zijin (Changsha) Engineering Technology Co., Ltd.)

Abstract: To improve the accuracy of pillar stability prediction, an improved scarab optimization algorithm (IDBO) is proposed to optimize the random forest (RF) classification prediction model. The improvement is based on 5 aspects: using PWLCM chaotic mapping to enhance the quality of the initial population; introducing Levy random walk strategy in the rolling scarab position update to improve the global optimization ability of the algorithm; introducing an adaptive boundary control factor to weigh the global search and local development ability of the algorithm, and using a cosine-sine search strategy to improve the individual of the stealing scarab, enhancing its local search ability, and executing an out-of-bound handling strategy based on chaotic factors to maintain population diversity throughout the process; using benchmark functions for testing, which shows that the IDBO algorithm has stronger search ability and robustness; utilizing the IDBO algorithm to optimize the number of RF trees and the minimum number of leaf nodes, establishing the IDBO-RF pillar stability prediction model. Based on case analysis and comparison with existing models, the prediction accuracy of the IDBO-RF model reaches 90 %, and its prediction performance and robustness are superior to other models.

Keywords: pillar stability; stability prediction; improved scarab algorithm; random forest; global search; local development; prediction accuracy