

定性与定量信息相结合预测金品位的方法研究

梁智霖¹, 郭攀²

(1. 河南卫生健康干部学院, 河南 郑州 450000;
2. 郑州大学 水利与交通学院, 河南 郑州 450000)

摘要:将改进云模型和改进 RBF 神经网络相结合, 提出了一种预测矿石中金品位的模型。先利用 DS 证据理论和云模型将定性信息量化, 再采用量子粒子群算法和 RBF 神经网络完成矿石中金品位预测。结果表明: 该模型的均方根误差为 0.009 2, 最大误差为 0.016 1, 相关系数为 0.940 2, 可较好保留定性信息特性, 金品位预测效果较好。

关键词:金; 品位; 预测; 模型; 定性信息; 定量信息; 云模型; RBF 神经网络

中图分类号: TF803.21 **文献标识码:** A **文章编号:** 1009-2617(2024)02-0195-06

DOI: 10.13355/j.cnki.sfyj.2024.02.014

从矿石中湿法提金过程中, 一些重要变量信息无法在线测定, 可通过建立预测模型解决^[1-3]。目前, 矿石中金品位预测方法的相关研究大多以定量信息为基础, 而对于定性信息的分析存在不足。定量信息的建模方法主要有 RBF 神经网络、支持向量机。RBF 神经网络在定量信息建模中的最大相对误差为 2.46%, 但其训练需大量参数, 且参数的选择对结果影响较大^[4]; 支持向量机在定量信息建模中最大相对误差为 3.48%, 但其对高维度、大样本预测效果较差^[5]。定性信息的建模方法主要有案例推理和模糊规则。案例推理在定性信息建模中, 可结合历史数据和专家经验将典型的工况转换为案例形式, 但其案例修正规则难以获取^[6]; 模糊规则在定性信息建模中可将不确定参数看作模糊数, 但定性信息在实际应用中无法满足上述条件^[7]。云模型在信息转换中可较好地保留定性信息的随机性和模糊性, 但会出现多专家评估情况, 须再通过 DS 证据理论对多个专家信息进行融合, 过程较为复杂^[8]。针对某低品位矿石湿法提金工艺, 研究建立了一种可预测金品位的改进云模型-改进 RBF 神经网络模

型, 主要利用云模型和 DS 证据理论对定性信息量化, 之后通过改进量子粒子群算法(QPSO)和 RBF 神经网络完成定量信息的金品位预测。

1 影响金品位的信息分析

某低品位矿石湿法提金生产工艺的主要工序为浸出和离子交换。对这 2 个工序中所涉及影响因素信息进行分析筛选, 包括可测定定量信息、由经验得到的定性信息, 以及一些无法获取的信息^[9-12], 从而得到对金品位影响较大的变量作为建模的辅助变量, 结果见表 1。

2 融合定性和定量信息的金品位预测模型的建立

针对目前金品位预测方法无法有效利用定性信息导致预测效果较差的问题, 提出了改进云模型和改进 RBF 神经网络相结合的金品位预测模型。结合 DS 证据理论和云模型将定性信息量化, 再用 RBF 神经网络融合 QPSO 算法完成定量信息的金品位预测。预测模型结构如图 1 所示。

收稿日期: 2023-11-09

第一作者简介: 梁智霖(1987—), 男, 硕士, 讲师, 主要研究方向为数学建模。

通信作者简介: 郭攀(1985—), 男, 博士, 高级工程师, 主要研究方向为结构无损检测及数学建模。E-mail: guopan@zzu.edu.cn。

表 1 建模的辅助变量

编号	变量名称	过程	信息划分
1	矿浆添加量		定性
2	矿浆浓度		定性
3	初始金品位	一段浸出	定性
4	氰化钠添加量		定量
5	溶解氧浓度		定量
6	矿浆添加量		定性
7	矿浆浓度		定性
8	初始金品位	二段浸出	定性
9	氰化钠添加量		定量
10	溶解氧浓度		定量
11	锌粉添加量		定性
12	液金品位	离子交换	定量
13	出口压力		定量
14	贵液流量		定量




图 1 结合定性和定量信息的金品位预测模型结构

2.1 定性信息量化

首先通过云模型将定性信息量化,云模型具有期望、熵和超熵 3 个重要特征,可先将定性信息表示为期望、熵、超熵,之后用云发生器算法产生云滴形成云。在多个专家参与定性信息估计时,通过 D-S 证据理论对估计信息进行融合,以提高描述的准确性。具体步骤为:1)利用 D-S 证据理论融合专家信息,构建云尺度;2)判断需要变换定性信息等级;3)根据级别进入对应的云标尺;4)生成一组云滴;5)输入逆向云发生器,输出定性期望即定量结果。定量信息量化流程如图 2 所示。

2.2 定量信息预测

RBF 神经网络是前馈神经网络(包括隐含层),一些研究结果^[13-18]表明,作为局部近似网络的典型,RBF 神经网络可以任何精度逼近任一目标函数。图 3 为 RBF 网络结构。

采用高斯函数作为隐含层的基函数,如式(1)所示。

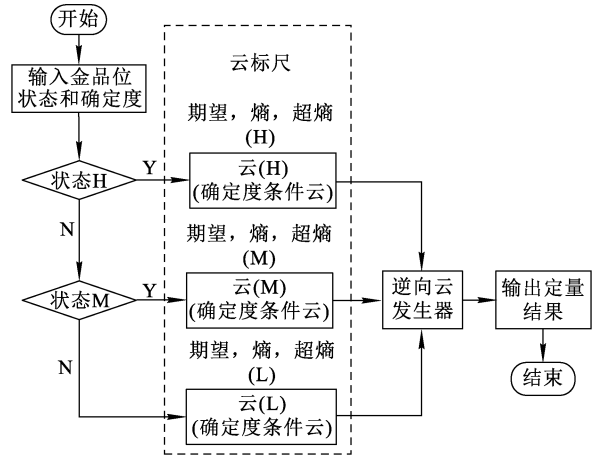


图 2 定量信息量化流程




图 3 RBF 网络拓扑

$$R_i(x) = \exp\left(-\frac{\|x - c_i\|}{2\sigma_i^2}\right), i = 1, 2, \dots, m \quad (1)$$

式中: x 、 c_i —网络输入、中心; m —隐含层神经元数; σ_i —高斯函数宽度。

最终输出结果如式(2)所示。

$$Y(x) = \sum_{i=1}^m \omega_i R_i \quad (2)$$

式中: ω_i —权值; $Y(x)$ —输出结果。

但其训练需大量参数,且参数的选择对其影响较大。因此,通过改进 QPSO 算法寻优 RBF 神经网络权重、中心和基宽等参数。与常规方法(如 PSO 算法)相比,QPSO 算法的泛化能力和优化精度等都具有一定优越性,为了提高其性能,对 QPSO 算法进行了改进。

1) 位置优化

首先根据粒子适应值对其进行排序,然后为各粒子分配权重系数 γ_i ,在已建立的最小化模型下,粒子适应值越低,分配权重系数越大,从 1.0 到 0.5 线性下降,之后引入加权思想进一步加以

优化,平均粒子历史最优位置 m_{best} 计算公式如式(3)所示。

$$m_{best}(t) = \sum_{i=1}^N \frac{\gamma_i P_i(t)}{N} \quad (3)$$

式中: γ_i — 粒子 i 权重系数; N — 粒子维数。

粒子的位置更新如式(4)所示。

$$X_i(t+1) = P_i(t) \pm \alpha \left| \sum_{i=1}^N \frac{\gamma_i P_i(t)}{N} - X_i(t) \right| \ln\left(\frac{1}{u_i(t)}\right) \quad (4)$$

式中: $P_i(t)$ — 粒子 i 的个体最优位置; α — 缩扩系数。

2) 权重自适应优化

通过平均适应度 f_{avg} 对其进行划分,适应度值大于 f_{avg} 时,权重逐渐降低,加快收敛,适应度值小于 f_{avg} 时,权重逐渐上升,加强搜索能力。如式(5)所示。

$$\omega = \begin{cases} \omega + \frac{t \times (\omega_{max} - \omega)}{t_{max}}, & f < f_{avg} \\ \omega - \frac{t \times (\omega_{max} - \omega)}{t_{max}}, & f \geq f_{avg} \end{cases} \quad (5)$$

改进 QPSO-RBF 预测模型预测步骤为:1)对获取信息进行预处理。2)对改进 QPSO 参数进行初始化,随机设定一组位置和速度。3)将 RBF 神经网络参数转换到改进 QPSO 算法的粒子位置坐标;通过改进 QPSO 算法寻优 RBF 神经网络权重、中心和基宽等参数;将均方根误差作为适应度计算函数。4)输入训练集进行训练,当达到终止条件(精度和迭代次数),优化过程结束,否则转到步骤 2)。5)输入测试集进行预测模型测试,输出测试集预测结果。预测模型流程如图 4 所示。

3 模型预测效果分析

3.1 试验参数设置

为验证模型的优越性,在 Windows 操作系统下,从某湿法提金工艺信息中选出具有代表性信息共 1 500 组,其中包括定性信息不变样本 500 组、定性信息有较小程度变化样本 500 组、定性信息有大程度变化样本 500 组。将信息划分为训练集、验证集、测试集,占比为 7 : 1 : 2。为确保精度,多次测试取平均值。试验环境参数见表 2,模型参数见表 3。

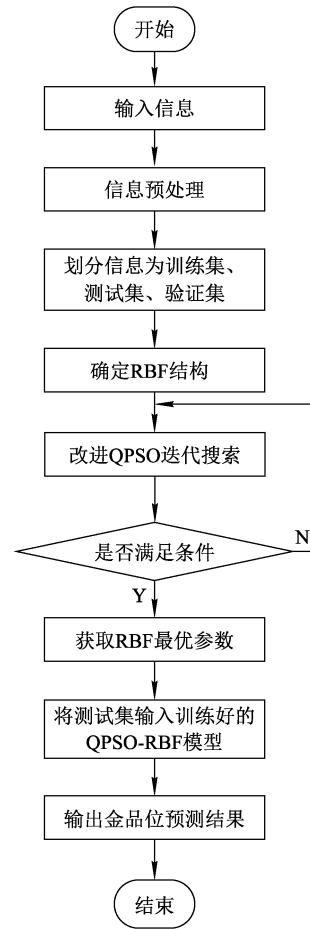


图 4 改进 QPSO-RBF 预测流程

表 2 试验环境参数

参数	数值
操作系统	Win 11
CPU	英特尔酷睿 i5-13400 处理器
内存	金士顿 32G
硬盘	2T
开发平台	Tensorflow
编程语言	Python

表 3 模型参数

参数	数值
粒子规模	50
迭代次数	1 000
惯性权重	[0.4, 0.9]
学习因子	$c_1 = c_2 = 2$
RBF 网络结构	14-13-1

不同的评价指标产生的结果也不同,因此,须选择有效的指标进行评价。在金品位预测中,选取均方根误差 RMSE 和最大误差 e_{\max} 及相关系数 R^2 3 个指标对预测模型进行评价,计算公式^[19-20]如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{s=1}^N (Y_s - \tilde{Y}_s)^2}; \quad (6)$$

$$e_{\max} = \max(|Y_s - \tilde{Y}_s|); \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^{N_p} (y_i - y'_i)^2}{\sum_{i=1}^{N_c} (y_i - \bar{y})^2}。 \quad (8)$$

式中: Y_s, \tilde{Y}_s — s 时刻金品位的实际值、预测值, g/t; \bar{Y}_s — 金品位均, g/t; N — 计算的总时间, s。

3.2 试验结果分析

为验证改进 QPSO 算法的优化能力,与改进前的 QPSO 算法进行对比分析研究,通过整个训练集对 RBF 神经网络参数进行优化,优化前后随迭代次数变化的适应度值如图 5 所示。




图 5 优化前后适应度值随迭代次数的变化曲线

由图 5 看出:QPSO-RBF 神经网络模型迭代至 650 次左右时收敛,个体最优适应值为 0.048 0;改进 QPSO-RBF 神经网络模型迭代至 355 次左右时收敛,个体最优适应值为 0.008 0,收敛精度较高。结果说明通过 QPSO 算法的位置优化和权重自适应处理提高了预测模型的收敛精度。

为验证定性信息对预测模型的影响,分别将包括定性信息不变样本、有较小程度变化样本、有较大程度变化样本各取 500 组,去除定性信息后建立改进 QPSO-RBF 神经网络预测模型 1、2、3。对比各模型预测值和实际值,结果如图 6~8 所示,3 种模型的预测效果评价指标见表 4。




图 6 模型 1 预测值与实际值的对比结果




图 7 模型 2 预测值与实际值的对比结果




图 8 模型 3 预测值与实际值的对比结果

表 4 2 种方法的预测效果评价指标

模型	RMSE	e_{\max}	R^2
模型 1	0.011 5	0.006 9	0.940 4
模型 2	0.008 6	0.010 8	0.940 2
模型 3	0.027 5	0.047 8	0.860 5

由图 6~8 及表 4 看出:定性信息变化较小时,模型 1 和模型 2 预测性能均较好,模型预测值的均方根误差和最大误差均在 0.010 0 左右,相关系数均大于 0.940 0;定性信息发生较大变化时,若忽略定性信息对金品位的影响,则模型 3 的预测值有较大变化,预测值均方根误差为 0.027 5,最大误差为 0.047 8,相关系数为 0.860 5。这说明只有

在定性信息变化较小时,基于定量信息的单一预测模型对金品位的预测性能较优,而当定性信息发生较大变化时,预测性能则较差。

为验证所提改进云模型和改进 RBF 模型的优越性,将本模型与 QPSO-RBF 神经网络模型进行对比分析,将训练后的模型用于测试集测试,2 种方法预测值与实际值的对比结果如图 9、10 所示,预测效果评价指标见表 5。




图 9 本模型预测值与实际值的对比结果




图 10 QPSO-RBF 神经网络模型预测值与实际值的对比结果

表 5 2 种模型的预测效果评价指标

模型	RMSE	e_{max}	R^2
本模型	0.009 2	0.016 1	0.940 2
QPSO-RBF 神经网络模型	0.012 5	0.028 5	0.902 4

由图 9、10 看出:2 种模型预测效果均较好,但本模型的预测值与矿石实际金品位更为接近。由表 5 看出:本模型对金品位的预测效果在多个评价指标中均优于 QPSO-RBF 神经网络模型,前者比后者的均方根误差降低 26.40%,最大误差降低 43.51%,相关系数提高 4.19%。改进 QPSO 算法实现了 RBF 神经网络模型参数的优化,在金

品位预测中具有较好的效果,有效地提高了模型的拟合能力和预测精度。

4 结论

将改进云模型和改进 RBF 模型相结合的方法应用于湿法提金生产过程中,可将主要工序中定量信息和定性信息相结合,用于预测金品位。本模型与 QPSO-RBF 神经网络模型相比,均方根误差降低 26.40%,最大误差降低 43.51%,相关系数提高 4.19%,预测效果评价指标均较好,拟合能力和预测精度较高。但受目前测试设备和信息规模的限制,本模型预测的性能还有待进一步优化和完善。

参考文献:

- [1] 莫文水. 金氰化浸出过程混合建模及仿真算法分析研究[J]. 湿法冶金, 2023, 42(4): 429-435.
- [2] 祁正栋, 连国党, 周小鸿, 等. 废旧电路板特性分析及金的湿法回收技术研究进展[J]. 当代化工, 2020, 49(8): 1798-1802.
- [3] 陈溥. 基于核偏最小二乘法的湿法冶金萃取过程建模[J]. 湿法冶金, 2021, 40(3): 260-266.
- [4] 常玉清, 许弟伍, 李昊恩, 等. 含不确定信息的湿法冶金金泥品位软测量[J]. 仪器仪表学报, 2018, 39(10): 18-26.
- [5] 袁青云, 王福利, 何大阔. 湿法冶金中预测金产量的混合建模方法[J]. 东北大学学报(自然科学版), 2013, 34(3): 308-311.
- [6] 牛大鹏, 臧雅丽, 贾明兴. 基于案例推理的湿法冶金全流程优化设定[J]. 东北大学学报(自然科学版), 2020, 41(1): 1-6.
- [7] 高军, 刘亚东. 基于定性定量混合建模的金湿法冶金过程优化研究[J]. 长春师范大学学报, 2022, 41(10): 65-73.
- [8] 高桂兰, 范丹丹, 贺欣, 等. 采用响应面优化酸浸法回收报废三元电池中有价金属的研究[J]. 安全与环境学报, 2020, 20(1): 290-296.
- [9] 田娟, 李英祥, 李彤岩. 激活函数在卷积神经网络中的对比研究[J]. 计算机系统应用, 2018, 27(7): 43-49.
- [10] 徐丽丽, 李洪, 李劲. 基于灰色预测和径向基网络的人口预测研究[J]. 计算机科学, 2019, 46(增刊 1): 431-435.
- [11] 李晓晖, 艾仙斌, 徐春保. 废印刷电路板有价金属分离回收技术研究进展及展望[J]. 安徽工业大学学报(自然科学版), 2017, 34(3): 247-253.
- [12] 何德军, 舒建成, 陈梦君, 等. 电解锰渣建材资源化研究现状与展望[J]. 化工进展, 2020, 39(10): 4227-4237.
- [13] 牛大鹏, 刘元清. 基于改进即时学习算法的湿法冶金浸出过程建模[J]. 化工学报, 2017, 68(7): 2873-2879.
- [14] 刘韵, 阮久莉, 郭玉文, 等. 废手机电路板的浸提方法比较研究[J]. 中国资源综合利用, 2013, 31(1): 38-41.
- [15] 钟捷, 黄振浩, 辛灿辉, 等. 从废印制电路板中提取金的研

- 究[J]. 再生资源与循环经济, 2018, 11(6): 32-34.
- [16] 葛忠英, 李晶莹, 安妮, 等. 紫色色杆菌从废旧电子线路板中浸出金的研究[J]. 贵金属, 2017, 38(1): 48-52.
- [17] 郭计敏. 金氰化浸出过程非线性预测控制方法及仿真算法分析研究[J]. 湿法冶金, 2023, 42(6): 659-665.
- [18] 于晓颖, 王淑花, 高银东, 等. 废旧材料的高温热解回收研究进展[J]. 中国粉体工业, 2018(2): 30-39.
- [19] 郑炯莉, 李颖, 苑文仪, 等. 废电路板再生材料制备聚丙烯复合材料性能研究[J]. 环境科学与技术, 2019, 42(2): 196-201.
- [20] 王忠昂. 基于区间数的湿法冶金全流程优化控制研究[D]. 沈阳: 东北大学, 2019.

The Method of Combining Qualitative Information and Quantitative Information to Predict Gold Grade

LIANG Zhilin¹, GUO Pan²

(1. Basic Department of Henan Health Executive College, Zhengzhou 450000, China;
2. School of Water Resources and Civil Engineering, Zhengzhou University, Zhengzhou 450000, China)

Abstract: A gold grade prediction model was proposed by combining improved cloud models with improved RBF neural networks. Qualitative information was quantified using DS evidence theory and cloud models, and then quantum particle swarm optimization algorithm and RBF neural network were used to predict the gold grade in ores. The results indicate that the mean square error of this model is 0.009 2, the maximum error is 0.016 1, and the correlation coefficient is 0.940 2, the model can better preserve the qualitative information characteristics, the prediction effect of gold grade is good.

Key words: gold; grade; prediction; model; qualitative information; quantitative information; cloud model; RBF neural network