

基于BP神经网络的炭浆提金工艺指标优化

朱德宇^{1,2}, 沈岩柏¹, 张丽颖³

(1. 东北大学资源与土木工程学院; 2. 中国黄金集团有限公司河北东梁黄金矿业有限责任公司;

3. 沈阳奥思特安全技术服务集团有限公司)

摘要:炭浆提金工艺在黄金选矿领域应用广泛,然而,受其工艺特性影响,指标控制存在滞后性,当前多采用事后问题分析的方式进行指标调控,显著增加了工艺控制的不确定性。为有效应对这一问题,构建了三层BP神经网络模型,其输入层、隐含层及输出层的神经元个数分别设置为5,8和1,用于预测炭浆提金工艺的尾矿品位。基于东梁金矿的实际生产数据对该网络进行训练,结果显示网络拟合效果良好。运用训练好的网络对现场30组生产数据进行仿真验证,仿真准确率高达85.52%,有效解决了炭浆提金工艺中尾矿品位滞后的难题。此外,通过BP神经网络对现场工艺进行优化,确定了最佳工艺参数,优化后尾矿品位降低至0.08 g/t,显著提升了金资源利用率。

关键词:BP神经网络;炭浆提金工艺;指标预测;工艺优化;单因素分析;资源利用

中图分类号:TD953

文章编号:1001-1277(2025)05-0053-05

文献标志码:A

doi:10.11792/hj20250511

引言

中国金矿石的主要选别工艺包括重选、浮选及炭浆提金工艺^[1]。其中,炭浆提金工艺应用非常广泛。尾矿品位是该工艺的关键评价指标,有效降低尾矿品位对于提升黄金资源利用率至关重要^[2]。相较于其他工艺,炭浆提金工艺中金矿石需在流程中停留以达到设计的浸出吸附时间,这导致尾矿品位指标存在显著的滞后性,进而增加了尾矿品位控制的难度。因此,解决尾矿品位滞后问题成为炭浆提金工艺指标优化的核心^[3]。鉴于此,利用BP神经网络建模方法对尾矿品位进行实时预测,已成为当前选矿技术人员关注的热点。

BP神经网络具有较强的非线性映射能力、自适应自学习能力、泛化和容错能力^[4],目前在选矿行业应用较多^[5]。CHAURASIA等^[6]利用BP神经网络对低品位铁粉的可选性进行了研究,得到了较好的预测效果。AL-THYABAT等^[7-8]利用BP神经网络研究浮选回收率和精矿品位影响因素,并利用BP神经网络对浮选工艺进行优化。MOHANTY等^[9]利用人工神经网络研究了水力旋流器的脱水性能。JAMRÓZ等^[10]利用人工神经网络与进化算法结合寻找铜浮选过程最优参数。NIQUINI等^[11]利用人工神经网络对铅锌矿浮选精矿、尾矿质量及回收率进行预测。刘青等^[12]利用BP神经网络对金的浮选回收率进行预测。

姚致远等^[13]利用BP神经网络建立的磨矿细度预测模型得出了最优磨矿细度。

为解决炭浆提金工艺指标控制滞后问题,参照中国黄金集团有限公司河北东梁黄金矿业有限责任公司(下称“东梁金矿”)选矿工艺构建基于BP神经网络的炭浆提金工艺尾矿品位指标预测模型,利用现场生产数据对BP神经网络进行训练,最终实现优化炭浆提金工艺指标的目的^[14-15]。

1 BP神经网络模型结构

BP神经网络作为一种多层神经网络,其结构主要由输入层、隐含层和输出层构成^[16]。相关研究表明,对于拟合问题而言,三层网络结构足以胜任各类任务^[17]。因此,本文采用三层网络结构进行模型构建。

1.1 输入层、输出层设计

在炭浆提金工艺中,尾矿品位受诸多因素影响,如原矿特性、给矿量、原矿品位、入选浓度、入选细度、氰化钠单耗、石灰单耗、絮凝剂单耗、浸出温度、浸出时间及搅拌强度等。基于东梁金矿的实际生产情况,遵循数据易采集性原则,运用鱼骨图法确定了输入层变量(如图1所示)。根据鱼骨图,确定输入变量为处理矿量、原矿品位、入选细度(细度-0.074 mm占比)、入选浓度、氰化钠单耗;而输出层变量则设定为尾矿品位。

收稿日期:2024-09-01; 修回日期:2024-10-30

基金项目:贵州省科技计划项目(ZX20230117)

作者简介:朱德宇(1988—),男,高级工程师,硕士,从事选矿工作;E-mail:307521045@qq.com




图1 尾矿品位影响因素分析图

Fig. 1 Analysis diagram of influencing factors on tailings grade

1.2 隐含层设计

BP神经网络隐含层神经元个数的确定是一个复杂问题。若隐含层神经元个数过少, BP神经网络的学习精度难以达到预期要求;若隐含层神经元个数过多, 则易导致过拟合现象, 并增加BP神经网络的学习时长。因此, 通常依据经验公式^[18](如式(1)所示)来确定隐含层神经元个数(n_1)。

$$n_1 = \sqrt{n + m} + a \tag{1}$$

式中: n 为输入层神经元个数, $n=5$; m 为输出层神经元个数, $m=1$; a 为0~10的常数。

通过MATLAB平台构建BP神经网络模型, 将隐含层神经元个数依次设置为3~12, 并逐一进行网络训练。每次训练后的均方差结果如表1所示。

表1 不同隐含层神经元个数的均方差

Table 1 Mean squared error of neurons on different hidden layers

隐含层神经元个数	均方差
3	0.011 4
4	0.059 3
5	0.158 5
6	0.019 5
7	0.086 4
8	0.004 1
9	0.488 7
10	0.110 0
11	0.007 5
12	0.061 2

由表1可知:均方差最小值为0.004 1, 由此确定最佳隐含层神经元个数为8。

根据上述输入层、隐含层、输出层神经元的选择, 确定BP神经网络结构如图2所示。

2 数据来源与预处理

2.1 数据来源

为确保BP神经网络模型的泛化能力, 训练数据




图2 BP神经网络结构

Fig. 2 Structure diagram of the BP neural network

采用东梁金矿近5年的生产数据, 具体数据(部分数据)如表2所示。

表2 东梁金矿近5年生产数据(部分)

Table 2 Production data of the Dongliang Gold Mine over the past 5 years (part)

处理矿量/ ($t \cdot h^{-1}$)	原矿品位/ ($g \cdot t^{-1}$)	入选细 度/%	入选浓 度/%	氰化钠单耗/ ($kg \cdot t^{-1}$)	尾矿品位/ ($g \cdot t^{-1}$)
58.03	0.86	88.61	39.21	1.29	0.10
59.20	0.72	88.56	39.32	1.37	0.08
55.32	0.93	86.23	38.73	1.59	0.10
56.36	0.98	87.83	39.08	1.40	0.10
55.05	0.84	85.08	36.23	1.22	0.11
54.57	0.50	85.75	32.33	1.74	0.07
54.17	0.51	86.13	32.63	1.57	0.07
52.81	0.44	85.19	37.79	1.49	0.07
51.68	0.41	85.05	37.02	1.72	0.08
51.68	0.33	84.24	35.05	1.56	0.09
53.40	0.48	87.54	36.04	2.08	0.07
55.57	0.71	87.56	38.80	1.47	0.07

2.2 数据预处理

鉴于所构建的BP神经网络采用sigmoid函数作为神经元激活函数, 其输出值被限制在 $[0, 1]$ 或 $[-1, 1]$, 若不对数据进行归一化处理, 将导致权值调整幅度不均, 且原始数据单位各异。因此, 需要对原始数据进行归一化处理^[19], 如式(2)所示。

$$y = \frac{x - Q_{\min}}{Q_{\max} - Q_{\min}} \tag{2}$$

式中: y 为归一化后的值; x 为归一化前的值; $Q_{\max}$ 、 $Q_{\min}$ 分别为样本最大值和最小值。

归一化处理后的生产数据(部分数据)如表3所示。


3 BP神经网络训练与仿真

在数据划分中, 训练集占原始数据的70%, 而测

表3 归一化处理后的生产数据(部分)
Table 3 Normalized production data (part)

处理矿量/ (t·h ⁻¹)	原矿品位/ (g·t ⁻¹)	入选细 度/%	入选浓 度/%	氰化钠单耗/ (kg·t ⁻¹)	尾矿品位/ (g·t ⁻¹)
0.70	0.38	0.64	0.73	0.30	0.37
0.83	0.29	0.64	0.74	0.37	0.15
0.40	0.44	0.29	0.68	0.57	0.38
0.52	0.47	0.53	0.72	0.39	0.44
0.37	0.37	0.12	0.41	0.24	0.59
0.32	0.12	0.22	0	0.70	0.06
0.27	0.13	0.28	0.03	0.55	0
0.12	0.08	0.14	0.58	0.48	0.05
0	0.06	0.12	0.50	0.68	0.14
0	0	0	0.29	0.53	0.26
0.19	0.11	0.49	0.39	1.00	0.04
0.43	0.28	0.49	0.69	0.46	0.01

试集占 30 %。采用归一化处理后的数据对所构建的



BP神经网络进行训练,训练参数如表4所示。

表4 BP神经网络训练参数

Table 4 Training parameters of the BP neural network

指标	参数
输入层神经元个数	5
隐含层神经元个数	8
输出层神经元个数	1
训练函数	trainlm
隐含层激活函数	tansig
输出层激活函数	purelin
训练次数	1 000
学习率	0.01
最小误差	0.000 1

利用东梁金矿生产数据训练建立 BP 神经网络,训练结果如图3所示。




图3 BP神经网络训练结果

Fig. 3 Training results of the BP neural network

一般来说, $R>0.9$ 时认为 BP 神经网络拟合较好^[20]。由图3可知,研究所构建的BP神经网络拟合情况非常好。

随机抽取东梁金矿现场生产数据 30 组,利用训练好的 BP 神经网络进行仿真,仿真结果如图4所示。




图4 BP神经网络仿真结果

Fig. 4 Simulation results of the BP neural network

由图4可知:仿真结果在低品位区间误差较大,达到了 0.04 g/t,但总体预测相对准确,30 组数据预测准确率达到了 85.52 %;说明 BP 神经网络可以应用于

现场尾矿品位的预测,解决了尾矿品位滞后问题,为炭浆提金工艺指标优化打下坚实基础。

4 基于BP神经网络的工艺指标优化

在实际生产过程中,通常要求处理矿量维持较高水平,而原矿品位一般不作为优化选矿工艺指标的调节参数。基于东梁金矿的实际生产状况,本研究选取入选细度、入选浓度及氰化钠单耗作为优化选矿指标的控制变量。通过单一变量法,并结合已训练好的 BP 神经网络,对现场生产工艺进行仿真分析,以探寻最优控制指标值。根据现场实际经验,处理矿量设定为 60 t/h,原矿品位为 1.2 g/t,在单一变量变动的情况下,其余变量均保持为设计值。仿真结果如表5~7所示。

通过仿真确定最佳入选细度为 88 %,最佳入选浓度为 38 %,最佳氰化钠单耗为 1.5 kg/t。此时,尾矿品位为 0.08 g/t。

5 结 论

1) 基于 BP 神经网络模型与东梁金矿现场生产数

表 5 最优入选细度仿真结果
Table 5 Simulation results for optimal feed fineness

处理矿量/ (t·h ⁻¹)	原矿品位/ (g·t ⁻¹)	入选细 度/%	入选浓 度/%	氰化钠单耗/ (kg·t ⁻¹)	尾矿品位/ (g·t ⁻¹)
60	1.2	85	40	1.2	0.14
60	1.2	86	40	1.2	0.13
60	1.2	87	40	1.2	0.13
60	1.2	88	40	1.2	0.12
60	1.2	89	40	1.2	0.12
60	1.2	90	40	1.2	0.12
60	1.2	91	40	1.2	0.12
60	1.2	92	40	1.2	0.13
60	1.2	93	40	1.2	0.15
60	1.2	94	40	1.2	0.15
60	1.2	95	40	1.2	0.15

表 6 最优入选浓度仿真结果
Table 6 Simulation results for optimal feed concentration

处理矿量/ (t·h ⁻¹)	原矿品位/ (g·t ⁻¹)	入选细 度/%	入选浓 度/%	氰化钠单耗/ (kg·t ⁻¹)	尾矿品位/ (g·t ⁻¹)
60	1.2	88	38	1.2	0.09
60	1.2	88	39	1.2	0.10
60	1.2	88	40	1.2	0.12
60	1.2	88	41	1.2	0.17
60	1.2	88	42	1.2	0.19

表 7 最优氰化钠单耗仿真结果
Table 7 Simulation results for optimal unit sodium cyanide consumption

处理矿量/ (t·h ⁻¹)	原矿品位/ (g·t ⁻¹)	入选细 度/%	入选浓 度/%	氰化钠单耗/ (kg·t ⁻¹)	尾矿品位/ (g·t ⁻¹)
60	1.2	88	38	1.0	0.10
60	1.2	88	38	1.1	0.10
60	1.2	88	38	1.2	0.09
60	1.2	88	38	1.3	0.09
60	1.2	88	38	1.4	0.09
60	1.2	88	38	1.5	0.08
60	1.2	88	38	1.6	0.08
60	1.2	88	38	1.7	0.08

据,研究构建了炭浆提金工艺流程的预测模型,有效解决了炭浆提金工艺中尾矿品位控制滞后问题。仿真结果说明,该模型具备出色的泛化能力,能够准确预测现场尾矿品位指标。

2)借助预先训练好的BP神经网络,实现了对炭浆提金工艺参数的动态、实时优化调整,从而确保选矿生产过程的质量控制达到最优状态。经过优化,最佳入选细度为88%,最佳入选浓度为38%,最佳氰化钠单耗为1.5 kg/t,优化后的尾矿品位降至0.08 g/t。

3)BP神经网络模型的应用为提升炭浆提金工艺回收率开辟了新的研究路径,为增强黄金资源利用率奠定了坚实基础。

[参 考 文 献]

[1] 邱曼,黄学雄,毛益林,等.我国金矿资源概况及选冶技术研究进展[J].矿产综合利用,2023(2):106-115.

[2] 黄征东.夹皮沟矿业公司选冶工艺优化改造[J].黄金,2017,38(5):62-64.

[3] 马仲凯.某金矿选矿厂浸出前移工艺优化实践[J].黄金,2023,44(12):51-54,63.

[4] 刘凡平.神经网络与深度学习应用实战[M].北京:电子工业出版社,2018.

[5] 李超,尚衍波,朱阳戈,等.神经网络技术在选矿行业的应用研究[J].现代矿业,2019,35(8):123-126.

[6] CHAURASIA R C, NIKKAM S. Application of artificial neural network to study the performance of multi-gravity separator (MGS) treating iron ore fines[J].Particulate Science and Technology, 2017, 35(1):93-102.

[7] AL-THYABAT S. On the optimization of froth flotation by the use of an artificial neural network[J]. Journal of China University of Mining and Technology, 2008, 18(3):418-426.

[8] FARGHALY M, SERWA A, AHMED M. Optimizing the Egyptian coal flotation using an artificial neural network [J].Mining World Express, 2012, 1(2): 27-33.

[9] MOHANTY S, DAS S K, MAJUMDER A K. Artificial neural network modeling and experimental investigation to characterize the dewatering performance of a hydrocyclone[J]. Mineral Processing and Extractive Metallurgy, 2021, 130(4):396-408.

[10] JAMRÓZ D, NIEDOBA T, PIĘTA P, et al. The use of neural networks in combination with evolutionary algorithms to optimise the copper flotation enrichment process [J]. Applied Sciences, 2020, 10(9): 3119.

[11] NIQUINI F G F, COSTA J F C L. Mass and metallurgical balance forecast for a zinc processing plant using artificial neural networks[J]. Natural Resources Research, 2020, 29(6):3 569-3 580.

[12] 刘青,王彬,袁玮,等.金矿浮选回收率预测模型[J].北京科技大学学报,2014,36(11):1 456-1 461.

[13] 姚致远,胡乃联,李国清,等.黄金选矿厂磨矿细度优化模型研究与应用[J].现代矿业,2016,32(6):45-47.

[14] 朱德宇.氰化尾矿无害化处理工艺生产实践[J].世界有色金属,2020(3):186-187.

[15] 朱德宇.一段两闭路磨矿分级工艺在生产实践中的应用[J].世界有色金属,2020(11):211-212.

[16] 汪志国,唐学义,陈东方,等.基于神经网络的采场凿岩爆破参

- 数优化及应用[J].黄金,2017,38(10):36-39.
- [17] 姚舜才,李大威.神经网络与深度学习:基于MATLAB的仿真与实现[M].北京:清华大学出版社,2022.
- [18] MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. *Advances in Engineering Software*, 2014, 69:46-61.
- [19] 邱锡鹏.神经网络与深度学习[M].北京:机械工业出版社,2020.
- [20] 郭锐.基于RSM和BP神经网络预测选矿厂药剂添加量研究[D].昆明:昆明理工大学,2020.

Optimization of carbon-in-pulp gold extraction process metrics based on the BP neural network

Zhu Deyu^{1,2}, Shen Yanbai¹, Zhang Liying³

(1. School of Resources and Civil Engineering, Northeastern University;

2. Hebei Dongliang Gold Mining Co., Ltd., China National Gold Group Corporation;

3. Shenyang Honest Safety Technology Service Group Co., Ltd.)

Abstract: The carbon-in-pulp (CIP) gold extraction process is widely used in the gold beneficiation field. However, due to the inherent characteristics of the process, there is a lag in metrics control. At present, metrics adjustment is typically carried out through post-analysis of issues, which significantly increases the uncertainty in process control. To effectively address this issue, a three-layer BP neural network model was constructed, with the number of neurons in the input, hidden, and output layers set to 5, 8, and 1, respectively, for predicting the tailings grade in the CIP process. The network was trained using actual production data from the Dongliang Gold Mine, and the results showed good network fitting performance. The trained network was then used to simulate and verify 30 sets of on-site production data, achieving a simulation accuracy of 85.52 %, effectively resolving the issue of lagging tailings grade in the CIP process. In addition, process optimization was performed using the BP neural network, and the optimal process parameters were identified. After optimization, the tailings grade was reduced to 0.08 g/t, significantly improving the utilization rate of gold resources.

Keywords: BP neural network; carbon-in-pulp gold extraction process; metrics prediction; process optimization; single-factor analysis; resource utilization

(上接第 32 页)

Stope stability analysis in the Jinqingding mining district

Nie Peiqiang, Zheng Yongsheng, Jiang Qianshan, Li Hongpu

(Shandong Jinzhou Mining Group Co., Ltd.)

Abstract: Based on the geological conditions and mining environment in a certain ore section of the Jinqingding mining district, This study investigates the mechanical stability of stopes using limit span theory, foundation beam theory, and rheological models. Through mechanical analysis of the stope roofs, floors, pillars, and filling bodies, the effectiveness of the existing support system is evaluated. The results show that the current support measures have certain limitations under deep high-pressure conditions, affecting the stope stability. To improve the support effectiveness, targeted optimized support plans are proposed, including increasing support strength and density, as well as improving support structure design. The research provides theoretical foundations and practical guidance for stope stability analysis and support design in the Jinqingding mining district.

Keywords: mechanical model; stress analysis; stope stability; limit span theory; foundation beam theory; rheological model; support system