

超细全尾砂絮凝沉降参数优化模型

王新民,刘吉祥,陈秋松,肖崇春,万孝衡

中南大学资源与安全工程学院,长沙 410083

摘要 为了得到最优的絮凝沉降参数,以絮凝沉降正交试验数据为训练样本和检验样本建立BP神经网络预测模型。絮凝剂单耗、料浆浓度及絮凝剂浓度作为输入因子,沉降速度和极限浓度作为输出因子。对比隐含层节点数对模型训练过程及预测精度的影响,选取最佳预测模型节点数为9。将絮凝沉降参数细化输入到预测模型中,从而搜索出优选样本,优选参数絮凝剂单耗为4.5 g/t,絮凝剂浓度为0.11%,料浆浓度为15%。经实验对比,该模型对絮凝沉降参数预测结果的相对误差能控制在5%左右,精确度较高,可以作为絮凝沉降参数优选的一种新思路。

关键词 BP神经网络;全尾砂;絮凝沉降;动态放砂

中图分类号 TD853

文献标志码 A

doi 10.3981/j.issn.1000-7857.2014.17.003

Optimal Flocculating Sedimentation Parameters of Unclassified Tailings

WANG Xinmin, LIU Jixiang, CHEN Qiusong, XIAO Chongchun, WAN Xiaoheng

School of Resources and Safety Engineering, Central South University, Changsha 410083, China

Abstract Back-propagation neural network was used to optimize the flocculating sedimentation parameters. To get the best network mode, some learning and training samples were established by the numbered orthogonal blasting tests. In the process of establishing the network mode, the tailings concentration, flocculant consumption and flocculant concentration were used as the input data, the sedimentation speed and limiting concentration were confirmed to be the synthesized output data. Comparison of the influences of hidden layer nodes on model training process and prediction accuracy indicates that the optimal hidden layer node was 9. By entering the refined flocculating sedimentation parameters into the prediction model, optimal samples are searched and the optimal parameters show that the flocculating agent consumption is 4.5 g/t, flocculating concentration is 0.11% and tailings concentration is 15%. Compared with that of the experimental results, the relative error of the prediction results can be controlled at about 5%. The application indicates this mode has relatively high accuracy, providing a new method to optimize the flocculating sedimentation parameters.

Keywords back-propagation neural network; unclassified tailings; flocculating sedimentation; dynamic sand release

随着经济持续快速发展,矿产资源被加速消耗,易于开采的优质矿产资源日渐枯竭^[1],矿业正面临着两大突出问题:资源开采的深部化和尾矿废石的灾害化。深部开采面临的主要问题是地压大、温度高,表现形式如岩爆、冲击地压和作业环境恶化;排放尾矿废石不仅会带来环境污染,还会给生态造成长远的破坏^[2]。业内学者普遍认为全尾砂胶结充填是处理采空区的最理想途径^[3]。

选矿后排出的全尾砂浆,其浓度一般为10%~25%,而全

尾砂充填,特别是胶结充填,对充填料浆的质量浓度一般要求68%~74%,膏体充填对质量浓度的要求更高^[4]。因此,全尾砂的浓缩沉降成为制约高浓度充填的关键因素。

传统的全尾砂浓缩沉降一般在立式砂仓中进行,主要依靠尾砂的自然沉降。由于全尾砂细泥比重大,尾砂在立式砂仓中自然沉降缓慢,溢流水含固量高,沉砂浓度低,无法满足工业水重复利用要求,并且超标排放污水,污染环境。为加快沉降速度,降低溢流水含固量,可以通过添加絮凝剂的方法

收稿日期:2014-03-05;修回日期:2014-04-15

基金项目:“十二五”国家科技支撑计划项目(2012BAC09B02)

作者简介:王新民,教授,研究方向为采矿与充填技术,电子信箱:237755829@qq.com

引用格式:王新民,刘吉祥,陈秋松,等.超细全尾砂絮凝沉降参数优化模型[J].科技导报,2014,32(17):23-28.

法加速沉降浓缩^[56]。然而,实际运用中,全尾砂的絮凝沉降参数选择往往借鉴于其他矿山的使用经验,而全尾砂性质的不同导致其絮凝沉降效果并不理想。为此,一些学者针对全尾砂絮凝沉降进行了大量的试验。焦华喆等^[7]以某矿全尾砂和聚丙烯酰胺(PAM)为实验原料进行静态絮凝沉降试验;张钦礼等^[8]分析了充填骨料固体颗粒的沉降规律;史秀志等^[9]针对不同供砂浓度尾砂浆液选用不同絮凝剂进行了立式砂仓尾砂浆液絮凝沉降试验。但仅仅通过实验室有限的试验研究,并不能有效的选出最佳絮凝沉降参数,若大量增加实验组,则耗时耗力,且结果易受到其他因素干扰。因此,通过有限的实验数据,对絮凝沉降参数进行预测具有一定的工程意义。

BP神经网络具有很强的多层次、非线性映射能力,能较好地解决少数据、贫信息、不确定性问题,且不受非线性模型的限制。向平等^[10]利用BP神经网络建立了城市用水量分时段预测模型;蒋建平^[11]利用BP神经网络方法对土压缩指数进行了预测;张钦礼等^[12]以充填配比试验数据为训练和检验样本来建立BP神经网络预测模型。因此,本研究为了对全尾砂絮凝沉降参数进行预测、优选,首先对絮凝沉降参数、评价指标进行了简化,获得最优的输入、输出因子;进而以正交试验为基础,获得有效的学习、训练样本,从而建立絮凝沉降参数BP神经网络预测、优选模型。

1 BP神经网络预测、优选模型

1.1 输入、输出因子

大量研究表明,在尾砂的物理力学性质和絮凝剂特性一定的情况下,供砂浓度、絮凝剂单耗和絮凝剂浓度、砂浆pH值是影响絮凝沉降效果的最主要因素。理论上絮凝剂的用量越大,尾砂的沉降速度越快,但用量大,其药剂成本增加,且会造成溢流水中絮凝剂含量高,废水处理困难;絮凝剂用量少,则沉降速度慢,满足不了立式砂仓连续动态放砂的要求,且溢流水中含固量高,增加废水处理成本。尾砂浓度越高,所含固体颗粒越多,絮凝剂的用量越多,且尾砂颗粒间的相互作用力增加,沉降速度降低;尾砂浓度过低,则造成其最终沉降浓度降低,达不到尾砂使用要求^[13,14]。絮凝剂浓度大,则黏度大,搅拌难度大,均匀分散到矿浆中的难度也大;絮凝剂浓度过小,单位体积絮凝剂量少,短时间内难以与单位体积全尾砂颗粒进行完全作用,影响沉降效果。虽然有研究表明,砂浆pH值对结果有所影响,但现场增加pH值调整装置将大大提高操作难度,降低沉降结果精度,不利于高效管理。因此,确定絮凝沉降参数主要有絮凝剂单耗 q (g/t)、絮凝剂浓度 C_f (%) and 尾砂浓度 C_w (质量浓度,%) ,可作为网络的输入因子。而主要的絮凝沉降效果评价指标有沉降速度 v (m/h)、放砂量 g 、放砂浓度(质量浓度,%) and 溢流水浓度(质量浓度,%)。

1) 沉降速度。在室内试验过程中,测定的沉降界面下沉

速度即尾砂沉降速度。为达到尾砂在立式砂仓中动态沉降,连续放砂的目的,必须保证砂仓内储砂量不变,即尾砂沉降速度 \geq 放砂速度。在保证进砂量满足的前提下,全尾砂沉降的沉降速度 v 应满足放砂能力 Q 的要求,与其所在的立式砂仓截面积 S 有关。

$$v \geq Q/S$$

充填能力按100 m³/h设计,则每小时需干砂量为76.05 m³,放砂速度设计为 $Q=80$ m³/h计算,在直径为11 m的立式砂仓中, $S=94.99$ m²,则全尾砂沉降速度 $v \geq 0.842$ m/h时,即可实现动态沉降,连续放砂。在实际生产中,成本一定的情况下,要求沉降速度越快越好。试验过程中,通过测定沉降面高度随时间的变化来计算沉降速度。

2) 放砂量和放砂浓度。即絮凝沉降结束后,底部尾砂的质量浓度。在高浓度充填中,为配置高浓度的浆体,要求放砂浓度越高越好,一般要求放砂浓度在50%以上。

3) 溢流水浓度。絮凝沉降过程中,上层溢流水的质量浓度,工程上常用溢流水含固量表示。

在立式砂仓絮凝沉降中,如果絮凝剂性能、浓度、用量一定,沉降速度确定后,放砂量和放砂浓度也就相应确定,故沉降速度与放砂量、放砂浓度实际上是一个问题的3个方面,研究时不宜重复考虑,本文选用前者。如果进砂浓度一定,在既定的立式砂仓中,浆体的总质量不变,尾砂固体颗粒的总质量也不变,则存在以下关系式:

$$C_{wy} = \frac{C_{wj}m_j - C_{wf}m_f}{m_j - m_f}$$

式中, C_{wj} 为进砂质量浓度,%; m_j 为进砂总质量,t; C_{wf} 为放砂质量浓度,%; m_f 为放砂总质量,t; C_{wy} 为溢流水质量浓度,%; m_y 为溢流水总质量,t。

溢流水质量浓度与放砂量是相互矛盾的,一般而言,放砂量越大,溢流水质量浓度越低,反之亦然。因此,在进行神经网络预测输出时,必须综合考虑沉降速度、放砂量、放砂浓度及溢流水浓度,制定一个综合评价输出因子。而上述指标均与沉降速度及放砂浓度密切相关,为简化网络体系,将沉降速度和放砂浓度作为评价絮凝沉降参数优劣的综合评价指标,即为神经网络的输出因子。

1.2 BP神经网络模型

此次研究以絮凝剂单耗、絮凝剂浓度、全尾砂砂浆浓度作为输入因子,沉降速度、沉降极限浓度作为输出因子来建立BP网络模型,隐含层的节点数参考如下公式进行选择:

$$l_1 < n - 1$$

$$l_2 < \sqrt{(m+n)} + a$$

$$l_3 = \log_2 n$$

式中, n 为输入层节点数; m 为输出层节点数; l 为隐含层节点数; a 为0~10之间的常数。根据以上公式,隐含层的合理节点数在2~12之间,建立模型时,应对多种隐含层神经元数目情况进行BP神经网络收敛速度、预测误差比较,确定最佳隐

含层节点数^[15,16]。

由于各个指标互不相同,为避免输入输出量级别相差较大而造成部分神经元达到饱和状态,应对样本进行归一化处理,归一化采用的函数为

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}$$

归一化后的数据都处于[0, 1]区间内,则BP神经网络隐含层的神经元传递函数采用S型正切函数tansig,输出层神经元传递函数采用对数函数logsig。预测后对输出结果进行反归一化,公式为

$$x = x'[\max(x) - \min(x)] + \min(x)$$

絮凝沉降参数的BP神经网络预测、优选模型算法流程如图1所示。

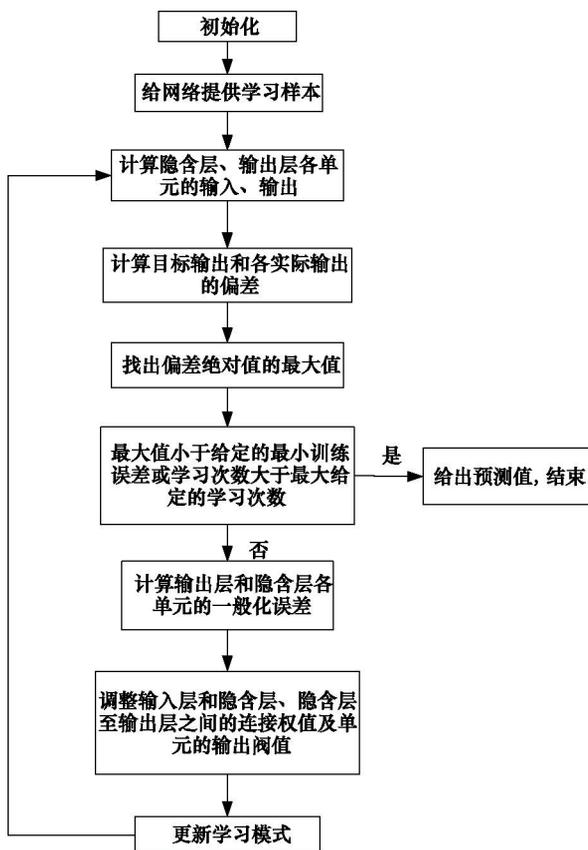


图1 神经网络算法流程图

Fig. 1 Flow chart of algorithm in the neural network

2 应用实例

以湖南郴州某铅锌矿全尾砂为例,运用BP神经网络模型对絮凝沉降参数进行预测、优选。该矿全尾砂粒径小,使用立式砂仓全尾砂胶结充填,其关键技术在于全尾砂快速沉降,实现动态放砂,而仅靠自然沉降,无法满足连续进砂连续放砂的沉降速度要求,必须依靠絮凝沉降。如何选取最佳的絮凝沉降方式,絮凝沉降参数的优化研究显得尤为重要。研究以全尾砂供砂浓度、絮凝剂单耗及絮凝剂添加浓度作为输

入因素,研究其与絮凝沉降速度及沉降极限浓度之间的关系,以获得最优絮凝沉降参数。

2.1 尾砂性质

取全尾砂颗粒主要物理力学性质测定结果见表1。全尾砂粒度较细,0.075~0.005 mm之间的颗粒含量占比达58.8%,中值粒径仅为0.049 mm,粒度过细,在自然状态下其沉降速度非常的小^[17-19],仅靠自然沉降不能满足动态放砂浓度和速度的要求。为了得到理想的沉降效果,必须采用絮凝沉降。经测定选矿全尾砂6.0<pH<7.0,属中性偏酸性水。

表1 全尾砂物理力学性能

Table 1 Physical and mechanical properties of unclassified tailings

| 名称 | 比重 | 中值粒径 d_{50}/mm | 200目以下有效粒径 含量/% | 不均匀 d_{10}/mm | 渗透系数/ 系数 C_u | ($\text{cm}\cdot\text{s}^{-1}$) |
|-----|------|----------------------------|--------------------|---------------------------|-------------------|-----------------------------------|
| 全尾砂 | 2.83 | 0.049 | 69.1% | 0.005 | 12.7 | 1.3×10^{-5} |

2.2 建立学习、训练样本集

研究中考虑3个絮凝沉降影响因素,为了在降低样本数量的同时,较全面反应各因素的影响,提高拟合的精度,采用3因素3水平的正交试验方案。根据矿山实际情况,经过定性选择3种比较典型的供砂浓度 C_w (%)、聚丙烯酰胺单耗 q (g/t)和聚丙烯酰胺添加浓度(%)组合(表2),建立3因素3水平正交试验方案,通过室内量筒试验,测定相应的沉降速度和极限浓度(表3),得到的正交试验结果作为模型的学习、训练样本集。

表2 正交试验因素水平

Table 2 Factors and levels in orthogonal experiment

| 水平 | 影响因素 | | |
|----|--------|--|------------------|
| | 砂浆浓度/% | 聚丙烯酰胺单耗/ ($\text{g}\cdot\text{t}^{-1}$) | 聚丙烯酰胺添加量 浓度/% |
| 1 | 15 | 2 | 0.06 |
| 2 | 23 | 4 | 0.10 |
| 3 | 35 | 6 | 0.14 |

表3 絮凝沉降试验结果

Table 3 Results of flocculating sedimentation experiment

| 序号 | 影响因素 | | | | |
|----|--------|--|-------------|--|--------|
| | 砂浆浓度/% | 聚丙烯酰胺单耗/ ($\text{g}\cdot\text{t}^{-1}$) | 聚丙烯酰胺添加浓度/% | 沉降速度/ ($\text{cm}\cdot\text{h}^{-1}$) | 极限浓度/% |
| 1 | 15 | 2 | 0.06 | 70.88 | 61.48 |
| 2 | 15 | 4 | 0.10 | 111.67 | 57.69 |
| 3 | 15 | 6 | 0.14 | 117.66 | 57.09 |
| 4 | 23 | 4 | 0.14 | 96.58 | 60.41 |
| 5 | 23 | 6 | 0.06 | 86.34 | 56.63 |
| 6 | 23 | 2 | 0.10 | 78.00 | 60.57 |
| 7 | 35 | 6 | 0.10 | 45.04 | 62.22 |
| 8 | 35 | 2 | 0.14 | 22.63 | 63.64 |
| 9 | 35 | 4 | 0.06 | 34.53 | 65.42 |

2.3 BP模型预测、优选

根据所确定的神经网络模型结构,建立BP神经网络预测模型。首先对网络调试,确定最佳隐含层节点数^[20]。以表3中的数据为训练样本数据,分别检查隐含层节点数为5,7和9时的网络性能,得出网络模型训练误差、预测结果相对误差曲线图,结果如图2、图3、图4所示。由图2、图3、图4可知,

当隐含层节点数为5,7和9时,分别经20,6和9步运算达到精度要求,中间的收敛速度高于其他两者,而三者预测结果的最大相对误差分别为0.083,0.085和0.049。由此可见,当隐含层节点数为9时,网络的预测误差较前两者相对较小。因此,综合考虑,取隐含层节点数为9,预测网络模型的收敛速度快,误差相对较小。

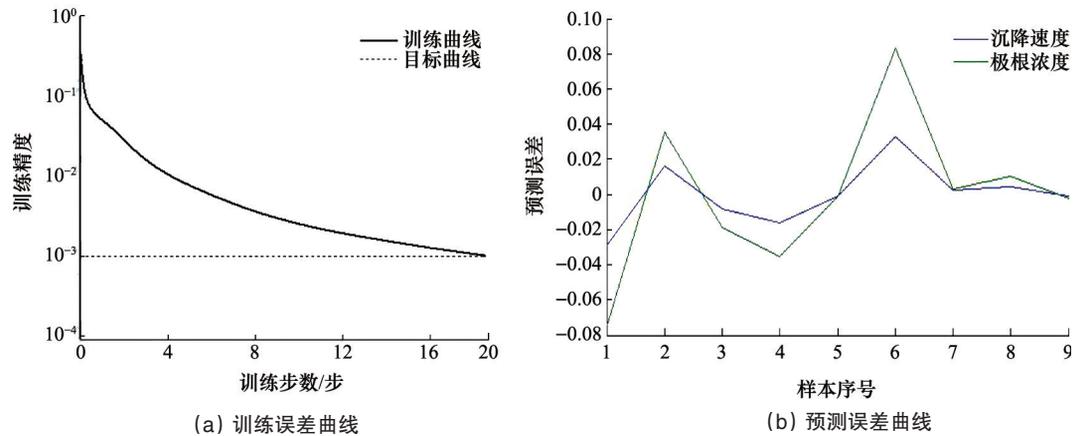


图2 BP神经网络性能曲线(隐单元数:5)

Fig. 2 Performance curve of BP neural network (concealed cell: 5)

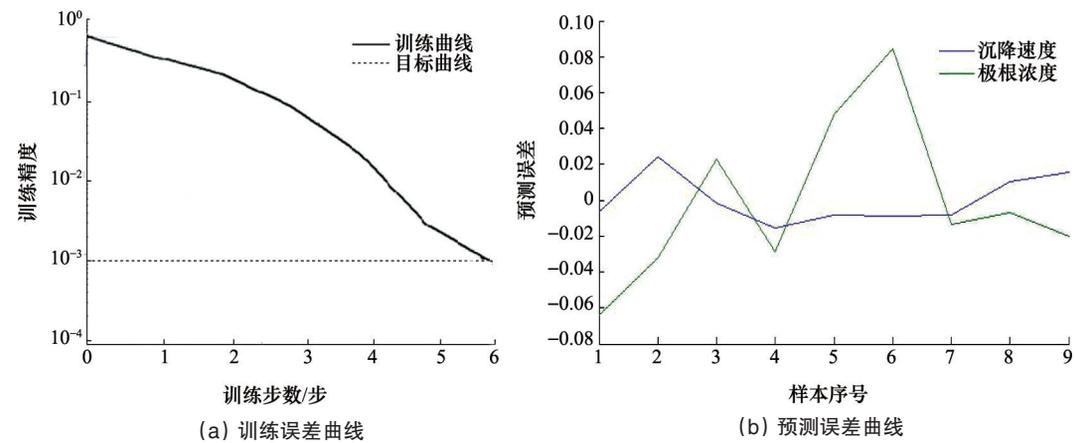


图3 BP神经网络性能曲线(隐单元数:7)

Fig. 3 Performance curve of BP neural network (concealed cell: 7)

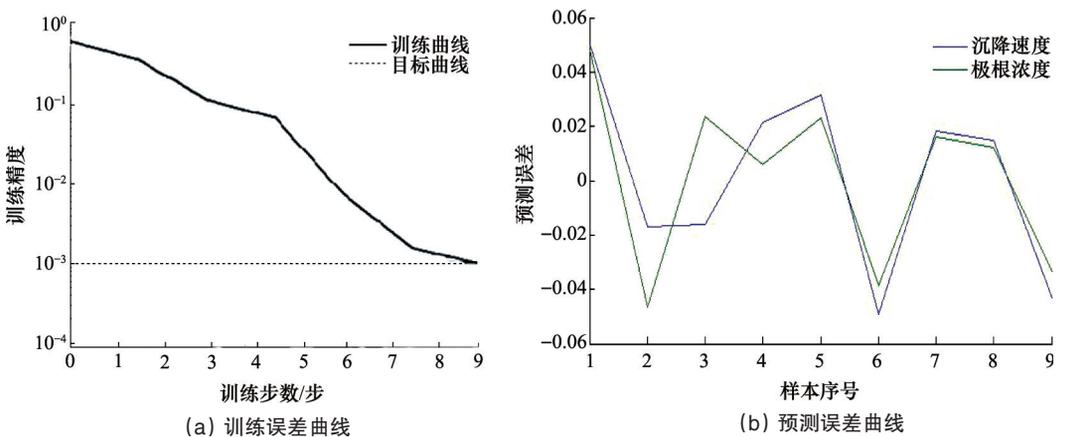


图4 BP神经网络性能曲线(隐单元数:9)

Fig. 4 Performance curve of BP neural network (concealed cell: 9)

为了搜索出最优的絮凝沉降参数,对砂浆浓度、絮凝剂单耗和絮凝剂浓度进一步细化,将参数输入到训练好的网络模型中进行预测,并以此为优选样本,搜索结果见表4。

表4 BP神经网络搜索结果

Table 4 Search results of BP neural network

| 序号 | 影响因素 | | | | 沉降速度/ ($\text{cm}\cdot\text{h}^{-1}$) | 极限浓 度/% |
|----|------------|--|-----------------|--|--|------------|
| | 砂浆浓 度/% | 聚丙烯酰胺单 耗/($\text{g}\cdot\text{t}^{-1}$) | 聚丙烯酰胺 添加浓度/% | | | |
| 1 | 15 | 2.5 | 0.07 | | 84.15 | 59.85 |
| 2 | 15 | 3.5 | 0.09 | | 113.66 | 58.36 |
| 3 | 15 | 4.5 | 0.11 | | 116.02 | 57.36 |
| 4 | 15 | 5.5 | 0.13 | | 115.50 | 57.19 |
| 5 | 17 | 2.5 | 0.09 | | 100.38 | 59.53 |
| 6 | 17 | 3.5 | 0.07 | | 85.56 | 57.79 |
| 7 | 17 | 4.5 | 0.13 | | 115.03 | 57.42 |
| 8 | 17 | 5.5 | 0.11 | | 114.92 | 57.16 |
| 9 | 19 | 2.5 | 0.11 | | 110.77 | 59.50 |
| 10 | 19 | 3.5 | 0.13 | | 113.38 | 58.28 |
| 11 | 19 | 4.5 | 0.07 | | 89.05 | 56.80 |
| 12 | 19 | 5.5 | 0.09 | | 111.35 | 57.07 |
| 13 | 21 | 2.5 | 0.13 | | 106.13 | 60.68 |
| 14 | 21 | 3.5 | 0.11 | | 103.05 | 57.80 |
| 15 | 21 | 4.5 | 0.09 | | 99.56 | 56.98 |
| 16 | 21 | 5.5 | 0.07 | | 96.02 | 56.78 |

预测优选结果表明:

1) 隐含层是影响BP网络模型预测结果的重要因素之一,节点数太少,网络不能很好地学习,需要增加训练次数,训练的精度也受影响;节点数太多,网络容易过拟合,导致容错性差,且误差不一定最小。因此,合理的隐含层节点数是保证BP神经网络预测模型高速度、高精度的首要条件。为获得最优预测模型,必须通过建立多种隐含层结构,进行网络性能优化对比。

2) 预测结果表明,建立的絮凝沉降参数优化模型具有较强的预测能力,能根据输入参数(絮凝剂单耗、砂浆浓度、絮凝剂浓度)较精确的预测出沉降速度和极限浓度。本次研究以絮凝沉降正交试验为依据,对多水平输入因子组合情况进行搜索,水平较为合理,输出因子也满足精度要求。

3) 由表4中的搜索结果可知,全尾砂的沉降速度和极限浓度与絮凝剂单耗、砂浆浓度和絮凝剂浓度并不成线性关系,在絮凝剂单耗较小时,沉降速度随浓度的增大而减小。絮凝沉降效果与絮凝剂单耗、絮凝剂浓度与砂浆浓度三者密切相关,单一改变其中的某一个变量并不能达到增加沉降速

度、提高极限浓度的要求,应综合考虑各个因素从而得到最优解。

综合以上分析,选取郴州某铅锌矿絮凝沉降参数为絮凝剂单耗为4.5 g/t,絮凝剂浓度为0.11%,尾砂浓度为15%,此时全尾砂在立式砂仓中的沉降速度最快(1.137 m/h),对应的极限浓度为57.36%,满足底部放砂浓度要求,沉降效果最好,且大于0.842 m/h,满足连续动态放砂的需要。通过BP神经网络模型,合理的优化了沉降参数,以成本最低、效果最优的参数指导立式砂仓絮凝沉降工艺流程,提高矿山充填系统的稳定性与可靠性。

2.4 误差分析

为验证预测结果可靠性,取表4中3、7、11、15组絮凝沉降参数进行室内试验,分析实验值和预测值的相对误差(表5)。结果表明,模型的拟合结果良好,经模型预测所得结果与实际值误差较小,能控制在5%左右,模型预测精度较高。

表5 相对误差分析

Table 5 Analysis of relative error

| 序号 | 沉降速度/($\text{cm}\cdot\text{h}^{-1}$) | | 极限浓度/% | | 相对误差/% | |
|----|--|--------|--------|-------|--------|------|
| | 真实值 | 预测值 | 真实值 | 预测值 | 沉降速度 | 极限浓度 |
| 3 | 111.30 | 116.02 | 56.01 | 57.36 | 4.06 | 2.35 |
| 7 | 109.58 | 115.03 | 56.80 | 57.42 | 4.73 | 1.07 |
| 11 | 85.67 | 89.05 | 55.84 | 56.80 | 3.79 | 1.69 |
| 15 | 96.91 | 99.56 | 55.87 | 56.98 | 2.66 | 1.94 |

3 结论

1) 预测方法的选择是预测模型建立的关键步骤,针对全尾砂絮凝沉降,建立了BP神经网络全尾砂絮凝沉降参数预测模型。通过简化,取供砂浓度、絮凝剂单耗和絮凝剂添加浓度作为BP神经网络预测的输入因子,以沉降速度和极限沉降浓度为综合评价输出因子,从而简化网络体系,提高网络的学习、训练速度。

2) 以正交试验结果为训练样本和检验样本,建立了BP神经网络预测模型。通过对3种隐含层神经元的网络性能进行对比,选用隐含层节点数为9的模型。输入多水平因子,使用训练好的网络搜索出优选样本,确定最优絮凝沉降参数为:絮凝剂单耗为4.5 g/t,絮凝剂浓度为0.11%,砂浆浓度为15%,在成本一定的前提下选择最优沉降参数。

3) 采用BP神经网络预测模型对全尾砂絮凝沉降参数进行预测、优选,避免了传统絮凝沉降参数选择的主观性、随机性,能够做出更为科学、准确、有理论依据的判断。由于试验次数少,操作过程简单,预测结果较为精确,其他矿山可经过简单试验,建立适合矿山的BP神经网络预测模型,对全尾砂絮凝沉降参数进行预测。本研究成果为矿山全尾砂絮凝沉降参数的选择提供了新的思路和可靠的技术支撑。

参考文献 (References)

- [1] 钱鸣高, 缪协兴, 许家林. 资源与环境协调(绿色)开采[J]. 煤炭学报, 2007, 32(1): 1-7.
Qian Minggao, Miao Xiexing, Xu Jialin. Green mining of coal resources harmonizing with environment[J]. Journal of China Coal Society, 2007, 32(1): 1-7.
- [2] 王新民, 古德生, 张钦礼. 深井矿山充填理论与管道输送技术[M]. 长沙: 中南大学出版社, 2010: 9-10.
Wang Xinmin, Gu Desheng, Zhang Qinli. Theory and technology of deep mine backfilling[M]. Changsha: Central South University Press, 2010: 9-10.
- [3] 孙光华, 李青山. 采空区充填技术研究[J]. 矿业研究与开发, 2011(5): 16-17, 65.
Sun Guanghua, Li Qingshan. Study on the technology of fillinggoaf[J]. Mining Research and Development, 2011(5): 16-17, 65.
- [4] 王洪江, 吴爱祥, 肖卫国, 等. 粗粒级膏体充填的技术进展及存在的问题[J]. 金属矿山, 2009(11): 1-5.
Wang Hongjiang, Wu Aixiang, Xiao Weigu, et al. The progresses of coarse paste fill technology and its existing problem[J]. Metal Mine, 2009(11): 1-5.
- [5] 王勇, 王洪江, 吴爱祥, 等. 细粒全尾矿絮凝沉降特性研究[J]. 黄金, 2012, 33(1): 48-51.
Wang Yong, Wang Hongjiang, Wu Aixiang, et al. Research on flocculation sedimentation characteristics of fine unclassified-tailings[J]. Gold, 2012, 33(1): 48-51.
- [6] Rulyov N N, Laskowski J S, Concha F. The use of ultra-flocculation in optimization of the experimental flocculation procedures[J]. Physicochemical Problems of Mineral Processing, 2011, 47: 5-16.
- [7] 焦华喆, 吴爱祥, 王洪江, 等. 全尾矿絮凝沉降特性实验研究[J]. 北京科技大学学报, 2011, 33(12): 1437-1441.
Jiao Huazhe, Wu Aixiang, Wang Hongjiang, et al. Experiment study on the flocculation settlement characteristic of unclassified tailings[J]. Journal of University of Science and Technology Beijing, 2011, 33(12): 1437-1441.
- [8] 张钦礼, 谢盛青, 郑晶晶, 等. 充填料浆沉降规律研究及输送可行性分析[J]. 重庆大学学报, 2011, 34(1): 105-107
Zhang Qinli, Xie Shengqing, Zheng Jingjing, et al. Sedimentation law research and transportation feasibility study of backfilling slurry[J]. Journal of Chongqing University, 2011, 34(1): 105-107
- [9] 史秀志, 胡海燕, 杜向红, 等. 立式砂仓尾矿浆液絮凝沉降试验研究[J]. 矿冶工程, 2010(3): 1-3.
Shi Xiuzhi, Hu Haiyan, Du Xianghong, et al. Experimental study on flocculating sedimentation of tailings slurry in a vertical sand tank[J]. Mining and Metallurgical Engineering, 2010(3): 1-3.
- [10] 向平, 张蒙, 张智, 等. 基于BP神经网络的城市时用水量分时段预测模型[J]. 中南大学学报: 自然科学版, 2012, 43(8): 3320-3323.
Xiang Ping, Zhang Meng, Zhang Zhi, et al. Period-divided predictive model of urban hourly water consumption based on BP neural network[J]. Journal of Central South University: Science and Technology Edition, 2012, 43(8): 3320-3323.
- [11] 蒋建平, 章杨松, 阎长虹, 等. BP神经网络在地基土压缩指数预测中的应用[J]. 中南大学学报: 自然科学版, 2010, 41(2): 722-724.
Jiang Jianping, Zhang Yangsong, Yan Changhong, et al. Application of BP neural network in prediction of compression index of soil[J]. Journal of Central South University: Science and Technology Edition, 2010, 41(2): 722-724.
- [12] 张钦礼, 李谢平, 杨伟. 基于BP网络的某矿山充填料浆配比优化[J]. 中南大学学报: 自然科学版, 2013, 44(7): 2867-2869.
Zhang Qinli, Li Xieping, Yang Wei. Optimization of filling slurry ratio in a mine based on back-propagation neural network[J]. Journal of Central South University: Science and Technology Edition, 2013, 44(7): 2867-2869.
- [13] Yuan Y, Chai L, Yang Z. Application of polymeric aluminum salts in remediation of soil contaminated by Pb, Cd, Cu, and Zn[J]. Journal of Central South University, 2013, 20(6): 1638-1640.
- [14] Hu H, Zhang K, Zhang L, et al. Thermal decomposition behaviour of polyacrylamidomethyltrimethyl ammonium chloride in red mud separation process[J]. Journal of Central South University, 2008, 15(6): 808-810.
- [15] 赵彬, 王新民, 史良贵, 等. 基于BP神经网络的爆破参数优选[J]. 矿冶工程, 2009, 29(4): 24-27.
Zhao Bin, Wang Xinmin, Shi Liangui, et al. Optimization of blasting parameters based on back-propagation neural network[J]. Mining and Metallurgical Engineering, 2009, 29(4): 24-27.
- [16] 张钦礼, 程健, 陈秋松, 等. GA-SVM和神经网络组合模型预测充填钻孔寿命[J]. 科技导报, 2013, 31(34): 34-38.
Zhang Qinli, Cheng Jian, Chen Qiusong, et al. Prediction of backfill drill-hole life based on combined model of GA-SVM and neural network [J]. Science & Technology Review, 2013, 31(34): 34-38.
- [17] 刘凯, 黄德镛, 张明旭, 等. 大红山铜矿全尾矿絮凝沉降的试验研究[J]. 中国矿业, 2008(12): 60-63.
Liu Kai, Huang Deyong, Zhang Mingxu, et al. Experimental study on all tailings flocculation settling in Dahongshan cooper mine[J]. China Mining Magazine, 2008(12): 60-63.
- [18] 王星, 瞿国媛, 胡伟伟, 等. 尾矿浆絮凝沉降影响因素的试验研究[J]. 金属矿山, 2008(5): 149-151
Wang Xing, Qu Yuanyuan, Hu Weiwei, et al. Experiment research on factors influencing tailing pulp flocculation settling[J]. Metal Mine, 2008(5): 149-151
- [19] Zhao Ru, Zhang Zheng, Shi Jiangbo. Characterization of stress corrosion crack growth of 304 stainless steel by electrochemical noise and scanning Kelvin probe[J]. Journal of Central South University, 2008, 17(1): 13-18.
- [20] 喻寿益, 王吉林, 彭晓波. 基于神经网络的铜闪速熔炼过程工艺参数预测模型[J]. 中南大学学报: 自然科学版, 2007, 8(3): 153-157.
Yu Shouyi, Wang Jilin, Peng Xiaobo. Prediction model of craft parameters based on neural network during the process of copper flash smelting[J]. Journal of Central South University: Science and Technology Edition, 2007, 8(3): 153-157.

(责任编辑 吴晓丽)