



基于强度折减与智能算法的井下充填体强度预测

吉坤, 韩斌, 胡亚飞, 吴凡, 邱剑辉
(北京科技大学 土木与资源工程学院, 北京 100083)

摘要: 矿山充填系统在试运行期间的充填料浆配合比变化较大, 如何快速准确的获得井下各采场的充填体强度对相邻采场的安全开采来说至关重要。本文首先以料浆体积分数、水泥掺量、人工砂尾砂比以及养护时间作为输入因子, 以室内实验充填体单轴抗压强度 S_L 作为输出因子, 建立了一种 ANN-PSO 预测模型。然后定义了充填体强度预测折减系数 k 的概念, 并通过对比大量相同配合比下的室内实验充填体强度值 S_L 及实际生产充填体强度值 S_E , 计算获得了两者之间的 k 值。该模型对室内实验充填体强度值 S_L 的预测性能较好, 在预测时其平均相对误差 MRE 为 2.41%, 可决系数 R^2 为 0.992。采用所建模型并联合强度折减系数 k , 成功预测并分析了某矿山井下 263 条进路内充填体的实际生产测定值 S_E , 为开采充填采场相邻矿体的支护工作提供了及时有效的指导。

关键词: 充填体强度; 智能预测; 人工神经网络; 粒子群算法; 强度折减

文章编号:

中图分类号: TD853

文献标志码: A

充填采矿法由于其具有矿石回收率较高, 损失贫化小, 开采过程绿色、安全、经济等优点, 因而受到了越来越多矿山的青睐^[1]。在矿山充填系统试运行期间, 充填料浆的配合比处于不断的调整与变化中, 导致实际充填体强度也在随之不断的变化。因此如何快速准确的获取试运行期间充填体的强度, 为充填采场周围矿石的安全开采提供及时指导是充填矿山普遍面临的问题^[2]。此外, 获得充填体强度的主要方法还是采用充填体试块的单轴抗压强度实验, 这就使得充填体强度确定工作变得十分的耗时费力^[3]。因此, 寻找一种迅速、经济、高精度的充填体强度预测方法具有很强的必要性。

近些年来, 国内外学者针对充填体的强度预测方法进行了广泛的研究, 如邓代强等采用二阶逐步回归方法得到影响因素与充填体强度之间的模型, 并通过公式变形, 反演出水泥用量^[4]。李典和赵国彦等采用响应面法对充填体强度进行预测, 在实验范围内可以获得较准的预测结果^[5-6]。但充填体是一种复杂的多相复合材料, 影响其强度的各因素之间具有高度的非线性, 所以很难用回归方法建立具有函数关系的数学解析模型来描述上述关系^[7]。随着人工智能技术的发展,

智能算法为充填材料复杂特性的研究提供了新途径。其中, 神经网络因其具有收敛速度快, 鲁棒性强, 映射能力好等优点而被广泛使用。Qi 等采用 BP 神经网络预测了尾砂类型、灰砂比以及养护时间影响下的充填体的强度^[8]。魏微等采用 BP 神经网络模型协同正交试验对充填体强度进行了预测, 预测误差为 4.23%^[9]。刘恒亮等通过建立 BP 神经网络预测了料浆浓度、灰砂比、减水剂掺量影响下的全尾砂充填体 28 d 强度, 预测的最大误差为 9.98%^[10]。但是由于上文所采用的传统 BP 神经网络的预测精度受网络初始权值和阈值影响较大, 单独使用时会降低预测的效果^[11]。此外, 采用上述方法开展的充填体强度预测通常以室内试验结果为依据, 实际上充填配合比室内试验结果和实际生产时在充填搅拌站取样测定的充填体强度值(下文简称实际生产充填体强度值 S_E)之间还存在较大的不同。一个采场的实际充填体强度值是否达到设计要求应该以实际生产充填体强度值 S_E 为参考依据, 因此上述方法在工程应用方面存在较大的误差。

为此, 本文基于人工神经网络(Artificial Neural Network, ANN)以及粒子群算法(Particle Swarm Optimization, PSO), 建立了一种 ANN-PSO 智能预测

模型。即首先利用粒子群算法对人工神经网络进行优化, 获得了最优的网络初始权值和阈值, 进而实现其对室内充填体试块强度的高精度预测。然后定义并计算了充填体强度预测折减系数 k , 通过联合以上智能预测模型以及折减系数 k , 预测并分析了某矿山 263 条进路充填体的实际生产充填体强度值 S_E , 对充填搅拌站试运行初期充填采场周围矿石的安全开采提供了及时的指导作用, 最终实现了上述进路的安全开采。同时, 采用该方法也可大幅减少日常充填体强度的取样和检测频率, 降低日常充填体强度检测工作量, 还可以根据井下采场充填体强度的实际需求, 快速、灵活的调节充填配合比, 在保证安全开采的前提下最大限度降低充填成本。

1 充填配合比实验

1.1 实验背景及方案设计

某金矿矿体主要以薄至中厚层状、细砂岩、粉砂岩和粘土岩为主, 厚度 0.62m-33m, 倾角 55° - 85° , 矿区地质构造发育, 岩体具有易风化、遇水泥化的特征。采矿方法为机械化盘区上向进路胶结充填开采, 采用高浓度胶结充填模式。充填骨料采用浮选尾砂和机制人工砂, 胶结材料选用 32.5 级复合硅酸盐水泥。在充填搅拌站试运行初期, 充填料浆体积分数为 64%~76%, 水泥掺量为 12%~32%, 人工砂尾砂比为 1.4~5.4。在试运行 7 个月内, 共充填进路 263 条, 其中 160 条进路为打底充填进路。但由于充填系统建设不完善, 没有监测各采场的充填体实际强度, 为后期相邻进路, 尤其是下部采场的安全开采留下了较大的安全隐患。为此, 开展了一系列充填配合比室内试验。根据以上各因素水平值, 确定实验方案见表 1。

1.2 实验过程及结果

按照上述各充填配合比方案配制充填料浆, 利用搅拌机搅拌至均匀, 再浇注至 $\Phi 80$ mm \times 200 mm 的圆柱型试模内, 常温下养护 24 h 后搬运至养护室, 养护室温度为 30°C , 湿度为 95%。待试块养护至预定龄期后, 将其取出用切割机切割为 $\Phi 80$ mm \times 160 mm 的标准试件, 然后应用 WES-100 型液压万能试验机测定其 7 d、14 d、28 d 的单轴抗压强度值, 每龄期的充填体试块测试 3 块, 取其平均值作为该龄期充填体试块的单轴抗压强度值, 实验结果统计见表 1。

2 充填体强度预测

2.1 数据归一化

本文通过以上实验得到了 75 组实验数据, 从中随机抽取 65 组作为训练集, 10 组作为测试集^[12]。其中训练集用来进行模型的训练, 测试集用来评价模型的预测性能。同时, 为了避免因输入量之间数量级差异过大而导致预测精度下降, 所以在网络训练之前对输入数据进行归一化处理, 使其分布在 [0,1] 之间。本文归一化所采用的函数为:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

$$y'_i = \frac{y_i - y_{\min}}{y_{\max} - y_{\min}} \quad (2)$$

式中: x'_i , y'_i 代表归一化后的输入\输出值, x_i , y_i 代表归一化之前的输入\输出值, x_{\min} , x_{\max} , y_{\min} , y_{\max} 分别代表输入\输出数据变化范围的最小值和最大值。

2.2 ANN 预测模型的建立

目前, 最广泛使用的 ANN 类型是 BP(Back Propagation)神经网络, 这种神经网络由输入层、隐含层和输出层组成^[13]。预测模型的第一层称为输入层, 因为本文中主要研究料浆体积分、水泥掺量、人工砂尾砂比以及养护时间对充填体强度的影响, 所以输入层神经元个数为 4 个。模型的第三层为输出层, 输出层包含 1 个神经元, 代表各龄期的室内实验充填体强度值 S_L 。第二层称为隐含层, 隐含层神经元个数对模型的预测精度有着很大的影响, 但目前针对隐含层最佳神经元个数的确定并没有非常精准的计算公式。因此, 本文建立了两种包含不同隐含层神经元个数(隐含层神经元数的变化范围为 5-12)的 BP 神经网络模型。其中, 一种采用 PSO 算法对网络权值和阈值进行了优化, 另一种为传统网络即权值和阈值不经过任何优化。并将两者进行预测性能比较, 以此获得最佳的隐含层神经元个数以及同时验证 PSO 算法优化是否有效。在本模型中训练算法采用 Levenberg-Mrquardt 算法, 隐含层采用的传递函数为 logsig, 输出层采用的传递函数为 purelin, 训练的次数设为 3000, 学习率取 0.2, 动量系数取 0.7^[14]。

2.2 PSO 优化 ANN 预测模型

PSO 算法是一种强大的全局优化算法, 是对鸟群

捕食行为的模拟。在 PSO 中, 每只鸟都代表一个“粒子”, 并且每个粒子都包含有位置和速度这两个属性^[15]。联系本文实际, 粒子位置代表网络的初始权值和阈值, 速度表示初始权值和阈值每次更新时的幅度大小。PSO 算法优化 ANN 初始权值和阈值的运行流程

如图 1 所示, 优化具体步骤如下:

- 1) 建立 BP 神经网络拓扑结构。
- 2) 粒子位置和速度初始化。通过生成一群具有随机位置和速度的粒子(随机解)来完成初始化。
- 3) 计算粒子适应度值。适应度值由适应度函数计

Table 1 Experimental arrangements and results

No.	slurry	cement	ratio of artificial aggregate and tailings	UCS/MPa			No.	slurry	cement	ratio of artificial aggregate and tailings	UCS /MPa		
	density /%	dosage /%		7d	14d	28d		density /%	dosage /%		7d	14d	28d
1	64	12	1.4	0.2	0.3	0.6	14	70	27	1.4	1.7	2.9	4.0
2	64	17	2.4	0.3	0.6	1.0	15	70	32	2.4	2.4	3.4	5.7
3	64	22	3.4	0.5	0.7	1.1	16	73	12	4.4	0.4	0.7	0.9
4	64	27	4.4	0.6	1.3	2.1	17	73	17	5.4	1.1	1.6	2.4
5	64	32	5.4	1.0	1.4	2.2	18	73	22	1.4	1.7	2.9	4.5
6	67	12	2.4	0.4	0.6	0.7	19	73	27	2.4	2.3	3.2	5.1
7	67	17	3.4	0.4	0.7	1.1	20	73	32	3.4	3.4	5.1	6.7
8	67	22	4.4	0.6	0.7	1.1	21	76	12	5.4	0.6	0.9	1.5
9	67	27	5.4	0.8	1.6	1.8	22	76	17	1.4	1.5	1.6	2.9
10	67	32	1.4	1.8	3.0	4.1	23	76	22	2.4	2.2	2.7	5.8
11	70	12	3.4	0.4	0.6	1.0	24	76	27	3.4	3.3	4.7	7.6
12	70	17	4.4	0.6	1.0	1.4	25	76	32	4.4	4.8	5.7	10.2
13	70	22	5.4	0.9	1.2	2.2							

算得到, 在本文中适应度函数采用均方误差 MSE , MSE 值越小表示该粒子越优, MSE 计算公式如下式所示。

$$MSE = \frac{1}{n} \sum_{i=1}^n (p_i - y_i)^2 \quad (3)$$

式中: n 为样本数据总数, y_i , p_i 分别为实验值和预测值。

4) 粒子速度和位置更新。首先比较新粒子的适应度值和个体极值 P_{best} 、群体极值 G_{best} 的适应度值, 如果发现当前粒子比以往发现的粒子更好, 则根据种群中的群体极值 G_{best} 和粒子本身的个体极值 P_{best} 调整粒子的速度和位置。粒子的速度和位置更新公式为:

$$V_{id}(t+1) = w(t)V_i(t) + c_1 r_1 (P_{ibest}(t) - X_{ibest}(t)) + c_2 r_2 (G_{best}(t) - X_{ibest}(t)) \quad (4)$$

$$X_{id}(t+1) = X_{id}(t) + V_{id}(t+1) \quad (5)$$

式中: r_1 和 r_2 为 [0,1] 内均匀分布的随机数; c_1 和 c_2 为学习因子, 取为 1.8; w 为惯性权重 $w_{start}=0.9$, $w_{end}=0.4$; $P_{id}(t)$ 为第 i 个粒子自身最优位置, $G_d(t)$ 为群体最优位置, $X(t)$ 为粒子的当前位置^[16]。

PSO 算法粒子个体长度为 55, 迭代次数为 100 次。在完成所设定的迭代次数后, 将经过更新的适应度最优粒子所包含的权值和阈值作为网络的最优初始权值和阈值。

5) ANN-PSO 预测。利用实验样本数据对经过优化的神经网络进行训练, 得到最优的模型来对充填体的室内强度进行预测。

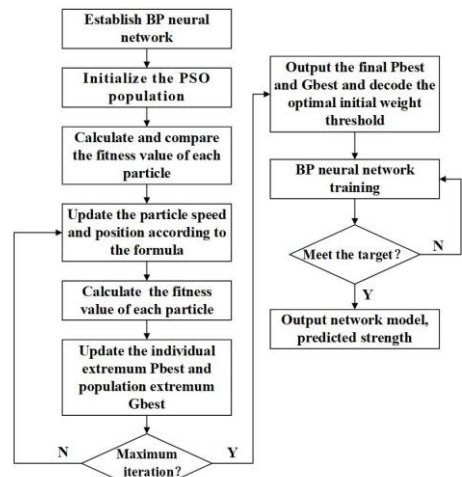


图 1 PSO 优化 ANN 流程图

Fig.1 Flowchart of PSO optimizes ANN

3 模型预测结果分析

3.1 模型拓扑结构确定及 PSO 优化效果

在本文中,模型预测效果采用平均相对误差 MRE 和可决系数 R^2 来进行评价,其中 MRE 值越低、 R^2 值越靠近 1 则模型预测效果越好,其计算公式如下式(6)、(7)所示。

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(y_i - p_i)}{y_i} \right| \times 100 \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (7)$$

式中: y_i , p_i 分别为实验值和预测值, \bar{y}_i 为实验值的平均值。

图 2, 3 所示为不同数量隐含层神经元数与测试集平均相对误差 MRE 、可决系数 R^2 的关系图。由图 2 可以看出,经过 PSO 算法优化后,模型预测的平均相对误差率有了明显的下降,其下降值最大为 17.31%。由图 3 可以看出,经 PSO 算法优化后,模型的拟合优度有了明显的提升, R^2 值的最大提升量为 0.032。以上两个评价指标的表现,综合说明了 PSO 算法在优化 ANN 中的有效性。

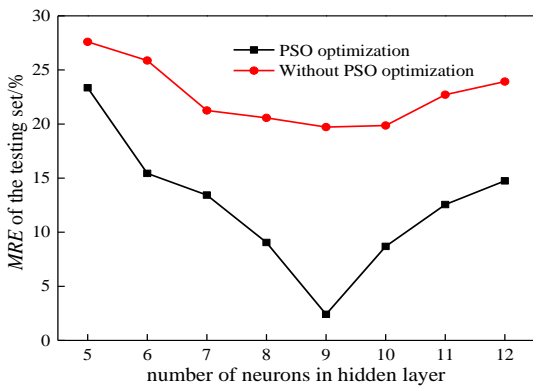


图 2 隐含层神经元数与平均相对误差关系图
Fig.2 Relation between number of neurons in hidden layer and MRE

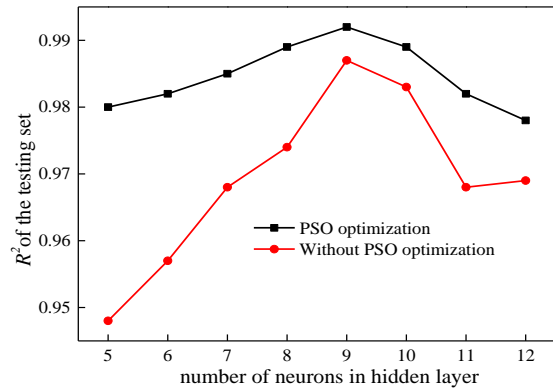


图 3 隐含层神经元数与可决系数关系图
Fig.3 Relation between number of neurons in hidden layer and R^2

同时,观察图 2 可发现,无论模型是否经过优化,在节点数小于 9 时,其 MRE 值总是呈现出逐渐降低的趋势,但当节点数大于 9 时,其 MRE 值却会突然升高。对比图 3 也可发现此相同规律,当节点数小于 9 时,模型 R^2 值在不断提高,当节点数超过 9 时,其 R^2 值则会大幅降低。出现此现象的主要原因是当隐含层节点数过少时,则无法在输入和输出之间建立有效的映射来表达它们之间的非线性关系,所以预测精度会变差。当隐含层节点数过多时,网络的复杂度则会大大增加,进而导致过拟合现象的产生,使预测精度产生大幅下降。所以,当隐含层神经元数为 9 时,模型具有最佳的预测性能,其测试集的 MRE 值为 2.41%, R^2 值为 0.992。最后经综合考虑,隐含层神经元个数取 9,形成的网络结构为 4-9-1 结构,其示意图如图 4 所示。

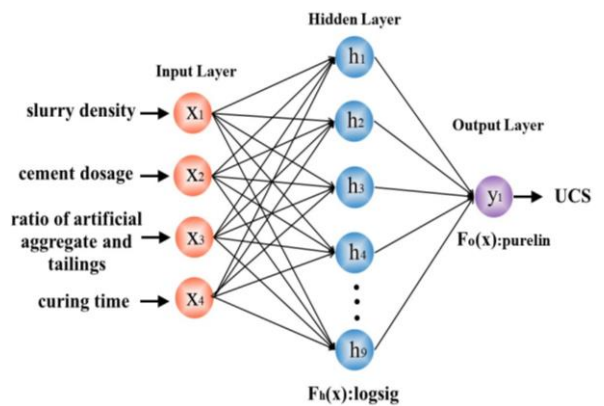


图 4 网络结构图
Fig.4 Artificial neural network structure

3.2 ANN-PSO 模型预测效果

图 5 所示为采用以上所建 ANN-PSO 模型对充填体室内实验强度 S_L 进行预测的预测值和实验值对比图。由 a 图可以看出,训练集的预测值曲线和实验值

曲线之间的贴合度较好, 其 MRE 值为 1.77%。由 c 图可以看出, 测试集的预测值和实验值之间除了极个别点的误差较大外, 其余点数据都吻合的特别好, 其 MRE 值为 2.41%。图 b、d 表明, 训练集和测试集的回归结果较优, 其 R^2 值分别为 0.997 和 0.992。特别是对于训练集, 散点与图中理想曲线几乎重合(即预测

值等于测试值), 而对于测试集, 则存在一定的离散性。以上结果综合说明了该模型训练良好, 避免了拟合不足和过拟合, 能准确的表达各影响因素和强度之间的非线性关系, 对室内实验充填体强度 S_L 的预测具有较好效果。

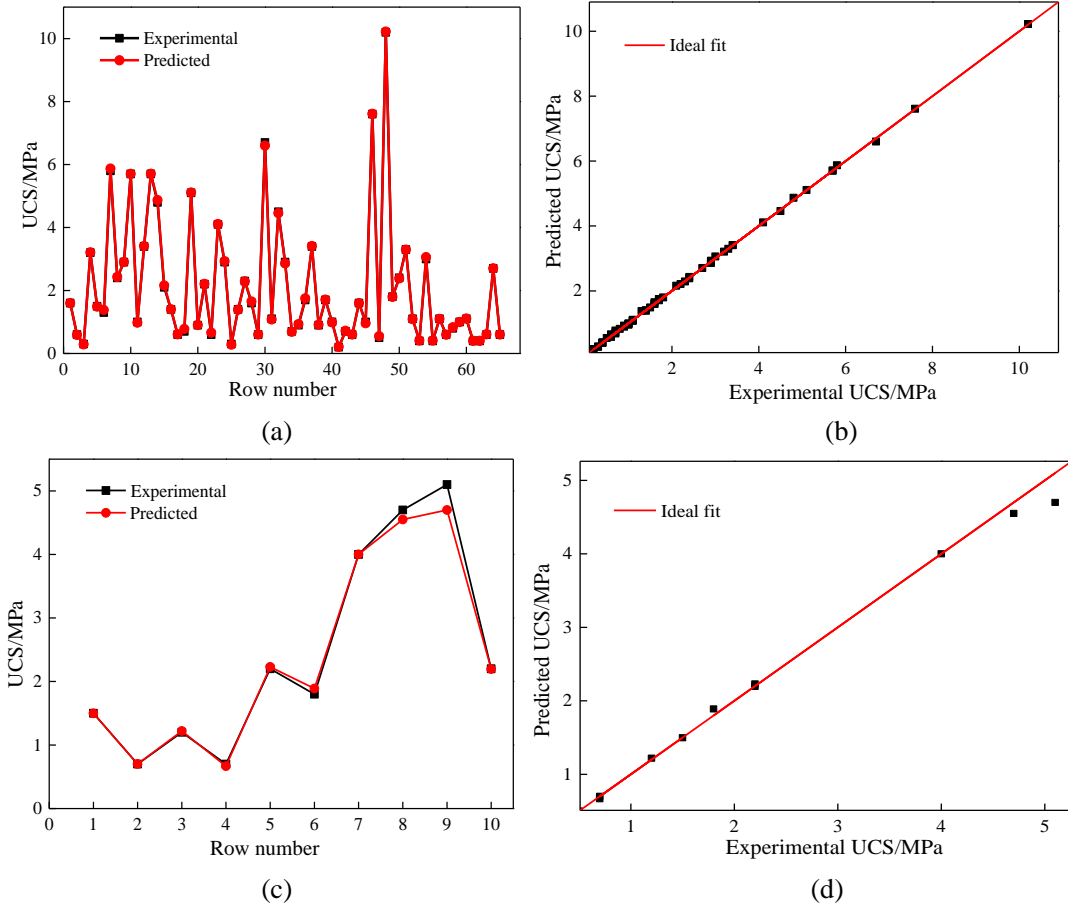


图 5 模型预测性能图

Fig.5 Model prediction performance: (a) training set error (b) regression of training set results (c) testing set error (d) regression of testing set results

为了进一步说明所建立的 ANN-PSO 模型在充填体强度预测方面的优越性, 本文利用以上训练集数据对室内实验充填体强度值 S_L 与各影响因素之间的关系进行了多元非线性回归分析, 得到的拟合公式如式 (8)所示。

$$\begin{aligned}
 S_L = & 0.051 - 0.074X_1^{0.258} - 0.028X_2^{0.534} - 0.076X_3^2 \\
 & - 0.002X_3 - 0.003X_1^2 + 0.35X_1X_2 + 0.14X_1X_3 \quad (8) \\
 & + 0.25X_1X_4 + 0.064X_2^2 + 0.048X_2X_3 + 0.27X_2X_4 \\
 & - 0.094X_3X_4 - 0.03X_4^2
 \end{aligned}$$

式中: S_L 为室内实验充填体强度值, X_1 为料浆体积分数, X_2 为水泥掺量, X_3 为人工砂尾砂比, X_4 为养护时间。

首先利用 F -检验法对回归方程进行显著性检验,

计算得该方程的 F 值为 219.7。在给定 $\alpha=0.05$ 的条件下, 查 F 分布表得到 $F_{0.05}(4,70)=2.37$ 。因 $F=219.7 > 2.37$, 所以该拟合方程是显著的, 具有统计学意义。

进一步分析可得, 该拟合公式对训练集数据进行预测时, 其 MRE 值为 22.15%, R^2 值为 0.97。但在对测试集数据进行预测时, 其 MRE 和 R^2 值却达到了 92.07% 和 0.44。这说明了尽管拟合公式对训练集内的数据预测效果较好, 但是当遇到训练集外的数据时, 则将不能表现出可接受的预测效果。同时分析拟合过程可发现, 多元非线性拟合实际上是输入因素以及输入因素的多次方项的线型组合, 那么其最多只能较为完美的表现一些非线性因素的线性关系^[17-18], 所以用某种特定的多元非线性函数形式来描述上述关系显得并不合理。而神经网络在预测时无需事前揭示描述这

种关系的数学函数形式,其能够学习和储存大量的输入-输出模式映射关系,即对一个输入,它能最大程度的输出一个和实际情况相符的概率分布,从而实现结果的高精度预测^[19]。所以通过以上预测结果对比及分析,说明在面对预测该矿充填体强度这类高非线性问题时,所建的 ANN-PSO 模型最大的优势不仅在于对训练集内数据的精准预测,更重要的是对训练集外数据同样具备精准预测能力,所以相较其他预测方法,ANN-PSO 模型能够完全胜任室内实验充填体强度 S_L 的预测工作。

4 工程应用

4.1 充填强度折减

因为井下采场充填体的强度值很难获得,所以国内充填矿山在运行时,通常是以实际生产充填体强度值 S_E 作为参考依据。之前研究人员采用其他方法进行预测的基本为室内实验充填体试块的强度,而并非更具工程指导意义的实际生产充填体强度值 S_E ,因此在工程应用中具有很强的局限性。并且分析实验数据发现,在配合比相同的条件下,充填时实际生产充填体强度值 S_E 要明显低于室内实验所测得的强度值 S_L 。出现此现象的主要原因为:1)料浆搅拌方式的不同:充填搅拌站一般采用双卧式搅拌或立式+卧式搅拌等组合,室内实验一般采用小功率搅拌机。由于两者在功率、转速、搅拌量以及叶片排列方式等方面有很大差异,所以导致两者充填料浆的均匀性有较大差别。同室内搅拌效果相比,充填站搅拌效果相对稍差,充填料浆流入钻孔前,料浆内可能还有部分尚未搅散的水泥团块。研究表明,料浆活化性能决定着料浆的制备质量,充填料浆在搅拌过程中,通过机械力化学效应得到混合与活化,使物料在宏观和微观上达到均质。通过改进搅拌方式,可以将塌落度和扩展度分别提高 11.5% 和 56.8%,28 d 强度提高 189%,有效改善了料浆的输送和力学性能^[20]。2)取料位置的不同:由于在充填站取样时,一般只能在搅拌槽液面附近取样,而此处料浆的体积分数较小,所含的细粒级物料较多,进而导致其制备的充填体单轴抗压强度同室内实验相比较小^[21-22]。3)物料计量损失:搅拌站采用冲板流量计、微粉秤、盘式给料机、流量计等进行水泥、砂石和尾砂浆的称重计量,同室内实验所用的计量秤相比,称量误差较大。

针对目前相关研究的欠缺,因此考虑引入充填体强度预测折减系数的概念,将其定义为

$$k = S_L / S_E \quad (9)$$

式中: S_L 室内实验充填体强度值, S_E 实际生产充

填体强度值。

通过对比上文室内实验充填体强度值 S_L ,与在充填搅拌站采用相同配合比时取样获得的 482 组充填体单轴抗压强度值的统计平均值进行比较,计算得到如下折减系数 $k_{7d}=1.76$, $k_{14d}=1.74$, $k_{28d}=1.76$,相同配合比下室内实验强度值 S_L 和实际生产充填体强度值 S_E 部分对比数据见图 6。

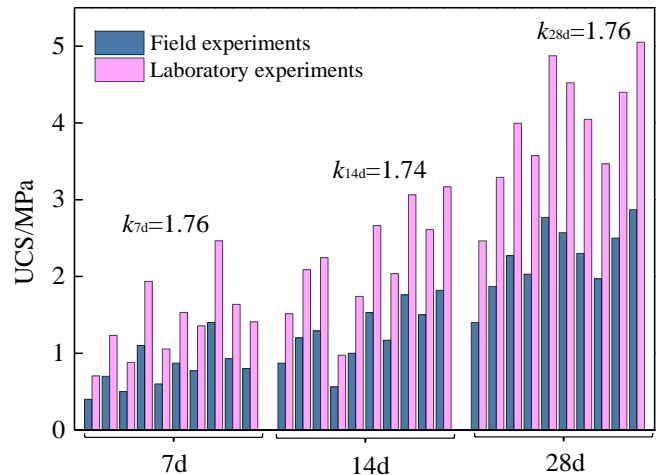


图 6 室内实验强度值 S_L 和实际生产强度值 S_E 对比

Fig.6 Comparison of laboratory test strength value S_L and field experiments test strength value S_E

4.2 各采场充填体强度预测分析

4.2.1 打底充填强度预测及分析

将充填系统试运行期间的 160 条打底充填进路配合比输入至 ANN-PSO 模型中,可得到各条进路的室内实验充填体强度值 S_L 。将预测得到的室内实验充填体强度值 S_L 乘以相对应的折减系数,最终得到实际生产充填体强度值 S_E 。预测结果统计分布如图 7。

由图 7 预测结果可得:有 57.5% 的打底充填体 7 d S_E 强度超过 0.6 MPa,26.8% 的打底充填体 14 d S_E 强度超过 1.2 MPa,88.1% 的打底充填体 28 d S_E 强度超过 1.2 MPa。依据该矿标准,打底充填 28 d 实际生产测定值 S_E 须大于 1.2 MPa,因此 88.1% 的打底充填体 28 d S_E 强度超过 1.2 MPa,但仍存在 19 条进路充填体 S_E 强度不符合要求。所以在开采上述 19 条进路时,采取了如下安全措施:当 S_E 强度在 0.6-1.2 MPa 时,采用缩小进路宽度至 3.5-4.0m、进路顶、帮采用了喷锚网支护施工工艺,其中管缝锚杆规格为 $\phi 47.5\text{mm} \times 2.4\text{m}$,间排距为 $1.2\text{m} \times 1.2\text{m}$,喷射混凝土采用 C25 的混凝土标号,厚度 60mm,钢网网孔规格为 $100\text{mm} \times 100\text{mm} \times \phi 5\text{mm}$,避免了顶板充填体的冒落。当 S_E 强度小于 0.6 MPa 时,对于部分矿量比较小的进路则放弃开采,对于矿量比较大的进路,主要采取了如下方法:1)如果工程允许,尽量实施上下进路交叉开采,

降低了低强度充填体顶板的暴露面积; 2) 掘进至低强度充填体时, 实施短掘短支的施工工艺, 每循环进尺不超过 1.5m; 3) 实施喷锚网+长锚索支护工艺, 其中喷锚网支护参数同前, 长锚索尺寸为 $6\text{m} \times \phi 15.24\text{mm}$, 间排距为 $2.0\text{m} \times 2.0\text{m}$ 。通过上述支护措施, 实现了低强度充填体进路的安全开采。




图7 打底充填进路充填体 S_E 强度预测值

Fig.7 Inferred values of strength of fill mate S_E : (a) curing time is 7 days; (b) curing time is 14 days; (c) curing time is 28 days

4.2.2 非打底充填强度预测及分析

非打底充填是指在充填时料浆的灰砂比同打底充填相比较低, 不起主要承载作用, 其形成的充填体只需满足相邻进路开采的强度要求和各类行走装备的运行要求^[23]。依据该矿标准, 非打底充填 28 d S_E 强度须大于 0.3 MPa。

按照上述方法, 可以计算得到非打底充填各进路的充填体 S_E 强度, 预测结果统计分布如图 8。图 8 预测结果显示, 有约 81.6% 的非打底充填体 7 d S_E 强度高于 0.3 MPa, 有约 84.5% 的非打底充填体 14 d S_E 强度高于 0.3 MPa, 有约 97.1% 的非打底充填体 28 d S_E 强度高于 0.3 MPa。对照该矿安全标准, 依然有 3 条

进路充填体不符合安全开采要求。故在开采上述 3 条进路的相邻矿体时, 对暴露的充填体侧帮实施了管缝锚杆+钢网+喷射混凝土支护, 以防充填体片帮或者顶板冒落。

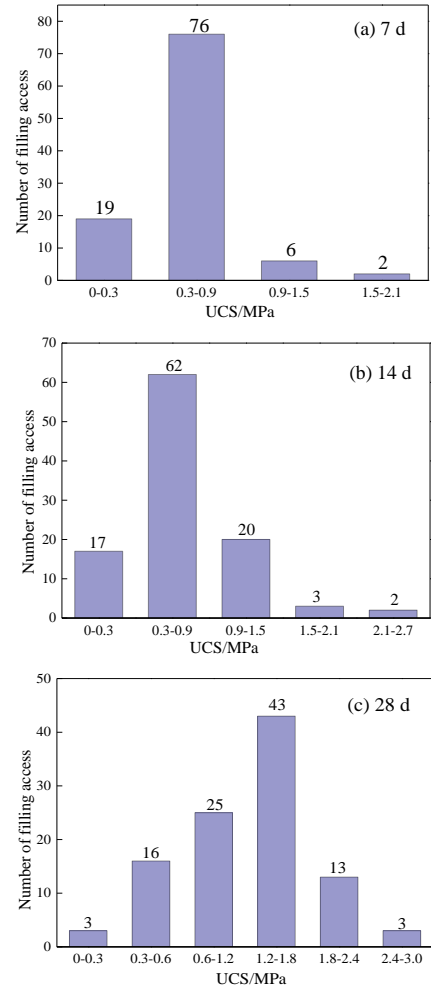


图8 非打底充填进路充填体 S_E 强度预测值

Fig.8 Inferred values of strength of non-fill mate S_E : (a) curing time is 7 days; (b) curing time is 14 days; (c) curing time is 28 days

5 结论

1) 本文采用 PSO 算法对传统的人工神经网络进行优化, 建立了一种 ANN-PSO 智能预测模型, 其预测平均相对误差 MRE 为 2.41%, 可决系数 R^2 为 0.992。同未采用的预测模型比较, 其 MRE 值下降了 17.31%, R^2 值提高了 0.032, 实现了对室内实验充填体强度值 S_L 的高精度预测;

2) 实验发现, 相同配合比下的室内实验强度值 S_L 及实际生产充填体强度值 S_E 之间存在较大差距。为此定义了充填体强度预测折减系数的概念, 通过计算获得了具体的强度折减系数, 即 $k_{7d}=1.76$, $k_{14d}=1.74$,

$k_{28d}=1.76$;

3) 利用 ANN-PSO 模型并联合充填体强度预测折减系数 k , 预测并分析了矿山 263 条进路充填体的实际生产充填体强度值 S_E 。预测结果表明, 有 19 条打底充填进路和 3 条非打底充填进路的充填体强度低于设计值, 在生产时必须采取安全有效的支护措施;

4) 本文提出的建立 ANN-PSO 模型并联合充填体强度预测折减系数的充填体强度预测分析方法, 不仅能快速确定实际生产充填体强度值, 为开采充填采场相邻矿体的支护工作提供及时指导, 还可作为日常充填体强度的监测手段, 减少日常充填体强度测试频率。对其他矿山的类似情况具有良好的借鉴作用。

REFERENCES

- [1] 吴爱祥, 杨莹, 程海勇, 陈顺满, 韩悦. 中国膏体技术发展现状与趋势[J]. 工程科学学报, 2018, 40(05): 517-525.
WU Ai-xiang, YANG Ying, CHENG Hai-yong, CHEN Shun-man, HAN Yue. Status and prospects of paste technology in China[J]. Chinese Journal of Engineering, 2018, 40(5): 517-525.
- [2] 韩斌, 王贤来, 肖卫国. 基于多元非线性回归的井下采场充填体强度预测及评价[J]. 采矿与安全工程学报, 2012, 29(05): 714-718.
HAN Bin, WANG Xian-lai, XIAO Wei-guo. Estimation and Evaluation of Backfill Strength in Underground Stope Based on Multivariate Nonlinear Regression Analysis[J]. Journal of Mining & Safety Engineering, 2012, 29(5): 714-718.
- [3] 徐淼斐, 高永涛, 金爱兵. 基于超声波波速及 BP 神经网络的胶结充填体强度预测[J]. 工程科学学报, 2016, 38(08): 1059-1068.
XU Miao-fei, GAO Yong-tao, JIN Ai-bing. Prediction of cemented backfill strength by ultrasonic pulse velocity and BP neural network[J]. Chinese Journal of Engineering, 2016, 38(8): 1059-1068.
- [4] 邓代强, 姚中亮, 朱永建, 汪令辉. 胶结充填体强度预测及水泥消耗量反演计算[J]. 中国矿业大学学报, 2013, 42(1): 39-44.
DENG Dai-qiang, YAO Zhong-liang, ZHU Yong-jian, WANG Ling-hui. Forecasting cemented backfill strength: backcalculation of cement dosage[J]. Journal of China University of Mining & Technology, 2013, 42(1): 39-44.
- [5] 李典, 冯国瑞, 郭育霞. 基于响应面法的充填体强度增长规律分析[J]. 煤炭学报, 2016, 41(2): 392-398.
LI Dian, FENG Guo-rui, GUO Yu-xia. Analysis on the strength increase law of filling material based on response surface method[J]. Journal of China Coal Society, 2016, 41(2): 392-398.
- [6] 赵国彦, 马举, 彭康, 杨清, 周礼. 基于响应面法的高寒矿山充填配比优化[J]. 工程科学学报, 2013, 35(5): 559-565.
ZHAO Guo-yan, MA Ju, PENG Kang, YANG Qing, ZHOU Li. Mix ratio optimization of alpine mine backfill based on the response surface method[J]. Chinese Journal of Engineering, 2013, 35(5): 559-565.
- [7] FENG De-cheng, LIU Zhen-tao, WANG Xiao-dan, CHEN Yin, CHANG Jia-qi, WEI Dong-fang, JIANG Zhong-ming. Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach[J]. Construction and Building Materials, 2020, 230: 1-11.
- [8] QI Chong-chong, Andy F, CHEN Qiu-song. Neural network and particle swarm optimization for predicting the unconfined compressive strength of cemented paste backfill[J]. Construction and Building Materials, 2018, 159: 473 - 478.
- [9] 魏微, 高谦. 改进的 BP 神经网络模型预测充填体强度[J]. 哈尔滨工业大学学报, 2013, 45(6): 90-95.
WEI Wei, GAO Qian. Strength prediction of backfilling body based on modified BP neural network[J]. Journal of Harbin Institute of Technology, 2013, 45(6): 90-95.
- [10] 刘恒亮, 张钦礼, 王新民, 肖崇春. 全尾砂充填体正交-BP 神经网络强度预测[J]. 金属矿山, 2016, 39(1): 43-46.
LIU Heng-liang, ZHANG Qin-li, WANG Xin-min, XIAO Chong-chun. Strength Prediction of Unclassified Tailing Backfilling Based on Orthogonal-BP Neural Network[J]. metal mine, 2016, 39(1): 43-46.
- [11] Ehsan M, Danial J A, Mohsen H. Prediction of uniaxial compressive strength of rock samples using hybrid particle swarm optimization-based artificial neural networks[J]. Measurement, 2015, 60: 50-63.
- [12] Behnam J, Mohamad R, Farnaz J. Using PSO-GA algorithm for training artificial neural network to forecast solar space heating system parameters[J]. Applied Thermal Engineering, 2019, 147: 647-660.
- [13] 田庆华, 洪建邦, 辛云涛, 郭学益. 基于人工神经网络模型的含锑硫化矿氧化浸出行为预测[J]. 中国有色金属学报, 2018, 28(10): 2103-2111.
TIAN Qing-hua, HONG Jian-bang, XIN Yun-tao, GUO Xue-yi. Prediction for oxidation leaching behavior of antimony containing sulfide ore based on artificial neural network model[J]. The Chinese Journal of Nonferrous Metals, 2018, 28(10): 2103-2111.

- [14] 周科平, 王星星, 高峰. 基于强度折减与 ANN-GA 模型的采场结构参数优化[J]. 中南大学学报(自然科学版), 2013, 44(7): 2848-2854.
ZHOU Ke-ping, WANG Xing-xing, GAO Feng. Stope structural parameters optimization based on strength reduction and ANN-GA model[J]. Journal of Central South University (Science and Technology), 2013, 44(7): 2848-2854.
- [15] 马驰, 赵亮, 梅雪松. 基于粒子群算法与 BP 网络的机床主轴热误差建模[J]. 上海交通大学学报, 2016, 50(5):686-695.
MA Chi, Zhao Liang, MEI Xue-song. Thermal error modeling of machine tool spindle based on particle swarm optimization and neural network[J]. Journal of Shanghai Jiao Tong University, 2016, 50(5):686-695.
- [16] QI Chong-chong, Andy F, CHEN Qiu-song, ZHANG Qin-li. A strength prediction model using artificial intelligence for recycling waste tailings as cemented paste backfill[J]. Journal of Cleaner Production, 2018, 183:566-578.
- [17] XU Jin-jun, ZHAO Xin-yu, YU Yong. Parametric sensitivity analysis and modelling of mechanical properties of normal- and high-strength recycled aggregate concrete using grey theory, multiple nonlinear regression and artificial neural networks[J]. Construction and Building Materials, 2019, 211: 479-491.
- [18] Zain M F M, Abd S M. Multiple regression model for compressive strength prediction of high performance concrete[J]. Journal of Applied Science, 2009, 9(1): 155-160.
- [19] QI Chong-chong, CHEN Qiu-song, Fourie A. An intelligent modelling framework for mechanical properties of cemented paste backfill[J]. Minerals Engineering, 2018, 123:16-27.
- [20] 王洪江, 杨柳华, 王勇, 吴爱祥, 周旭, 张连富. 全尾砂膏体多尺度物料搅拌均质化技术[J]. 武汉理工大学学报, 2017, 39(12):76-80.
WANG Hong-jiang, YANG Liu-hua, WANG Yong, WU Ai-xiang, ZHOU Xu, ZHANG Lian-fu. Multi-scale materials' dispersive mixing technology of unclassified tailings paste[J]. Journal of Wuhan University of Technology, 2017, 39(12):76-80.
- [21] 王新民, 赵建文, 张德明. 全尾砂絮凝沉降速度优化预测模型[J]. 中国有色金属学报, 2015, 25(3): 793-798.
WANG Xin-min, ZHAO Jian-wen, ZHANG De-ming. Optimal prediction model of flocculating sedimentation velocity of unclassified tailings[J]. The Chinese Journal of Nonferrous Metals, 2015, 25(3): 793-798.
- [22] 杨柳华, 王洪江, 吴爱祥, 李红, 高维鸿. 全尾砂戈壁集料膏体充填粒级优化[J]. 中国有色金属学报, 2016, 26(07):1552-1558.
YANG Liu-hua, WANG Hong-jiang, WU Ai-xiang, Li Hong, GAO Wei-hong. Gradation optimization of unclassified tailings paste with Gobi aggregates[J]. The Chinese Journal of Nonferrous Metals, 2016, 26(07):1552-1558.
- [23] 付建新, 杜翠凤, 宋卫东. 全尾砂胶结充填体的强度敏感性及其破坏机制[J]. 北京科技大学学报, 2014, 36(9):1149-1157.
FU Jian-xin, DU Cui-feng, SONG Wei-dong. Strength sensitivity and failure mechanism of full tailings cemented backfills[J]. Journal of University of Science and Technology Beijing, 2014, 36(9): 1149-1157.

Prediction of backfill strength in underground stope based on strength reduction and intelligent algorithm

JI Kun, HAN Bin, HU Ya-fei, WU Fan, QIU Jian-hui

(School of Civil and Resource Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: Backfill mix proportion changes greatly during the test running of backfill system, thus, obtaining the backfill strength of particular stopes accurate and timely plays an important role in the safety of mining in adjacent stopes. This paper firstly established an ANN-PSO intelligent prediction model by taking slurry density, cement dosage, ratio of artificial aggregate and tailings and curing time as input factors, and uniaxial compressive strength of laboratory backfill as output factors. Subsequently, the concept of predicted strength reduction coefficient of backfill was defined, and the strength reduction coefficient k was obtained by comparing the backfill strength of laboratory experiments and backfill strength of actual production under the same mix proportion. The model showed a good prediction performance for the backfill strength of laboratory experiments, with a mean relative error (*MRE*) of 2.41% and a determination coefficient

(R^2) of 0.992. Based on the ANN-PSO model and strength reduction coefficient k , the backfill strength of actual production of 263 access during the running period were predicted and analyzed, which provided guidance timely and effective for the support works of mining in adjacent stopes.

Key words: strength of backfilling body; intelligent prediction; artificial neural network; particle swarm optimization; strength reduction

Foundation item: Project(2018YFC1900603, 2018YFC0604604) supported by the National Key Research and Development Project

Received date: 2020-04-08; **Accepted date:** 2020-05-22

Corresponding author: HAN Bin; Tel: +86-010-62332264; E-mail: cirrus8023@163.com

(编辑 何学峰)