

采场冒顶灾害的声发射预报技术^①

曹庆林 余克圣 桑玉发

(长沙矿山研究院, 长沙 410012)

摘要 简要介绍了用于监测岩体稳定性的声发射源定位系统 SDL-1 和便携式声发射智能监测仪 DYF-1, 这些仪器能获取一个声发射事件所包含的尽量多的信息, 基于这些信息开发了一种有效可靠的预测冒顶技术。该技术利用多个声发射参数(AE 事件率、AE 能量和 m 值) 评价声发射活动, 在这些参数的监测数据基础上应用灰色系统理论预测将来的声发射, 预测值通过训练好的冒顶模式识别, 由人工神经网络模型输出对应的冒顶模式(较大规模的顶板塌落、小规模掉块和稳定)。实例研究表明, 该方法的预测结果与实际情形具有很好的一致性。

关键词 冒顶模式 声发射 灰色理论 神经网络 预测预报

顶板冒落是地下矿山开采过程中常见的灾害, 直接危及井下工作人员、设备和矿山结构(采场、巷道)的安全, 导致有价值的矿产资源的损失。作者采用长沙矿山研究院研制的声发射源定位系统(SDL-1)和预测冒顶的便携式人工智能声发射监测仪(DYF-1)监测岩体的声发射活动, 然后基于这些仪器测取的声发射数据提出冒顶灾害的定量预报方法^[1, 2]。

近年来应用比较广泛的声发射(或微震)监测仪等一类仪器, 一般停留在声发射源位置和事件总数与频度的记录水平上, 而常用的便携式声发射监测仪也只能获取少量的声发射信息, 这些仪器大都无法区分噪音或岩音引起的事件, 而且不能进一步分析其能量频谱, 所以难以提高现场预报的正确性, 也不便对岩石声发射及地压作更深入的理论研究。SDL-1 声发射定位系统用于声发射源的定位, 能模拟人脑思维同时结合模拟信号滤波(由硬件实现)与数字滤波(由软件实现), 自动提取有用声发射信号, 而排除其它噪音信号。

DYF-1 声发射监测仪是用于对岩石工程进行顶板分类, 顶板冒落、片帮预报以及矿山地压综合分析的智能化仪器。本仪器能瞬态记

录地音发生前后或正在发生中的任一时刻波形及每次声发射的主频, 监测顶板局部以某一能量值为基准(可设置任意值)下的地音频度、频率、每次地音发生的时间、发射的能量。通过功能键转换可监视每一时刻的声发射频度、频率, 能量, 总事件数, 平均事件率以及与地音频度和最大振幅相关的指数 m 值等参数。

1 冒顶灾害的预测方法

声发射活动的现场监测分两个步骤: 首先由声发射源定位系统 SDL-1 监测全矿性的声发射, 确定声发射活动的分布状态; 其次, 选择声发射活动比较集中的区段, 利用便携式声发射监测仪 DYF-1 对其作重点监测, 基于 DYF-1 测试的数据研究预报顶板冒落灾害的方法。

如前所述, 岩体破坏的声发射预测很少成功的原因之一是没有完全利用所记录的原始数据, 所以, 我们将同时考虑由 DYF-1 测试的三个声发射参数来评价顶板岩体的冒落:

(1) AE 率 C , 即单位时间的 AE 数是最有用的参数, 而且几乎用在所有用声发射或微震

① 收稿日期: 1995-05-03; 修回日期: 1995-10-13 曹庆林 男, 30岁, 高级工程师

评价岩体破坏过程的研究中。

(2) AE 能量 E , 在一些研究中也经常被考虑为预示岩体破坏的前兆参数。一些微震事件能量分布的现场研究表明, 集中了 35% 以上高能事件的低事件率就显示工作面接近危险。所以取各次抽样间隔内最大能量 AE 事件的能量作为评价指标, 即

$$E = \max((A_i)^2) \quad (1)$$

式中 A_i 为 AE 波最大振幅

(3) m 值。 AE 振幅与事件率之比, 由最大似然法计算如下^[2]

$$m = \frac{n \log e}{\sum (n_i \log A) - n \log A_m} + 1 \quad (2)$$

式中 n 为振幅大于或等于 A_m 的事件总数, n_i 是振幅为 A_i 的事件数, e 为自然对数底。这些被采用的参数基本上是互不相关的, 它们反映了冒顶破坏过程不同方面的变化, 而且是从不同变量的组合计算出来的。

许多研究与我们的测试都表明, AE 数据的时间分布是高度分散歪斜的, 但是可以肯定每次测试的声发射或微震不是随机的而是以前活动的函数, 所以建立预测将来时间声发射活动的数学模型是有可能的。由于 AE 数据的高度歪斜性质, 诸如回归分析之类的传统统计分析方法不适合于整理分析这些测试数据; 即使采用时间序列分析能预报声发射(或微震), 但它需要许多长期监测的数据, 对于短期的冒顶预报, 时间序列分析不是有效的方法。而下面将要讨论的灰色系统理论却是建立那些高度分散的 AE 数据预测模型的有效工具, 它仅仅需要 4 组以上的数据。

虽然通过采用灰色理论能定量预测声发射活动, 由于冒顶的物理机制的复杂性, 声发射参数与冒顶机制以及冒顶何时发生的对应关系仍然无法建立。神经网络作为人工智能中最有吸引力的分支, 对处理这类问题很有潜力, 如果有足够的由冒顶事件和相应的声发射参数组成的样本时, 通过将这些主导的声发射参数 (C, E, m) 视为一个整体, 就可训练神经网络模型, 该模型对灰色模型预测的声发射参数的

外部刺激执行复杂的处理后, 会自动识别冒顶的可能性。

1.1 AE 参数值的灰色预测方法

顶板冒落之前的损伤发展过程可以通过变化的位移、应力和声发射现象表现出来, 由于测试这些物理现象的设备及手段的不完善和岩体冒落机制的复杂性, 人们能认识的物理特征只有一部分, 因此, 岩体冒落机理及监测预报研究是一个典型的灰色系统问题, 对解决这类问题, 灰色建模理论^[3] 可显示出优越性。它通过建模前的数据处理, 使原来紊乱的参数序列呈现出某种规律; 然后着手建模, 并通过残差分析修正初始模型, 以提高模型精度; 最后通过模型预测未来任何时刻的参数值。根据灰色理论所建立的灰色模型可表示为 $GM(n, h)$, n 为阶数, h 为变量数, 作为预测模型, $GM(1, 1)$ 应用最广泛而且最有效。

假设测试的 AE 数据组成非负数据序列 $\{X(0)(i)\}$, $i = 1, 2, \dots, N$, 相应的 1 次累加生成 $(1 - AGO)$ 序列为:

$$\{X^{(1)}(i)\}$$

$$\text{其中 } X^{(1)}(i) = \sum_{j=1}^i X^{(0)}(j) \quad (3)$$

相应的 1 次累减生成 $(1 - IAGO)$ 序列为:

$$\{\alpha^{(1)}(X^{(1)}(i))\}$$

$$\text{其中 } \alpha^{(1)}(X^{(1)}(i)) = X^{(0)}(i) \quad i = 2, \dots, N \quad (4)$$

对于 $X^{(1)}$, 其动态变化可用下述形式的白化微分方程来描述:

$$\frac{dX^{(1)}}{dt} + aX^{(1)} = b \quad (5)$$

式中 a, b 为辨识参数, 记为: $\hat{a} = [a, b]^T$, 按最小二乘法求解, 其辨识模型为

$$\hat{a} = [B^T B]^{-1} B^T Y_N \quad (6)$$

式中

$$B = \begin{bmatrix} (X^{(1)}(2) + X^{(1)}(1))/2, & 1 \\ - (X^{(1)}(3) + X^{(1)}(2))/2, & 1 \\ \dots & \dots \\ - (X^{(1)}(N) + X^{(1)}(N-1))/2, & 1 \end{bmatrix} \quad (7)$$

$$Y_N = [X^{(0)}(2), X^{(0)}(3) \dots X^{(0)}(N)]^T \quad (8)$$

GM(1, 1) 解的离散形式为

$$\hat{X}^{(1)}(i+1) = (X^{(0)}(1) - \frac{b}{a}) \cdot \exp(-a \cdot i) + \frac{b}{a} \quad (9)$$

将模型离散形式求得的预测序列 $\{\hat{X}^{(1)}(i)\}$ 进行还原, 得还原序列 $\{\hat{X}^{(0)}(i)\}$, 其中,

$$\hat{X}^{(0)}(i+1) = (-a)(X^{(0)}(1) - \frac{b}{a}) \cdot \exp(-a \cdot i) \quad (10)$$

当 $i+1 \leq n$ 时, $\hat{X}^{(0)}(i+1)$ 称为模型的拟合值, 利用拟合值可以检验模型的预测精度; 当 $i+1 > n$ 时, $\hat{X}^{(0)}(i+1)$ 就是序列 $X^{(0)}(i+1)$ 的预测值。当模型预测的精度不符合要求时, 可通过残差分析进行修正。模型预测数据与原始数据的残差仿 $X(0)$ 的建模过程, 建立的残差预测模型可以修正初始预测模型。

一旦用给定地点在给定时期内获得的 AE 数据序列建立了单个 AE 参数合适的 GM 模型, 就可根据该 GM 模型预报给定区域内各个 AE 参数值。

1.2 冒顶模式的神经网络识别系统

神经网络是试图模仿人脑生物神经元的思维力, 即感知、回忆和推理能力, 它是由大量并行处理的非线性简单元件广泛连接而成的复杂网络系统, 具有高度非线性、自学习、联想记忆和动态处理的特征, 神经网络可以解决用传统方法无法解决或在具体处理技术上尚存在困难的问题。因此, 对冒顶模式这类非线性系统的预测问题, 应用神经网络技术是一条新的途径。神经网络的最大优点, 在于它具有可训练性和从经验和实践中学习并获得知识的能力。学习的算法有许多种, 用得最普遍的是误差反向传播(BP)算法。

用人工神经网络预测冒顶模式, 首先要求建立一个基于神经网络的自适应模式识别系统。冒顶模式分为较大规模冒落、小块冒落和稳定三类, 与这些冒顶模式对应的 AE 参数通过现场直接监测或灰色预测获得。系统的模式识别包括以下三个步骤:

(1) 积累声发射监测区域的冒顶事件。从

积累的大量冒顶事件中选择典型的作为网络训练样本, 通过BP算法训练网络, 构造声发射参数(C, E, m)和可能的冒顶模式之间的非线性映射。

图1所示为自适应各 AE 参数的冒顶模式识别网络, 网络中的输入层、隐层和输出层分别由3个输入神经元、10个隐单元和1个输出神经元组成。在输入层和隐层内各设置一个特殊单元用作阈值单元, 其值设为1。

图1 自适应冒顶模式识别网络

网络以归一化的各样本特征变量 C, E, m 作为输入, 期望输出按以下方法给定: 要求识别的冒顶模式为 P_1, P_2, P_3 , 分别表示较大的冒落、小块冒落和稳定。这样本的期望输出矢量为: $t_i (i = 1 \sim N)$, t_i 各分量定义为:

$$t_i = \begin{cases} 0.9(P_1), & i \leq N_1 \\ 0.6(P_2), & N_1 < i \leq N_2 \\ 0.3(P_3), & i > N_2 \end{cases} \quad (11)$$

式中 N_1 为模式属于较大冒落的样本数, N_2 是较大冒落与小块冒落样本之和, N 为样本总数。

训练网络模型时, 当所有样本在网络输出节点的实际输出 O_i 与网络期望输出 t_i 之间的最大误差 $E_{\max}$ 小于预先给定的常数 ϵ , 即

$$E_{\max} = \max_{i=1 \sim N} |O_i - t_i| < \epsilon \quad (12)$$

时学习结束。

(2) 由灰色理论预测的 AE 数据经预处理后, 输入训练好的网络模型, 该网络即可自动识别可能的冒顶模式。识别的方法是首先假设

要求识别的样本为 W , 预测的 AE 参数经训练好的网络变换后输出 O_w , 将其与各个模式期望输出 $S = (0.9(P_1), 0.6(P_2), 0.3(P_3))$ 相比较, 有:

$$g_i(O) = |O_w - S_i|, i = 1 \sim 3 \quad \text{如果}$$

$$g_j(O) = \min_{i=1 \sim 3} g_i(O) \quad (13)$$

则 $W \in P_j, j = 1 \sim 3$, 即冒顶模式 W 属于 P_j 。

(3) 将新的冒顶事件不断加入到神经网络中以发挥网络“适应”连续学习的功能, 提高网络的识别精度。

2 实例应用

选择位于中国西北部的一个金属矿山作为应用实例, 该矿矿岩节理发育, 在过去的开采工作中发生了许多冒顶灾害, 为此采用下向分层充填法以降低这类冒顶事故。但是在开采残矿和边部矿体时冒顶事件仍时常发生, 威胁井下工人和设备的安全, 影响矿山正常的生产, 所以应用声发射技术进行冒顶预测研究。由于冒顶的局部性和控制冒顶灾害的紧迫性, 在用便携式声发射监测仪(DYF-1)于1994年开始进行测试之前, 没有建立全矿性的声发射定位系统。

以一个采场作为一个监测点, 每天对各个监测点进行声发射测试, 每次监测时间为5分钟。本研究的初始计划是企图通过获取冒顶过程中的声发射参数值确定各参数的临界水平, 然后基于这些临界水平预报可能来临的冒顶灾害。许多测试结果表明, 虽然采场冒顶时的声发射参数都有所增长(C 、 E)或降低(m), 但在一次测试周期内各参数之间却没有类似的变化趋势, 即使在相同地质条件的各采场在发生冒顶期间获得的同一参数也没有固定的值, 图2和图3便是这种结果的典型例子。

将在43号采场测试的5天内的声发射数据组成一组数据序列列入表1, 并构成时间分布图如图4所示。

从表1和图4可以看出, 声发射数据的分

布是很随机的, 所以有必要采用灰色理论建立有效的数学模型来拟合这些高度歪斜分布的数

图2 43与39采场 AE 事件率的直方图

测试日期: 1——10-31; 2——11-01;

3——11-02; 4——11-03; 5——11-04

图3 39号采场声发射参数的分布特征

(a) — AE 率; (b) — AE 能量; (c) — m 值

据并预测将来的声发射活动。取表1中5天的监测数据建立灰色预测模型, 采用后验差检验

法检验模型的精度。分析结果表明, AE 事件率和 m 值的预测模型通过一次残差分析后达到精度要求, AE 能量的预测模型一次建模成功, 各模型的数学方程和拟合值及二天的预测值示于表 1 和图 4。

从表 1 和图 4 可以看出, 各参数的 GM (1, 1) 方程比较好地拟合了各 AE 参数的测试值, 虽然个别的拟合误差比较大(最大相对误差达 47%), 但我们发现, 越是靠近最新时间, 拟合的效果越好(最小误差为 0.6%), 因此, 这些模型的预测值具有良好的可信度。另外, 从图 4(a) 还可看出, AE 事件率的初始 GM (1, 1) 模型精度是很低的, 通过残差分析修正后, 模型的精度有较大的提高, 这表明了灰色理论区别于常规建模方法的独特功能。由灰色预测结果可知, 声发射参数的预测值是随时间呈指数规律无限增大或呈负指数规律无限减小的, 显然这不符合实际情况, 因此, 灰色预测模型只能作短期预测, 应随新数据不断加以修正。

在现场声发射测试过程中监测到了许多冒顶事件, 冒顶形式主要为较大规模的顶板坍塌和局部掉块, 如果将顶板的稳定状态视为冒顶模式的特例, 那么, 冒顶模式有三种。选择典型的冒顶过程中监测的或用灰色理论预测的声发射数据与对应的冒顶模式作为神经网络的训练样本训练网络模型。

利用训练好的神经网络模型识别 43 号采场在 11 月 5 日和 6 日的冒顶模式, 这两天的声发射参数已由灰色理论进行了预测并列于表

图 4 43 号采场 AE 参数实测值与预测值的对照
(a) — AE 率; (b) — AE 能量; (c) — m 值
1— 初始模型; 2— 修正模型; 3— 测试值; 4— 预测值

表 1 43 采场 AE 参数的实测值与灰色预测结果

AE 参数	数据类型	测试日期(月- 日)							GM (1, 1) 模型
		10- 31	11- 01	11- 02	11- 03	11- 04	11- 05	11- 06	
事件率 C $/min^{-1}$	实测值	2. 9	4. 4	14. 2	10. 3	12. 4			$\hat{C}^{(0)}(k+1)$
	预测值		4. 8	7. 42	10. 02	12. 77	15. 78	19. 16	$= 7. 27\exp(0. 17k)$
	相对误差 / $\%$	9. 1	47. 7	2. 7	2. 9				$- 5. 13\exp(- 0. 31k)$
能量 E $/10^4\text{ mV}$	实测值	8. 2	7. 45	17. 14	15. 26	20. 52			$\hat{E}^{(0)}(k+1) =$
	预测值		9. 99	13. 17	15. 92	20. 39	25. 67	32. 30	$\hat{E}^{(1)}(k+1) - \hat{E}^{(1)}(K)$
	相对误差 / $\%$		34. 1	23. 1	4. 3	0. 6			$\frac{\exp(0. 23k) - 31. 6}{E^{(1)}(k+1)} = 39. 56$
m 值	实测值	3. 76	3. 69	2. 95	3. 11	3. 25			$\hat{m}^{(0)}(k+1)$
	预测值	3. 45	3. 30	3. 18	3. 10	2. 98	2. 88		$= 3. 53\exp(- 0. 038k)$
	相对误差 / $\%$		6. 5	11. 8	2. 2	4. 6			$+ 0. 05\exp(0. 083k)$

1, 网络识别的结果列于表 2。根据前述的判别准则可以判定, 11 月 5 日将发生小规模掉块, 而 11 月 6 日将有较大规模的冒顶, 这一预测结果与实际情况是一致的。

表 2 神经网络模型的识别结果

日期	AE 率 C / min^{-1}	AE 能量 $E / 10^4$ 毫伏	值 m	冒顶模式
11 月 5 日	15. 78	25. 67	2. 98	0. 597 (P ₂)
11 月 6 日	19. 16	32. 30	2. 88	0. 792 (P ₁)

3 结束语

以前, 声发射技术预测岩体塌落(冒顶或岩爆)的失效率很高。其原因, 除了对岩体塌落本身复杂的机制了解甚少外, 还包括监测仪器和技术不够完善。本文所叙述的声发射源定位系统和便携式智能声发射监测仪能够帮助我们获取尽量多的一个声发射事件的信息, 为准确监测声发射活动提供了条件, 是预报冒顶灾害的有效而可靠的方法, 因为:

- (1) 该方法利用了声发射事件尽量多的参数来评价声发射活动, 而不是单独利用其中的某一个。
- (2) 冒顶活动是一个典型的灰色系统, 而且由于声发射参数的时间分布的高度歪斜性质, 应用灰色系统理论短期预测声发射活动具有别的方法无可比拟的优越性。
- (3) 冒顶模式的识别, 不仅影响因素多, 且有模糊性和不确定性; 而神经网络方法具有联想、记忆功能和判断识别的模糊性等特征, 所以它对冒顶模式这类具有很强模糊性的问题进行预测, 是一种强有力的方法。

参考文献

1 Brady B T. Prediction of Failure in Mines—An Overview. Washington DC: BuMines RI 8285.

2 Blake W. In: Proceedings of 3rd Conference on Acoustic Emission/ Microseismic Activity in Geologic Structure Materials. University Park, PA, PA State Univ, 1981, 239 – 249.

3 邓聚龙. 灰色系统基本方法. 武昌: 华中理工大学出版社, 1987, 96– 117.

INTELLIGENT PREDICTION OF ROOF FALL
BY AE TECHNIQUE

Cao Qinglin, Yu Kesheng, Sang Yufa
Changsha Institute of Mining Research, Changsha 410012

ABSTRACT A mine-wide Acoustic Emission(AE) Source Location System(SDL-1) and a Portable Intelligent AE Monitoring Device(DVF-1) were described. These instruments can acquire AE data as much as those associated with an AE event. An effective and reliable technique to predict the occurrence of roof fall hazards has been developed, based on the AE data measured. It has utilized several AE indicators(AE rate, AE energy and m value) to evaluate the AE activity and applied grey system theory to construct grey prediction models for forecasts on AE . The predicted values of AE indicators could then be input to the trained artificial neural network for adaptive roof fall modes recognition to automatically identify the roof fall modes(collapse, small blocks fall and stable). The case study showed that the result of forecast on the occurrence of roof fall modes has a good agreement with the practice.

Key words roof fall mode acoustic emission grey theory neural network prediction

(编辑 吴家泉)