

基于模糊自适应变权重算法的采场冒顶函数链神经网络预报

左红艳，罗周全，王益伟，王爽英

(中南大学 资源与安全工程学院，长沙 410083)

摘要：为提高采场声发射事件率预报精度，将采场声发射事件率不同的单个预测模型的预测值作为函数链神经网络的原始输入值，并将原始输入值按正交的三角函数扩展得到的数值作为函数链神经网络扩展输入值，在分析函数链神经网络拟合充要条件的基础上，结合模糊自适应变权重算法计算函数链神经网络权重，对采场声发射事件率进行基于模糊自适应变权重算法的函数链神经网络预测，对其预测结果再进行函数链神经网络算法拟合，然后结合采场冒顶尖点突变模型的判别式对采场冒顶进行预报。某铅锌矿采场冒顶预报结果表明，基于模糊自适应变权重算法的函数链神经网络预测方法的预测误差小于 0.3%，可实现采场冒顶精确预报。

关键词：函数链神经网络；模糊自适应变权重算法；预测；采场冒顶；声发射

中图分类号：TD76

文献标志码：A

Prediction of functional link neural network of roof caving based on fuzzy adaptive variable weight method

ZUO Hong-yan, LUO Zhou-quan, WANG Yi-wei, WANG Shuang-ying

(School of Resource and Safety Engineering, Central South University, Changsha 410083, China)

Abstract: In order to enhance the predict precision about happening rate of acoustic emission in mine, the happening rate of acoustic emission in mine was forecasted based on functional link neural network due to fuzzy adaptive variable weight algorithm by using of making some forecasting values from different single forecasting model of happening rate of acoustic emission in mine as original input values of functional link neural network, making the original input values as patulous input values of functional link neural network after the original input values being extended according to the orthogonal trigonometric function, analyzing the necessary and sufficient conditions of functional link neural network fitting and calculating the weight of functional link neural network based on fuzzy adaptive variable weight algorithm. And the roof caving can be predicted when the forecasting results is fitted by functional link neural network algorithm and the discriminant of roof caving abrupt change model. The forecasting results of happening rate of acoustic emission in some lead and zinc mine reveal that the functional link neural network forecasting method based on fuzzy adaptive variable weight algorithm is higher than that of other forecasting model and its forecasting error is smaller than 0.3%. And the precision predicting roof caving is able to be realized due to the functional link neural network forecasting.

Key words: functional link neural network; fuzzy adaptive variable weight method; prediction; roof caving; acoustic emission

对于采场这样的复杂工业系统来说，由于往往存在内部结构复杂，影响因素和评价指标较多，预测总是在不确定且不稳定的环境下进行的^[1-2]，信息集和处理信息能力的局限性、复杂工业系统的结构性调整、

新理论与新技术的发展以及复杂工业系统结构中的非线性等不确定和不稳定的因素都会导致预测模型的不确定性和预测的风险。如果采用不同的单个预测模型或部分因素和指标来对其输入、输出进行模拟、预测

基金项目：国家“十一五”科技支撑计划项目(2007BAK22B04-12, 2006BAB02B05-01-02-01)

收稿日期：2010-03-22；修订日期：2010-12-26

通信作者：罗周全，教授，博士；电话：0731-88879612；E-mail: lzq505@hotmail.com

和调控, 然后按照预测精度大小从众多的预测方法中选择结果最好的单项预测方法, 只能体现所研究的系统的局部, 而并非提高预测精度的好办法^[3]。不同的定性预测方法各有其优点和缺点, 它们之间并不是相互排斥的, 而是相互联系、相互补充的, 而 BATES 和 GRANGER^[4]以及 AKSV 和 GUNTER^[5]提出的组合预测方法为复杂工业系统预测精度提高提供新思路。

利用组合预测方法的关键是确定单个模型的权重^[6-10]。由于不同预测方法特点的差异及现实世界复杂多变, 每种模型往往有“时好时坏”的现象, 故变权组合预测成为提高精度的有效途径。在现有的成果中, 变权组合预测权重的确定是以观测期的观测值为基础, 主要以预测误差最小或精度最大为目标求得各期权重^[6-14]。在已有的变权重确定方法中, 因预测期无观测值, 有些方法不能使用, 即使有些方法可用, 也没有将已获得的预测信息充分用于确定后期的权重。

函数链神经网络(Functional link neural network, FLNN)^[15-16]通过对原来的输入模式进行扩展增强, 可在更高维空间中描述该模式, 将增强后的模式作为神经网络的输入, 这样在没有加入任何新的“特定”信息条件下就增强了模式的表达, 从而使原来在低维空间中不可分的模式在增强的空间里获得可分性, 可克服上述缺陷, 并具有良好的非线性逼近能力, 因而可视为采场这种复杂工业系统预测的一种有效途径。

当采场中的岩体发生变形时, 内部积聚的能量释放时有一部分以声波形式传播, 这种现象称为岩体声发射(Acoustic emission, AE)^[17]。于是通过监测岩体声发射即可监测岩体稳定性, 这也成为采场冒顶监测的常用工具。考虑到采场声发射事件率观测值需进行长时间的检测或人工分析和计算得到, 为减少样本获取过程中多次改变系统控制量的设定点, 影响实际系统的正常运行, 需要一种只需少量样本就能获得较好性能的预测方法。为此, 本文作者提出一种模糊自适应变权重函数链神经网络预测方法, 将模糊自适应变权重算法引入函数链神经网络, 以改善函数链神经网络的泛化能力。

1 基于非线性模糊自适应变权重算法的函数链神经网络

1.1 函数链神经网络结构

BP 神经网络具有一定的非线性逼近能力, 但存在着固有的缺陷: 学习收敛速度慢, 中间隐层节点数的

选择无规律, 易于陷入计算能量局部极小, 因而只能用于粗略的回归, 难以实现精确的拟合, 且不易硬件实现。而函数链神经网络到通过对输入的函数扩展, 将多层网络缩为单层网络, 使该网络具有极强的非线性映射能力, 达到快速高效的学习目的, 避免陷于局部最小的问题, 从而成为一个应用极广的神经网络模型。

函数链神经网络具有很强的映射功能, 能构造出任意复杂的连续函数。其基本思想是通过采用一组线性无关(或正交)函数将原输入样本扩展模式矢量, 在维数更高的空间上进行模式的表示和区分, 得到了在增强的空间里的多个独立的新输入样本再输入到单层前向网络。函数扩展采用了模式识别的思想, 在没有引入新的信息条件下, 将低维模式变换到高维模式, 增强了模式的表达, 使原来在低维空间中的非线性问题在高维空间中得到解决。由于增加了扩展过程, 函数链神经网络能实现多层次感知机的功能; 同时, 在学习中仅为单层运算, 故其收敛速度极快, 且不会陷入局部最小, 因此, 能用于精确估计和拟合。

函数链神经网络在结构上有两部分组成: 函数扩展和单层感知器, 分别如图 1 和 2 所示。函数扩展部分进行某种非线性变换。由此将每一输入分量 x_k 变换为一系列线性独立函数 $f_1(x_k), f_2(x_k), \dots, f_n(x_k)$ 。从而将模式矢量的空间维数变为独立函数的高空间维数。这样, 新的信息表述空间扩展了, 使单层网络具有了分辨复杂对象的能力。

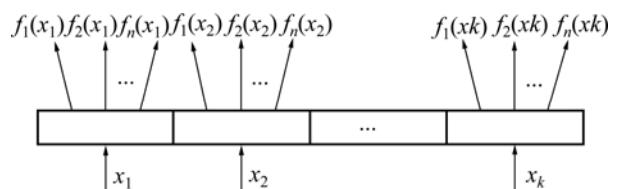


图 1 函数链神经网络函数扩展

Fig.1 Functional extending of functional link neural network

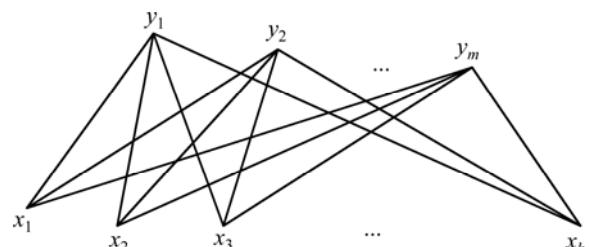


图 2 单层感知器

Fig.2 Single-layer perceptron

1.2 非线性模糊自适应变权重函数链神经网络预测模型建立

对于复杂工业过程非线性时间序列 $X=(x_1, x_2, \dots, x_m)$ 所组成的 m 维相空间的预测问题，设有 $K(K > 2)$ 种常规预测方法 $f_1(x_i), \dots, f_i(x_i), \dots, f_K(x_i)$ ($i=1, 2, \dots, m$) 作为如图 3 所示的非线性模糊自适应变权重函数链神经网络的 K 个原始输入 $u_1=f_1(x_i), \dots, u_i=f_i(x_i), \dots, u_K=f_K(x_i)$ ，经函数扩展从而形成实际的神经元输入 v_m ($m=1, 2, \dots, K+N$)。从均方值的意义考虑，函数展开采用较其他的正交基函数位函数逼近简洁的正交的三角函数来完成函数展开。

对于一个事先定义好的函数展开阶次 S ，这个神经元的实际输入 v 为： $\{u_k, \{\cos(s\pi u_k), \sin(s\pi u_k)\}\}$ ， $k=1, 2, \dots, K, s=1, 2, \dots, S$ 。通过这种方式，将增加 $N=2SK$ 辅助输入。单神经元的激活函数为 Sigmoid 函数，则函数链神经网络的输出 Y 可表示为

$$Y=1/(1+e^{-z}) \quad (1)$$

式中： $z=\theta_0+y$ ， θ_0 为神经元的阈值； y 为神经元的原始输入以及经函数展开后增加的输入与权值乘积之和，可表示为

$$y = \sum_{m=1}^{K+N} w_m v_m \quad (2)$$

式中： v_m 为原始各个输入 u_n 经过函数展开式 $\{u_k, \{\cos(s\pi u_k), \sin(s\pi u_k)\}\}$ 而获得。

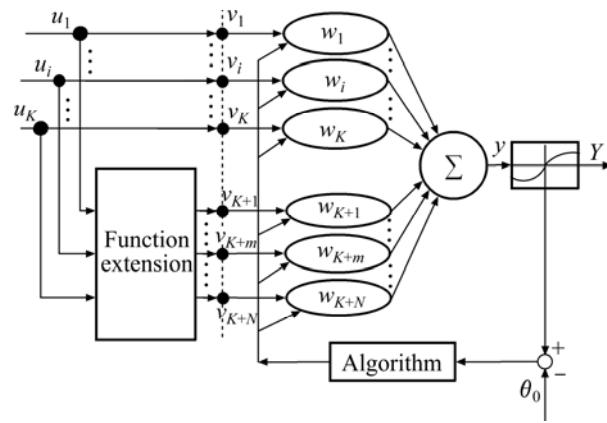


图 3 函数链神经网络预测模型

Fig.3 Functional link neural network forecasting model

1.3 函数链神经网络拟合充要条件

设 K 个原始输入 $u_1, \dots, u_i, \dots, u_K$ 经函数扩展后有 $N+K$ 个分量： $v_{1i}, v_{2i}, \dots, v_{(N+K)i}$ ，以及 $N+K+1$ 个权向量： $w_0, w_1, \dots, w_{(N+K)}$ 。

根据函数链神经网络输出 $Y=1/(1+e^{-z})$ ，欲使 $Y_i=x_i$ ，则 $z_i=\ln[x_i/(1-x_i)]$ ， x_i 与 z_i 有一一对应关系。而

$$\sum w_i v_{ii} - \theta = z_i, \text{令 } w_0 = -\theta, \text{则 } w_0 + \sum w_i v_{ii} = z_i。$$

对于复杂工业过程非线性时间序列 $X=(x_1, x_2, \dots, x_m)$ ，有

$$\begin{bmatrix} 1 & v_{11} & \cdots & v_{(N+K)1} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & v_{1m} & \cdots & v_{(N+K)m} \end{bmatrix} \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{N+K} \end{bmatrix} = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_m \end{bmatrix} \quad (3)$$

从而，使网络输出 $Y=[Y_1, Y_2, \dots, Y_m]$ 拟合非线性时间序列 $X=[x_1, x_2, \dots, x_m]$ 的问题就变成求解权系数 $W=[w_0, w_1, \dots, w_{(N+K)}]$ 的问题。

1) 若 $N+K+1=m$ ，即扩展函数的个数 $N+K+1$ 与输入样本个数 m 相等时，由于扩展函数均选为正交或线性无关的函数，所以， $X=[x]_{(N+K)K}$ 是正定的， $X \neq 0$ ，则 $W=X^{-1}Z$ 有唯一封闭解。

2) 若 $N+K+1 > m$ ，则可将 X 矩阵分块，得到分块矩阵 X_B ，其维数为 $m \times m$ ， $X_B \neq 0$ 。令 $w_{m+1}=w_{m+2}=\dots=w_{N+K}=0$ ，则 $W=X_B^{-1}Z$ 。如果不对 X 进行分块，则 W 有无穷多解。

3) 若 $N+K+1 < m$ ，则式(1)无精确封闭解。

因此，只要在扩展函数集中使用足够多的附加正交函数，使 $N+K+1 \leq m$ ，则 FLNN 就能由单层网络解决非线性估计和拟合问题。此外，网络采用具有平滑特性的函数 $Y=1/(1+e^{-z})$ 输出，有利于插值点之间的光滑过渡。

1.4 模糊自适应变权重算法

在非线性模糊自适应变权重函数链神经网络预测模型中，关键是确定非线性模糊自适应变权重函数链神经网络预测模型的权系数，从而真正达到综合不同预测方法的信息、提高预测精度的目的。

设函数链神经网络经函数展开后在 i 时刻第 j 个输入值的误差 $e_j(i)$ 以及预测对象在 i 时刻的实际值 x_i 相对于前 t 个时刻的实际值的算术平均值的变化量 $c_j(i)$ ，由式(4)可以确定：

$$e_j(i) = \frac{x(i) - f_j(i)}{x(i)} \quad (4)$$

$$c_j(i) = \frac{x(i) - \frac{1}{k} \sum_{j=i-t+1}^i x(j)}{x(i)} \quad (5)$$

式中： $j=0, 1, \dots, N+K$ ； $i=1, 2, \dots, t$ ； t 为一确定值，由具体预测对象决定； $f_j(i)$ 为函数链神经网络经函数展开后在 i 时刻第 j 个输入值的预测值。

1.4.1 模糊运算器

预测相对误差 $e_j(i)$ ($j=1, 2, \dots, N+K$ ； $i=1, 2, \dots,$

t)的模糊化过程为^[18]:先将 $e_j(i)$ 的变化范围统一设为 $[-1, 1]$, 将连续论域 $[-1, 1]$ 划分为若干段, 每一段对应一个离散点, 由此得到 $e_j(i)$ 的离散论域 U 。并用 A 表示相对误差的语义变量, 令其在离散论域 U 上取 5 个语义值, 如表 1 所列。

表 1 预测相对误差离散论域上对应的语义值

Table 1 Corresponding semantic value in discrete region about forecasting value of relative errors

| U | Semantic value | Discrete area |
|--------------|----------------|---------------|
| $[-1, -0.5)$ | A_1 | X_1 |
| $[-0.5, 0)$ | A_2 | X_2 |
| 0 | A_3 | X_3 |
| $(0, 0.5]$ | A_4 | X_4 |
| $(0.5, 1)$ | A_5 | X_5 |

在实际情况中, 由于函数链神经网络经函数扩展开后的输入值在 i 时刻的实际值相对于前 t 个时刻的实际值的变化量 $c_j(i)$ 的变化范围不在连续论域 $[-1, 1]$ 之间, 而在 $[-M, M]$ (M 为正整数, 其取值由具体问题确定) 之间, 则可通过式(3) 将在 $[-M, M]$ 之间变化的变量 $c_j(i)$ 转化为连续论域 $[-1, 1]$ 之间的变量 $c'_j(i)$ 。

$$c'_j(i) = c_j(i) / M \quad (6)$$

此外, 归一化前的函数链神经网络经函数扩展开后输入值的权重 $l_j(i)$ 的变化范围为 $[0, 1]$, 故只要在 $l_j(i)$ 所对应的连续论域上进行相应的离散化, 得出离散论域上的相应语义值即可。

令 E 为函数链神经网络经函数扩展开后 i 时刻第 j 种输入值偏离真实值的大小, C 为函数链神经网络经函数扩展开后 i 时刻第 j 种输入值偏离或趋向于真实值的程度, K_{ij} 为函数链神经网络经函数扩展开后 i 时刻第 j 种输入值的模糊权重, 根据事先制定的控制规则^[18]:

$$\text{if } E = e_j(i) \text{ and } C = c'_j(i), \text{ then } K_{ij} = k'_j(i)$$

这样就设计了一个双输入($e_j(i), c'_j(i)$)单输出(K_{ij})的模糊运算器, 然后在对输出的模糊权重 K_{ij} 进行模糊判决, 将其转化为精确权重 $k'_j(i)$, 最后进行归一化处理, 得到在函数链神经网络经函数扩展开后 i 时刻第 j 种输入值的模糊权重为

$$k_j(i) = k'_j(i) / \sum_{j=1}^{N+K} k'_j(i) \quad (7)$$

1.4.2 模糊变权重组合方法

若用 i 时刻前 t 个时期的实际值 $x(i-t)$ 、

$x(i-t+1)$ 、 \dots 、 $x(i-1)$ 来预测 i 时刻的值 $x(i)$, 则函数链神经网络经函数扩展开后 i 时刻第 j 个输入值的误差 $e_j(i)$ 以及预测对象在 i 时刻的实际值相对于前 t 个时刻的实际值的变化量 $c'_j(i)$ 相对于 t 时刻的实际值的灰色基本权重 $p[e_j(i)]$ 、 $q[c'_j(i)]$ 分别为

$$p[e_j(i)] = \frac{\alpha_1 + \beta_1 \delta}{|e_j(i)| + \beta_1 \delta} \quad (8)$$

$$q[c'_j(i)] = \frac{\alpha_2 + \beta_2 \delta}{|c'_j(i)| + \beta_2 \delta} \quad (9)$$

式中: $\alpha_1 = \min_j \min_i |e_j(i)|$; $\beta_1 = \max_j \max_i |e_j(i)|$; δ 称为灰色关联度分辨系数, 在本模拟中, 取 $\delta=0.5$; $\alpha_2 = \min_j \min_i |c'_j(i)|$; $\beta_2 = \max_j \max_i |c'_j(i)|$ 。

则函数链神经网络经函数扩展开后第 j 个输入值的基本权重 $l_j(i)$ 由式(10)确定:

$$l_j(i) = \beta_i p[e_j(i)] + (1 - \beta_i) q[c'_j(i)] \quad (10)$$

式中: β_i 为自适应调节系数, $0 < \beta_i < 1$ 。

自适应调节系数 β_i 采用如下方法进行自适应确定:

$$\beta_i = 1 - \left(\frac{i-1}{i} \right)^G \quad (11)$$

式中: G 为一正数, 一般按式(12)取得。

$$G = \begin{cases} 1/\varepsilon, & \varepsilon > 2.0 \\ 0.5, & 0.5 \leq \varepsilon \leq 2.0 \\ \varepsilon, & 0 < \varepsilon < 0.5 \end{cases} \quad (12)$$

式中: $\varepsilon = p[e_j(i)]/q[c'_j(i)]$ 。

因此, 进行归一化处理, 则可得函数链神经网络经函数扩展开后在 i 时刻第 j 个输入值的模糊自适应权重为

$$w_j(i) = \frac{l_j(i)k_j(i)}{\sum_{j=1}^{N+K} l_j(i)k_j(i)} \quad (13)$$

式(13)描述了函数链神经网络经函数扩展开后各种输入值在某时刻前一段时期内全面的、平均的预测效果对加权系数的影响, 它使得函数链神经网络经函数扩展开后各种输入值的权重分配更合理, 将大大地提高预测精度。

求得归一化后的函数链神经网络经函数扩展开后各种输入值的权重 $w_j(i)$ 后, 利用 $f_j(i)$, 就可以对 i 时刻作出预测, i 时刻的预测值由式(14)决定:

$$f(i) = \sum_{j=0}^{N+K} w_j(i) f_j(i) \quad (14)$$

式中： $j=0, 1, \dots, N+K$ ； $i=1, 2, \dots$

2 铅锌矿冒顶预测应用实例

2.1 尖点突变模型

Thom 证明，控制参数不超过 4 维，状态参数不超过 3 维的系统，只有 7 种突变形式，但常用的是相空间为 3 维势函数的尖点突变模型。该尖点突变模型可为边坡、滑移、地震突发、采场坍塌等突出不连续现象问题的解决提供很好的理论基础。

尖点突变模型的正则函数形式为

$$V(x) = x^4 + ux^2 + vx \quad (15)$$

式中： x 为状态变量； u 、 v 为控制变量。

尖点突变模型的临界点为 $V(x)=0$ 的解的集合为平衡曲面，即

$$4x^3 + 2ux + v = 0 \quad (16)$$

设想岩体状态由 x 、 u 、 v 为坐标的三维空间的一点来表示，并称该点为相点，则相点必定总在 $V(x)=0$ 上，即位于顶叶或底叶，因为中叶对应于岩体不稳定状态。

平衡曲面的临界点的集合(奇点集)可表示为

$$12x^2 + 2u = 0 \quad (17)$$

由式(16)和(17)消去 x 得尖点突变模型的判别式为

$$\Delta = 8u^3 + 27v^2 \quad (18)$$

$\Delta=0$ 的控制点(u, v)的点集称为分歧点集，控制点(u, v)发生变化，相应点在平衡曲面上相应变化，但当控制点轨迹越过分歧点集 $8u^3 + 27v^2 = 0$ 时，相应点必经过中叶产生跳跃，即岩体失稳，即：

- 1) 若 $\Delta > 0$ ，采场顶板稳定；
- 2) 若 $\Delta = 0$ ，则采场顶板处于临界状态；
- 3) 若 $\Delta < 0$ ，采场发生冒顶。

对于尖点突变模型的正则函数 $V(\delta)$ ，利用泰勒级数展开，并截尾至 4 次项，则有

$$V(\delta) = w_0 + w_1\delta + w_2\delta^2 + w_3\delta^3 + w_4\delta^4 \quad (19)$$

令 $x = \delta + w_3/(4w_4)$ ，消去式(18)中的 3 次项和常数项 w_0 ，可得 $u = 6[w_3/(4w_4)]^2 + w_2/w_4 - 3$ ， $v = w_1/w_4 - [w_3/(4w_4)]^3 - 2[w_3/(4w_4)]w_2/w_4$ ，则可得到式(15)所示的尖点突变模型的正则函数形式，因此，式(19)和(15)是微分同胚变换。

2.2 尖点突变模型的正则函数拟合

式(19)中的常系数 w_0 、 w_1 、 w_2 、 w_3 、 w_4 可将经非线性模糊自适应变权重函数链神经网络预测后的声发射特征状态变量 x_i ($i=1, 2, \dots$)代入式(19)，并应用函数链神经网络拟合法求出，并进而求出 u 、 v 和 Δ 值，具体过程如下。

假设采用如图 4 所示的函数链神经网络对经非线性模糊自适应变权重函数链神经网络预测后的状态变量 x_i ($i=1, 2, \dots$)进行拟合，其预测输出值 $X(x_i)$ 可以用一幂级数 4 次多项式描述，则

$$X(x_i) = w_0 + w_1x_i + w_2x_i^2 + w_3x_i^3 + w_4x_i^4 \quad (20)$$

图 4 中 $w_j(j=0, 1, 2, 3, 4)$ 为网络的连接权值。连接权值的个数与反非线性多项式的阶数相同，即 $j=4$ ，函数链神经网络的输入值为 1、 x_i 、 x_i^2 、 x_i^3 、 x_i^4 。

函数链神经网络的输出值 $x_i^{\text{est}}(k)$ 为

$$x_i^{\text{est}}(k) = \sum_{j=0}^4 x_i^j w_j(k) \quad (21)$$

式中： $w_j(k)$ 为第 k 步时的权值，且 $w_j(k+1) = w_j(k) + \eta_j e_j(k) x_i^j$ ， $e_j(k) = X_i - x_i^{\text{est}}(k)$ ， η_j 为学习因子，它的选择影响到迭代的稳定性和收敛速度，取 $\eta_j = 1 - k/M$ ， M 为最大迭代次数， X_i 为声发射特征状态变量第 i 个预测值对应的实际测量值。

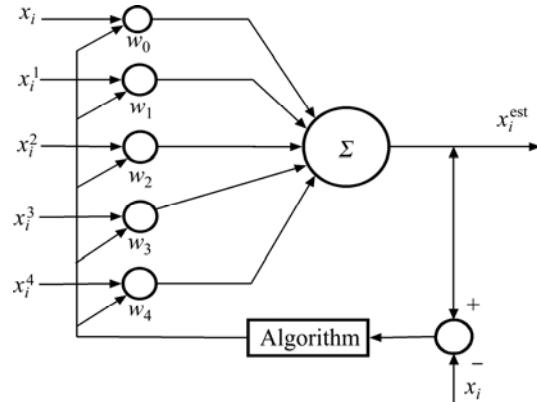


图 4 函数链神经网络示意图

Fig.4 Schematic diagram of function link NN

函数链神经网络的输出值 $x_i^{\text{est}}(k)$ 与状态变量第 i 个预测值对应的实际测量值 X_i 进行比较，经函数链神经网络学习，求出函数链神经网络的输出估计值与声发射特征状态变量第 i 个预测值对应的实际测量值 X_i 均方差在全局范围内的最小值：

$$\min \sum_{i=1}^N [x_i^{\text{est}}(k) - X_i]^2 = \min \sum_{i=1}^N \left[\sum_{j=0}^4 x_i^j w_j(k) - X_i \right]^2 \quad (22)$$

即该最小值是关于权值 w_0 、 w_1 、 w_2 、 w_3 和 w_4 的函数。一般而言,权值 w_0 、 w_1 为同一数量级, w_2 比 w_1 至少低一个数量级, w_3 比 w_2 和 w_4 比 w_3 均相应低较多的数量级。所低的数量级由声发射特征状态变量的非线性程度确定。

2.3 铅锌矿冒顶预测实例

某铅锌矿一矿区采用下向胶结充填采矿法,随着采矿作业的进行,采场稳定性问题日趋突出。为保证采矿作业的安全,采用声发射技术对采场顶板稳定性进行监测。测试地点选在四工区 25#至 40#进路之间。这些进路处在矿体边界,为一期进路,无假顶,矿岩节理裂隙发育,破碎,稳定性很差,一经揭露便可能发生冒顶。为了建立适合这类地质和开采条件矿岩破坏过程的声发射特征预测模型,同时消除声发射源与测试点距离的影响,每天测试为同一时间、同一地点进行。现以 28#进路为例,根据其工程地质条件,采用声发射事件表征进路顶板岩体状态。表 2 所列为 28#进路在一定时期内测得的声发射参数值。

表 2 28#进路声发射参数值

Table 2 AE parameter values in No.28 stope

| | | | | | | | |
|--|------|------|------|------|------|------|------|
| Monitoring date | 9.18 | 9.19 | 9.20 | 9.21 | 9.22 | 9.23 | 9.24 |
| AE value (times·min ⁻¹) | 3.1 | 1.2 | 4.2 | 2.3 | 5.6 | 8.7 | 11.4 |

选用灰色系统预测方法、指数回归预测方法和指数平滑预测方法分别对表 2 所示的 28#进路声发射参数值进行预测,则有 3 个原始输入 u_1 、 u_2 、 u_3 ,设函数展开阶次 $S=1$,则辅助输入量的数目 $N=2SK=2 \times 1 \times 3=6$,故经函数扩展后有 9 个输入分量以及 10 个权向量。

28#进路声发射参数时间序列 $X=[x_1, x_2, \dots, x_7]$ 的问题就变成求解权系数 $W=[w_0, w_1, \dots, w_9]$ 的问题。由于 $N+K+1=10 > 7$,则可将 X 矩阵分块,得到分块阵 X_B ,其维数为 7×7 , $X_B \neq 0$ 。令 $w_8=w_9=0$ 则 $W=X_B^{-1}Z$ 。可见 28#进路声发射参数时间序列 $X=[x_1, x_2, \dots, x_7]$ 能由单层网络解决非线性估计和拟合问题。

将灰色系统预测方法、指数回归预测方法、指数平滑预测方法的单个预测结果作为函数链神经网络预测模型的原始输入,经函数扩展后,采用模糊自适应变权重组合方法(用 F_2 表示)来进行组合预测,其预测结果与文献[19]中方法(用 F_1 表示)的预测结果进行对比,具体情况如表 3 所列。从表 3 可以看出,文献[19]中方法和本研究提出的预测模型的预测精度都较高,

均能满足非线性的预测要求,但本研究提出的预测模型的预测误差更小,具有更高的预测精度。

表 3 28#进路声发射参数值和预测值

Table 3 AE parameter values and prediction values in No.28 stope

| Date | AE value/ (times· min ⁻¹) | Forecasting value from model/ (times·min ⁻¹) | | |
|------------|---|---|------------------------|-------|
| | | F_1 | Forecasting error/% | F_2 |
| 2009-09-18 | 3.1 | 3.1 | 0.0 | 3.1 |
| 2009-09-19 | 1.2 | 2.2 | 1.0 | 1.4 |
| 2009-09-20 | 4.2 | 4.1 | -0.1 | 4.3 |
| 2009-09-21 | 2.3 | 3.1 | 0.8 | 2.5 |
| 2009-09-22 | 5.6 | 5.9 | 0.3 | 5.7 |
| 2009-09-23 | 8.7 | 9.1 | 0.4 | 9.0 |
| 2009-09-24 | 11.4 | 11.3 | -0.1 | 11.4 |
| 2009-09-25 | | 16.2 | | 15.3 |
| 2009-09-26 | | 19.8 | | 18.5 |
| 2009-09-27 | | 23.6 | | 21.3 |

将表 3 中文献[19]中方法和本研究提出的预测模型所得到的声发射参数预测值代入突变模型的微分同胚变换式(19),并应用函数链神经网络拟合法求出,并进而求出 u 、 v 和 Δ 值,具体结果如表 4 所列。

由表 4 中 Δ 值评价可知,本研究提出的预测模型预报 9 月 27 日出现 $\Delta < 0$ (而文献[19]中方法预报 9 月 27 日出现 $\Delta > 0$),说明 9 月 27 日可能会出现采场冒顶,因而作出了预报。实际情况是,9 月 27 日凌晨距监测点 3.5 m 远处出现了一次大冒落,体积达 25.4 m^3 ,由于事先作出了预报,人员设备及时撤离了现场,避免了一场安全事故的发生,这说明本文作者提出的预测模型的预报结果与实际情况十分吻合。

表 4 采场冒顶预测预报表

Table 4 Prediction of roof caving

| Date | Δ value estimation | |
|------------|---------------------------|-----------------------|
| | F_1 | F_2 |
| 2009-09-23 | 173 232 | 188 324 |
| 2009-09-24 | 3.56×10^{13} | 2.62×10^{13} |
| 2009-09-25 | 1 359.256 | 495.765 |
| 2009-09-26 | 784.4 | 297.8 |
| 2009-09-27 | 323.2 | -23 604 |

3 结论

1) 基于应用声发射技术,结合函数链神经网络理论、模糊自适应变权重算法以及冒顶尖点突变理论,建立了采场冒顶的预报模型,并对某铅锌矿一矿区的一次冒顶进行了预报,应用结果表明,该预测模型的预测误差小于0.3%,能满足非线性的预测要求,并具有较高的预测精度。

2) 基于模糊自适应变权重算法的函数链神经网络预测方法建模数据少,计算简便,预测结果精度较高,方法简便,易于实际应用,具有广泛的适用性,可实现采场冒顶精确预报。

REFERENCES

- [1] 程卫民, 苏绍桂, 辛嵩. 系统安全性预测模型与系统的建立[J]. 辽宁工程技术大学学报, 2003, 22(4): 533–535.
CHENG Wei-min, SU Shao-gui, XIN Song. System safety forecast models and forecast system[J]. Journal of Liaoning Technical University, 2003, 22(4): 533–535.
- [2] 曾康生, 胡乃联. 煤矿系统安全预测模型与组合预测[J]. 煤炭学报, 2008, 33(10): 1122–1125.
ZENG Kang-sheng, HU Nai-lian. Model of system safety forecasting and combination forecasting[J]. Journal of China Coal Society, 2008, 33(10): 1122–1125.
- [3] 刘素兵. 组合预测模型的构建及其应用[D]. 西安: 西安理工大学, 2008.
LIU Su-bing. The establishment and application of combination forecasting model[D]. Xi'an: Xi'an University of Science and Technology, 2008.
- [4] BATES J M, GRANGER C W J. Combination of forecasts[J]. Operations Research Quarterly, 1969, 20(4): 451–468.
- [5] AKSU C, GUNTER S I. An empirical analysis of the accuracy of SA, OLS, ERLS and NRLS combination forecasts[J]. International Journal of Forecasting, 1992(8): 27–43.
- [6] HARVEY N, HARRIES C. Effects of judges' forecasting on their later combination of forecasts for the same outcomes[J]. International Journal of Forecasting, 2004, 20(3): 391–409.
- [7] PALIT A K, POPOVIC D. Nonlinear combination of forecasts using artificial neural network, fuzzy logic and neuro-fuzzy approaches[C]// 2000 the Ninth IEEE International Conference on Fuzzy Systems. San Antonio: The IEEE Neural Networks Council, 2000: 566–561.
- [8] ZOU Hui, YANG Yu-hong. Combining time series models for forecasting[J]. International Journal of Forecasting, 2004, 20(1): 69–84.
- [9] TANG X W, ZHOU Z F, SHI Y. The variable weighted functions of combined forecasting[J]. Computers & Mathematics With Application, 2003, 45(4/5): 723–730.
- [10] CHEN Yu, ZHANG Qi-sen. Application of functional-link neural network in evaluation of sublayer suspension based on FWD test[J]. Journal of Central South University of Technology, 2004, 11(2): 225–228.
- [11] WU Xiao-ling, WANG Chuan-hai, CHEN Xi, XIANG Xiao-hua, ZHOU Quan. Kalman filtering correction in real-time forecasting with hydrodynamic model[J]. Journal of Hydrodynamics, 2008, 20(3): 391–397.
- [12] MOHAMMADI K, ESLAMI H R, KAHAWITA R. Parameter estimation of an ARMA model for river flow forecasting using goal programming[J]. Journal of Hydrology, 2006, 331(1/2): 293–299.
- [13] CHENG Ching-Hsue, CHEN You-Shyang, WU Ya-Ling. Forecasting innovation diffusion of products using trend-weighted fuzzy time-series model[J]. Expert Systems with Applications, 2009, 36(2): 1826–1832.
- [14] AGAMI N, ATIYA A, SALEH M, EL-SHISHINY H. A neural network based dynamic forecasting model for trend impact analysis[J]. Technological Forecasting and Social Change, 2009, 76(7): 952–962.
- [15] 鄂加强, 张华美, 龚金科, 王耀南. 基于函数链神经网络的管道煤气流量计量系统[J]. 中南大学学报: 自然科学版, 2006, 37(5): 976–980.
E Jia-qiang, ZHANG Hua-mei, GONG Jin-ke, WANG Yao-nan. Measurement system for gas flux in pipeline based on function chain neural network[J]. Journal of Central South University: Science and Technology, 2006, 37(5): 976–980.
- [16] 胡力耘, 谷强, 卢杰持. 函数链神经网络在火箭大喷管加工中的应用[J]. 大连理工大学学报, 1997, 37(4): 443–446.
HU Li-yun, GU Qiang, LU Jie-chi. Application of functional-link neural networks to machining rocket jet[J]. Journal of Dalian University of Technology, 1997, 37(4): 443–446.
- [17] 傅鹤林, 桑玉发. 采场冒顶的声发射预测预报[J]. 岩石力学与工程学报, 1996, 15(2): 109–114.
FU He-lin, SANG Yu-fa. Application of acoustic emission technology to predict roof caving[J]. Chinese Journal of Rock Mechanics and Engineering, 1996, 15(2): 109–114.
- [18] 鄂加强, 王耀南, 龚金科, 李春生. 一种新的非线性模糊自适应变权重组合预测模型[J]. 模糊系统与数学, 2006, 20(4): 123–127.
E Jia-qiang, WANG Yao-nan, GONG Jin-ke, LI Chun-sheng. A new nonlinear combined forecasting model based on method of fuzzy adaptive variable weight[J]. Fuzzy Systems and Mathematics, 2006, 20(4): 123–127.
- [19] TSEKOURAS G J, DIALYNAS E N, HATZIARGYRIOU N D, KAVATZA S. A non-linear multivariable regression model for midterm energy forecasting of power systems[J]. Electric Power Systems Research, 2007, 77(12): 1560–1568.

(编辑 李艳红)