

文章编号: 0253-9993(2012)10-1624-06

# 基于多变量混沌时间序列的冲击地压预测

陶 慧<sup>1,2</sup>, 马小平<sup>1</sup>, 乔美英<sup>1,2</sup>

(1. 中国矿业大学 信息与电气工程学院, 江苏 徐州 221116; 2. 河南理工大学 电气工程及其自动化学院, 河南 焦作 454000)

**摘 要:** 考虑到冲击地压的混沌特征及其监测数据含噪且长度有限, 基于多变量时间序列重构和 GRNN 模型来预测冲击地压监测变量。给出了多变量时间序列相空间重构理论和 GRNN 混沌预测原理, 并提出采用遗传算法同时确定最佳重构参数和 GRNN 的光滑因子以保证预测精度。在 Matlab2010a 仿真环境下, 将本文方法用于 Lorenz 系统以验证对含噪且长度有限的混沌序列的适用性, 最后对微震能量和电磁辐射两类数据进行预测研究。结果表明: 即使历史数据有限, 多变量混沌序列预测方法也能提前预测出多个监测变量, 从而实现冲击地压预报。

**关键词:** 冲击地压; 混沌预测; 多变量时间序列; 相空间重构; GRNN; 遗传算法

中图分类号: TD324 文献标志码: A

## Rock burst prediction on multivariate chaotic time series

TAO Hui<sup>1,2</sup>, MA Xiao-ping<sup>1</sup>, QIAO Mei-ying<sup>1,2</sup>

(1. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou 221116, China; 2. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454000, China)

**Abstract:** Given rock burst chaotic characteristics and its limited-length monitor data containing noise, the multiple rock burst monitor variants were predicted on multivariate time series reconstruction and generalized regression neural network (GRNN). The theories of multivariate phase space reconstruction and GRNN prediction were introduced, and the method was proposed that adopting genetic algorithm to simultaneously determine reconstruction parameters and GRNN smoothing parameter to ensure prediction precision. In Matlab2010a environments, the method was simulated on Lorenz system to verify its effectiveness for limited-length multivariate series containing noise. Finally the method was used to microseism energy and electromagnetic radiation signal monitor data, and the results show that the prediction method on multivariate chaotic series can predict multiple monitor variants and therefore forecast rock burst even in the case of relatively limited-history data.

**Key words:** rock burst; chaos prediction; multivariate time series; phase space reconstruction; GRNN; genetic algorithm

冲击地压是矿井生产中最严重的自然灾害之一。随着开采深度的增加和开采范围的扩大, 冲击地压灾害将日趋严重。目前, 冲击地压的监测有微震法、电磁辐射法、钻屑法等多种方法, 监测数据基本上采用基于数理统计的拟合预测<sup>[1]</sup>。但冲击破坏是一动态演化过程, 谢和平、尹光志等已证实其动力学行为具有混沌特性<sup>[2-3]</sup>, 从现场获取的监测数据大多是貌似随机的混沌时间序列, 因此统计理论并不完全适合其

预测, 而应采用混沌时间序列来分析和预测冲击地压。

目前对冲击地压监测数据的混沌特性和预测研究都基于单变量时间序列重构<sup>[4-6]</sup>。理论上, 只要嵌入维数足够大, 单变量时间序列足以重构原动力系统, 但在实践中不能保证任何单变量都能很好的实现重构<sup>[7]</sup>, 此时, 预测精度也没有保证。实际上, 对于复杂的冲击地压监测信息, 用单一指标进行预测本身

就存在很多不足,如无法仅根据电磁辐射信号的幅值或者脉冲数来识别冲击危险性,而应将两者结合起来综合评价<sup>[8]</sup>。因此,对冲击地压的预测应基于多个监测变量的相空间重构。此外,冲击地压监测数据含有噪声且长度有限,由于包含更加丰富的系统信息,多变量时间序列重构预测能弥补数据长度的不足,克服噪声的影响,获得比单变量重构预测更好的效果<sup>[7 9-10]</sup>。

基于相空间重构的神经网络预测法是应用较广泛的混沌预测方法<sup>[11]</sup>。广义回归神经网络(GRNN)在逼近能力和学习速度上较 BP 网络和传统 RBF 网络有着较强的优势。另外,即使样本数据稀少,GRNN 也能够收敛于最优回归表面<sup>[12]</sup>。考虑到冲击地压现场监测样本数量有限,本文采用 GRNN 作为混沌预测的拟合工具。

## 1 多变量重构预测原理

### 1.1 多变量时间序列重构

对于  $l$  个冲击地压的监测变量时间序列  $\{x_{i,n}\}_{n=1}^N$  ( $i=1, 2, \dots, l$ ), 根据多变量时间序列延迟重构的思想<sup>[7 9]</sup> 构造的状态变量  $X_n$  为

$$X_n = (x_{1,n}, x_{1,n-\tau_1}, \dots, x_{1,n-(m_1-1)\tau_1}, x_{2,n}, x_{2,n-\tau_2}, \dots, x_{2,n-(m_2-1)\tau_2}, \dots, x_{l,n}, x_{l,n-\tau_l}, \dots, x_{l,n-(m_l-1)\tau_l})$$

$$n = N_0, N_0 + 1, \dots, N$$

$$N_0 = \max_{1 \leq i \leq l} \{ (m_i - 1)\tau_i + 1 \} \quad (1)$$

其中  $\tau_i$  和  $m_i$  分别为第  $i$  个变量的时间延迟和嵌入维数。由  $X_n$  形成的状态空间的维数  $m$  为

$$m = \sum_{i=1}^l m_i \quad (2)$$

则状态空间中  $X_n \rightarrow X_{n+1}$  的演化反映了原始未知动力系统的演化。经过相空间重构后,存在映射  $G: R^m \rightarrow R^m$  使:

$$X_{n+1} = G(X_n) \quad (3)$$

或存在映射  $G_i: R^m \rightarrow R$  使:

$$x_{i,n+1} = G_i(X_n) \quad (4)$$

也就是说,可根据重构的状态变量来预测时间序列  $x_i$  未来  $l$  步的值。其中  $l$  为预测步长。

### 1.2 GRNN 混沌预测

混沌预测就是根据观测数据构造  $G$  或  $G_i$  的一个近似形式  $\hat{G}$  或  $\hat{G}_i$ 。神经网络具有逼近任意复杂非线性函数的能力,通过训练可建立预测模型  $\hat{G}$  或  $\hat{G}_i$ <sup>[11]</sup>。广义回归神经网络(GRNN)是由美国学者 Donald F. Specht 在 1991 年提出,是 RBF 神经网络模

型的一种。研究表明,GRNN 不仅在逼近能力和学习速度上较 BP 神经网络和传统 RBF 神经网络有着较强的优势。而且,GRNN 人为设置的参数只有一个,最大限度地避免人为设置参数对预测结果的影响。此外,GRNN 的理论基础是非线性回归分析,即使样本数据稀少,网络的输出结果也能够收敛于最优回归表面<sup>[12]</sup>。而 BP 神经网络要求通过批量样本训练。冲击地压时间序列数据样本有限,因此本文采用 GRNN 作为拟合工具来实现混沌预测。

根据式(3)和(4),建立基于多变量相空间重构和 GRNN 的冲击地压预测模型如图 1 所示。

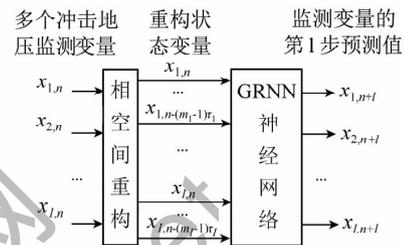


图 1 冲击地压监测变量预测模型

Fig. 1 Prediction model of rock burst monitoring variables

## 2 遗传算法确定最佳参数

多变量相空间重构时,重构参数的选择是关键。可以先利用单变量时序的方法来选择时间延迟,再利用虚假最近邻法、预测误差最小法<sup>[7]</sup>或者条件熵扩维<sup>[13]</sup>等方法来确定嵌入维数。但 Martinerie 等指出时间延迟与嵌入维数的选取存在较强的关联<sup>[14]</sup>,在文献[15]中,我们基于预测误差最小化,采用遗传算法同时确定多变量时间序列的重构参数,考虑了时间延迟与嵌入维数之间的互相影响,取得了较好效果。此外,基于多变量重构的预测效果还与预测模型 GRNN 的光滑因子  $\sigma$  的设置密切相关,  $\sigma$  越小,网络对样本的逼近性就越强;  $\sigma$  越大,网络对样本的逼近过程越光滑,但误差也相应增大。为此本文在文献[15]的基础上进行扩展,采用遗传算法同时优化重构参数和 GRNN 光滑因子,以保证良好的预测效果。

### 2.1 染色体编码

遗传算法是为了选择出最佳的重构嵌入维数、延迟时间和 GRNN 光滑因子  $\sigma$  的组合。为此个体  $Y_d$  的染色体采用多参级联二进制串编码方式:

$$Y_d = [y_1, y_2, \dots, y_l, y_{l+1}, y_{l+2}, \dots, y_{2l}, y_{2l+1}] \quad (5)$$

其中  $y_i$  ( $i=1, 2, \dots, l$ ) =  $[z_{i,1}, z_{i,2}, \dots, z_{i,j_i}]$  为  $m_i$  的编码串;  $y_{l+1}$  ( $l+2, \dots, 2l$ ) =  $[z_{l+1,1}, z_{l+1,2}, \dots, z_{l+1,j_l}]$  为  $\tau_i$  的编码串;  $y_{2l+1}$  =  $[z_{2l+1,1}, \dots, z_{2l+1,j_{2l+1}}]$  为  $\sigma$  的编码串。

所有字符  $z_{ij}$  ( $i=1, 2, \dots, 2l+1$ ) 取 0 或 1。  $m_i$  和  $\tau_i$  为正整数  $\sigma$  的取值范围为  $[0, 1]$ 。解码得各个参数的表达式为

$$m_i = \sum_{j=1}^{J_i} 2^{z_{ij}} + 1 \quad (6)$$

$$\tau_i = \sum_{j=1}^{J_{l+i}} 2^{z_{l+i,j}} + 1 \quad (7)$$

$$\sigma = \sum_{j=1}^{J_{2l+1}} 2^{-z_{2l+1,j}} \quad (8)$$

## 2.2 适应度函数的设计

预测误差越小,说明参数的选择越合理<sup>[15]</sup>。因 GRNN 预测时,要对数据进行归一化,本文将归一化平均均方误差  $e_{NSE}$  定义为预测误差。

$$e_{NSE} = \frac{1}{N_p} \sum_{p=1}^{N_p} \frac{1}{l} \sum_{i=1}^l \left( \frac{\hat{x}_{i, n_0+l} - x_{i, n_0+l}}{x_{(i, n_0+l) \max} - x_{(i, n_0+l) \min}} \right)^2 \quad (9)$$

式中,  $N_p$  为预测样本个数;  $x_{i, n_0+l}$ 、 $\hat{x}_{i, n_0+l}$  分别为实际值和预测值;  $x_{(i, n_0+l) \max}$ 、 $x_{(i, n_0+l) \min}$  分别为最大和最小值。

误差计算采用  $K$ -fold 交叉验证法<sup>[12]</sup>,训练时,将训练样本均分为  $K$  份,除去任意 1 份,用其余  $K-1$  份学习样本训练 GRNN,然后对除去样本进行预测,可得到各个训练子集的预测结果。假设  $N_k$  为第  $k$  份样本集中的样本个数。取全部样本的预测误差平均值的倒数作为适应度函数  $f_1(Y_d)$ ,即

$$f_1(Y_d) = \frac{1}{\frac{1}{K} \sum_{k=1}^K \frac{1}{N_k} \sum_{i=1}^{N_k} \sum_{j=1}^l \left( \frac{\hat{x}_{i, n_0+l} - x_{i, n_0+l}}{x_{(i, n_0+l) \max} - x_{(i, n_0+l) \min}} \right)^2} \quad (10)$$

此外,在构建重构相空间域的 GRNN 预测模型时,GRNN 输入变量个数(也就是相空间的重构维数)越少,预测模型越简单,越不容易出现过拟合现象。因此,适应度函数  $f(Y_d)$  在  $f_1(Y_d)$  的基础上减去关于嵌入维数  $m$  的惩罚函数。

$$f(Y_d) = f_1(Y_d) - Cm \quad (11)$$

式中,  $C$  为惩罚系数,根据经验来试探选择。

## 2.3 遗传操作

选择操作采用基本的轮盘赌方法,即基于适应度比例的选择策略。由于染色体编码为多参数编码的级联组合,交叉操作采用多点交叉算子。

针对多参数级联的编码方式,采用了一种新的变异操作—级联单点变异。其步骤为:将染色体  $Y_d$  拆分成  $2l+1$  个子串,分别对每个子串进行单点变异操作,再拼接成新的个体串  $Y_d$ 。这种变异操作不仅使每个子串都能获得相同的变异概率,不易造成不同参数解

的精度差异过大;而且对每个子串的变异只限于一位,也不易因变异面积过大而造成个体适应度值的振荡,具有较好的稳定性。

## 3 实例应用

### 3.1 实验步骤

本文在 Matlab2010a 下进行仿真的步骤为:

(1) 根据染色体编码原则随机产生  $D$  个初始个体。

(2) 基于交叉验证原则计算各个个体在训练集上的适应度函数。

(3) 通过遗传操作得到下一代种群。

(4) 重复步骤(2)、(3),经过迭代最终确定最优的重构参数和 GRNN 的光滑因子。

(5) 根据最佳重构参数对多变量时间序列进行重构,并将光滑因子设置为最佳值,以重构后的状态变量作为 GRNN 的输入,再次训练 GRNN。

(6) 在重构相空间域,利用训练好的 GRNN 模型来预测冲击地压监测变量的第  $l$  步值。

### 3.2 Lorenz 系统预测

首先以典型混沌系统 Lorenz 系统<sup>[13]</sup>为例来分析本方法的预测效果。Lorenz 系统方程如下:

$$\begin{cases} \frac{dx}{dt} = \sigma(y - x) \\ \frac{dy}{dt} = x(r - z) - y \\ \frac{dz}{dt} = xy - bz \end{cases} \quad (12)$$

其中  $\sigma = 10$ ,  $r = 28$ ,  $b = 8/3$ ; 初始值  $x_0 = 15.34$ ,  $y_0 = 13.68$ ,  $z_0 = 37.91$ ; 采用四阶 Runge-Kutta 在积分步长为 0.04 时计算 3 个变量的 6 000 组数据,为消除瞬态的影响,去掉前 5 500 组数据,对后 500 组数据的  $x$ 、 $y$  两个变量进行相空间重构。首先将数据归一化,前 400 个数据为训练数据,后 100 个数据为预测数据。

在遗传算法中,染色体设计为 22 位二进制数,其中重构参数  $m_i$  和  $\tau_i$  的取值范围设置为  $[1, 8]$ ,每个参数由 3 位二进制数,两个变量的重构参数的编码串为 12 位,  $\sigma$  编码采用 10 位二进制数;种群规模为 30;进化代数数为 100。以单步预测误差计算适应度函数时,  $K=5$ , 惩罚系数  $C$  取 10;采用 3 点交叉,交叉概率为 0.6;变异概率 0.05;适应度曲线如图 2 所示,经过遗传操作后得到的最优个体为: 0100100100110001101011,对应的最优参数为  $m_1 = 3$ ,  $m_2 = 3$ ,  $\tau_1 = 3$ ,  $\tau_2 = 4$ ,  $\sigma = 0.1045$ 。得到的单步预测结果如图 3 所示。在最佳参数下, Lorenz 系统的预测精

度非常高。

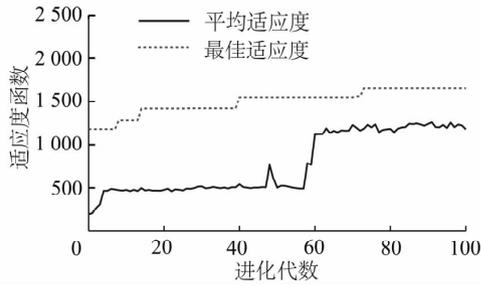


图 2 适应度函数进化曲线

Fig. 2 Evolution curves of fitness function

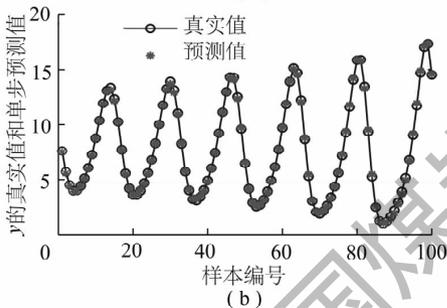
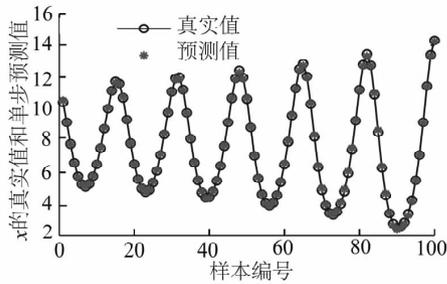


图 3 Lorenz 系统的单步预测结果

Fig. 3 One-step prediction results of Lorenz system

采用 GRNN 神经网络作为预测模型,不同方法确定重构参数的预测误差比较见表 1,其中 IFNN<sup>[7]</sup>为单变量推广的虚假邻近点法确定嵌入维数  $m = m_1 + m_2 = 2 + 1 = 3$ ,互信息法确定时间延迟  $\tau_1 = \tau_2 = 4$ ; CEED<sup>[13]</sup>为互信息法确定时间延迟,条件熵扩维确定  $m = m_1 + m_2 = 2 + 4 = 6$ 。由表 1 可以看出,由于混沌系统对初始值敏感依赖性,虽然多步预测的误差要大于单步预测;但总体来说本文的方法能取得更好的预测效果。

表 1 基于不同方法确定重构参数的预测误差

Table 1 Prediction error with reconstruction parameters determined by different methods

方法	单步预测 $e_{NSE} / 10^{-5}$	三步预测 $e_{NSE} / 10^{-5}$	五步预测 $e_{NSE} / 10^{-5}$	七步预测 $e_{NSE} / 10^{-5}$
IFNN	4.883	7.862	8.145	15.52
CEED	6.448	18.06	35.91	57.35
本文方法	1.963	3.862	9.335	16.70

为了讨论本文方法对含噪声且数据长度有限的冲击地压时间序列预测的适用性,对原始数据添加一定的噪声,并缩短时间序列的长度进行仿真研究。此外,不同的预测模型的预测效果也不相同。采用不同预测模型对不同噪声比例和长度的数据进行单步预测的结果比较见表 2。在表 2 中,无论是否含有噪声,GRNN 模型比一阶加权局部模型的预测精度要高得多,相对于 BP 神经网络和传统 RBF 神经网络,GRNN 的预测精度也有所提高。另外,GRNN 特别明显的优势是对数据长度的依赖性不强,即使在较短的数据下,预测精度也能保持在一定的水平上。这说明本文的方法能够用于含噪且数据长度有限的冲击地压时间序列预测。

表 2 不同的模型在不同噪声和数据长度下的预测误差

Table 2 Prediction errors under different models noises and data-lengthen

条件	局部预测 $e_{NSE} / 10^{-5}$	BPNN $e_{NSE} / 10^{-5}$	传统 RBF $e_{NSE} / 10^{-5}$	GRNN $e_{NSE} / 10^{-5}$	
400 个数据	无噪声	24.27	1.894	5.961	1.963
	2% 噪声	62.38	21.97	12.67	8.448
	5% 噪声	103.4	71.24	67.61	36.80
200 个数据	无噪声	45.42	8.262	26.04	4.874
	2% 噪声	106.7	46.80	44.10	18.69
	5% 噪声	324.3	78.40	72.54	47.19
100 个数据	无噪声	105.2	38.26	45.60	14.84
	2% 噪声	217.2	86.89	97.31	25.96
	5% 噪声	832.8	186.8	194.7	65.53

### 3.3 冲击地压预测实例

#### 3.3.1 基于微震能量的冲击地压预测

微震监测是一种应用广泛的冲击地压监测方法。煤岩体在开采影响下发生破裂滑动过程中会产生地震波,微震监测系统通过拾震器对微震事件进行实时监测,能够较为准确地获得已发生微震事件的震源位置、发生时间和释放能量<sup>[16-17]</sup>。本案例数据来源于某矿微震监控系统,监测时间从 2009-08-12—2010-09-15 共 400 d,取日累计微震能量  $\lg \sum E$  和日最大微震能量  $\lg E_{\max}$  两个时间序列做重构预测。由于监测到的能量在  $10 \sim 10^7$  J 之间,范围较大,而震级与微震能量的对数呈线性关系,这里对原始微震能量数据做了取对数处理。前 350 组数据为训练样本,后 50 组数据为测试样本。遗传算法的参数设置和 3.2 节相同。得到最佳重构参数为  $m = m_1 + m_2 = 3 + 2 = 5$ ;  $\tau_1 = \tau_2 = 1$ ; GRNN 的最佳  $\sigma = 0.3008$ 。

不同数据长度下采用不同变量重构预测时,  $\lg \sum E$  和  $\lg E_{\max}$  的预测误差见表 3。其中单变量或双变量指重构的时间序列个数, I 或 II 表示数据长度为 150 或 350。由表 3 可以看出,一方面,数据长度越长,预测精度越高。另一方面,在数据长度相等的情况下,相对于单变量重构,双变量重构的预测误差大幅下降,即使在不到单变量重构的一半数据,其预测也略好于单变量预测。这说明多变量时间序列在一定程度上克服数据长度的限制。

表 3 微震系统不同重构变量和数据长度的预测误差

Table 3 Prediction error of microseism with different models under different data-lengthens

重构方法	一步预测误差 $e_{NSE}/10^{-4}$		三步预测误差 $e_{NSE}/10^{-4}$	
	$\lg \sum E$	$\lg E_{\max}$	$\lg \sum E$	$\lg E_{\max}$
单变量 I	15.4	17.8	33.7	38.4
单变量 II	6.65	8.91	16.9	18.5
双变量 I	6.21	7.36	14.3	15.7
双变量 II	2.57	3.37	10.2	11.4

在最佳参数下,采用双变量重构得到的预测结果如图 4 所示。虽然相比于标杆混沌系统 Lorenz 系统,实际混沌系统的预测误差要大得多,但基于双变量的微震时间序列的重构预测具有较高的精度。实际上,该矿 8 月 16 日在己二轨下四区段口、9 月 12 日在己 16-17-22122 风巷与二胶带下山交叉口向南 70 m 发生了较大冲击震动,而在图 4 的第 20 和 47 样本点即发生冲击震动的对应时间里,我们看到单步预测法(提前一天)预测出了对应的  $\lg \sum E$  和  $\lg E_{\max}$  会非常大,三步(提前 3 d)预测的效果虽差一些,但也能预测出这两个样本点将发生较大冲击震动,因此,通过多变量混沌时间序列历史数据的重构预测,提前较为准确地预测出微震能量的大小,从而实现冲击地压预报。

### 3.3.2 基于电磁辐射的冲击地压预测

电磁辐射信号能够捕捉到煤岩体破坏前的非稳定和加速扩展,因此可以作为预测冲击破坏的前兆指标<sup>[4,8]</sup>。本案例数据来源于某煤矿 24110 工作面,取工作面间隔 7 架 1 个点,共 24 个点测得的电磁辐射信号的日平均幅值  $x_1$  和日最大脉冲数  $x_2$  两个时间序列为重构变量;监测时间从 2008-10-01—2009-06-05 共 250 d。其中有少量数据缺失,采用三次插值算法进行填充。前 200 组样本作为训练数据,后 50 组数据作为测试数据。遗传算法的参数设置和 3.2 节相同。

遗传算法得出最佳重构参数为  $m = m_1 + m_2 = 4 +$

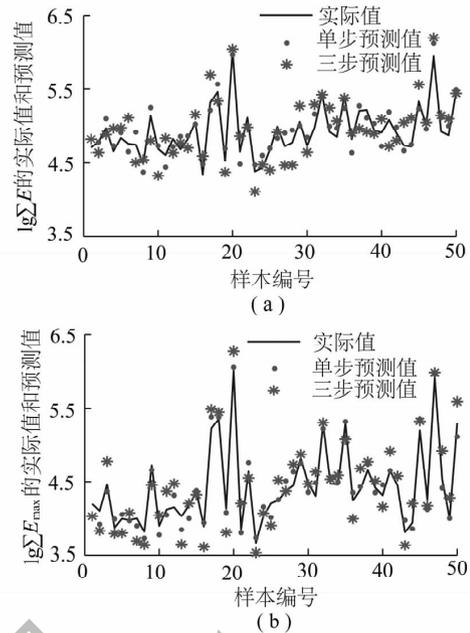


图 4 微震时间序列的预测结果

Fig. 4 Prediction results of microseism time series

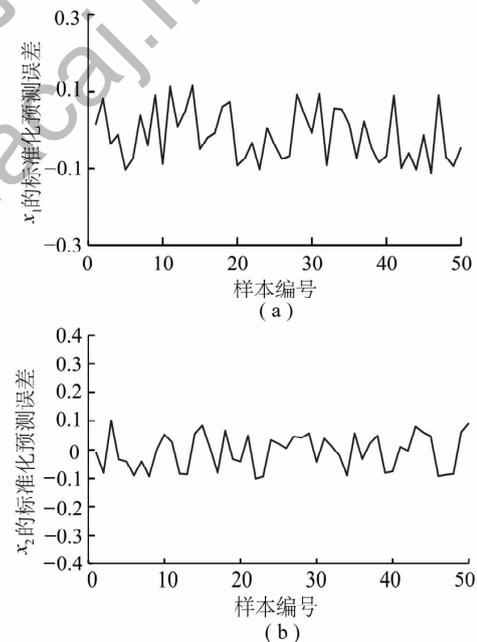


图 5 电磁辐射时间序列的预测误差

Fig. 5 Prediction error of electromagnetic radiation time series  $3 = 7$ ,  $\sigma_1 = \sigma_2 = 1$ ; GRNN 的  $\sigma = 0.408 2$ 。  $x_1, x_2$  一步预测标准化误差如图 5 所示,可以看出本文的方法有一定的预测精度。在最佳重构参数下,电磁辐射信号  $x_1$  和  $x_2$  的一步平均预测误差  $e_{NSE}$  分别为  $2.8 \times 10^{-3}$ ,  $3.4 \times 10^{-3}$ , 三步预测误差为  $5.5 \times 10^{-3}$ ,  $6.4 \times 10^{-3}$ 。虽然相对于微震能量预测(表 3),电磁辐射信号的预测误差略大一些,这是由于电磁辐射监控信号的抗干扰能力差一些,而且存在少量的数据的缺失,但是,本方法仍能够通过提前较为准确的预测出大的冲击震动,

有效的指导冲击地压的预测。实际上,该工作面在 4 月 25 日、5 月 14 日和 5 月 27 日均有冲击震动,由于提前预测和及时解危处理,未造成事故。

#### 4 结 论

本文在多变量混沌时间序列的相空间重构的基础上,采用 GRNN 预测模型实现对多个冲击地压监测变量的预测,并采用遗传算法来确定最佳参数组合。

(1) 多个监测变量含有系统更加丰富的信息,基于多变量序列的重构预测提高了监测变量的预测精度,能够提前准确预测出大的冲击震动,从而实现冲击地压的提前预报和防治。

(2) 遗传算法可以同时确定相空间重构的嵌入维数、时间延迟和 GRNN 预测模型的参数,基于最佳参数的重构预测可以取得更好的预测效果。

(3) GRNN 预测模型能够克服冲击地压数据样本稀少的限制,预测精度较高。

#### 参考文献:

- [1] 赵善坤,李宏艳,刘 军,等.深部冲击危险矿井多参量预测预报及解危技术研究[J].煤炭学报,2011,36(S2):339-345.  
Zhao Shankun, Li Hongyan, Liu Jun, et al. The research of deep rock burst dangerous mine prediction with multi-parameter and danger recession technology [J]. Journal of China Coal Society, 2011, 36(S2): 339-345.
- [2] Xie Heping, Chen Zhida. Fractal geometry and fracture of rock [J]. Acta Mechanica Sinica, 1988, 4(3): 255-264.
- [3] 黄 滚,尹光志.冲击地压黏滑失稳的混沌特性[J].重庆大学学报,2009,32(6):633-637.  
Huang Gun, Yin Guangzhi. Chaotic behavior of stick slip in rock bursts [J]. Journal of Chongqing University, 2009, 32(6): 633-637.
- [4] 刘贞堂,赵恩来,王恩元,等.不同尺度电磁辐射时间序列的混沌特征初步分析[J].煤炭学报,2009,34(2):224-227.  
Liu Zhen tang, Zhao Enlai, Wang Enyuan, et al. Chaotic characteristic of electromagnetic radiation time series of coal or rock under different scales [J]. Journal of China Coal Society, 2009, 34(2): 224-227.
- [5] 宋维源,潘一山,苏荣华,等.冲击地压的混沌学模型及预测预报[J].煤炭学报,2001,26(1):26-31.  
Song Weiyuan, Pan Yishan, Su Ronghua, et al. Forecast and chaos model of rockburst [J]. Journal of China Coal Society, 2001, 26(1): 26-31.
- [6] 李 洪,戴仁竹,蒋金泉.基于最大 Lyapunov 指数的冲击地压预测模型[J].采矿与安全工程学报,2006,23(2):215-219.  
Li Hong, Dai Renzhu, Jiang Jinquan. Predicting model of rock burst based on Lyapunov index [J]. Journal of Mining & Safety Engineering, 2006, 23(2): 215-219.
- [7] 王海燕,卢 山.非线性时间序列分析及其应用[M].北京:科学出版社,2006.  
Wang Haiyan, Lu Shan. Nonlinear time series analysis and its application [M]. Beijing: Science Press, 2006.
- [8] 陈国祥,窦林名,曹安业,等.电磁辐射法评定冲击矿压危险等级及应用[J].煤炭学报,2008,33(8):866-870.  
Chen Guoxiang, Dou Linming, Cao Anye, et al. Assessment of rock burst danger and application on electromagnetic emission method [J]. Journal of China Coal Society, 2008, 33(8): 866-870.
- [9] Cao Liangyue, Mees Alistair, Judd Kevin. Dynamics from multivariate time series [J]. Physica D, 1998, 121: 75-88.
- [10] Porporato A, Ridolfi L. Multivariate nonlinear prediction of river flows [J]. Journal of Hydrology, 2001(248): 109-122.
- [11] 张玉梅,曲仕茹,温凯歌.基于混沌和 RBF 神经网络的短时交通流量预测[J].系统工程,2007,25(11):26-30.  
Zhang Yumei, Qu Shiru, Wen Kaige. A short-term traffic flow forecasting method based on chaos and RBF neural network [J]. Systems Engineering, 2007, 25(11): 26-30.
- [12] Sprechtd Donald F. A general regression neural network [J]. IEEE Trans Neural Networks, 1991, 2: 568-576.
- [13] 张春涛,马千里,彭 宏,等.基于条件熵扩维的多变量混沌时间序列相空间重构[J].物理学报,2011,60(2):1-8.  
Zhang Chuntao, Ma Qianli, Peng Hong, et al. Multivariate chaotic time series phase space reconstruction based on extending dimension by conditional entropy [J]. Acta Physica Sinica, 2011, 60(2): 1-8.
- [14] Martinerie J M, Albano A M, Mees A I, et al. Mutual information, strange attractors, and the optimal estimation of dimension [J]. Physical Review A, 1992, 45(10): 7058-7064.
- [15] Tao Hui, Ma Xiaoping, Qiao Meiyang. Determining parameters in the phase-space reconstruction of multivariate time series on genetic algorithm [J]. Proc. of International Conference on Intelligence Science and Information Engineering, 2011: 81-84.
- [16] Cao Anye, Dou Linming, Yan Ruling, et al. Classification of microseismic events in high stress zone [J]. Mining Science and Technology, 2009, 19(6): 718-723.
- [17] 夏永学,潘俊锋,王元杰,等.基于高精度微震监测的煤岩破裂与应力分布特征研究[J].煤炭学报,2011,36(2):239-243.  
Xia Yongxue, Pan Junfeng, Wang Yuanjie, et al. Study of rule of surrounding rock failure and stress distribution based on high-precision microseismic monitoring [J]. Journal of China Coal Society, 2011, 36(2): 239-243.