

高边坡开挖变形的非线性时间序列预测分析

周家文, 徐卫亚, 石安池

(河海大学 岩土工程研究所, 江苏 南京 210098)

摘要: 在岩体高边坡开挖过程中, 可以得到现场的位移监测数据, 如何利用现场监测数据来预测高边坡的开挖变形是一件很有实用价值的工作。根据高边坡开挖变形时间序列的非线性特征, 应用局域法对三峡高边坡的位移进行了预测分析。把局域法的思想引入到神经网络中去, 按照寻找邻近点的原理构造出训练样本, 通过神经网络得到的预测值与局域法得到的预测值很接近, 并且可以大大地节约计算时间。计算结果表明, 对于岩土体工程中的一维监测数据, 通过非线性时间序列分析方法可以对其进行预测分析, 该方法具有较高的实用价值。

关键词: 岩石力学; 开挖变形; 非线性时间序列; 局域法; 混沌; 神经网络

中图分类号: TU 457

文献标识码: A

文章编号: 1000 - 6915(2006)增 1 - 2795 - 06

APPLICATION OF NONLINEAR TIME SERIES ANALYSIS TO EXCAVATION DEFORMATION PREDICATION OF HIGH SLOPE

ZHOU Jiawen, XU Weiya, SHI Anchi

(*Institute of Geotechnical Engineering, Hohai University, Nanjing, Jiangsu 210098, China*)

Abstract: In the course of high rock slope excavation, the deformation data in the locale can be monitored, and it's useful to predicate the excavation deformation of high slope with the monitor data. According to the nonlinear characteristics of the excavation deformation of high slope, the displacements of the high slope of the Three Gorges are predicted by local-region method. The idea of the local-region method is introduced to the neural network, and the training samples are formed according to the theory of finding near points. The predicated displacements by the trained neural network are very close to those by the local-region method, and computational time is saving. The result shows that, based on the one-dimensional monitoring data, the displacement can be predicted by the method of nonlinear time series, and the method has practical value.

Key words: rock mechanics; excavation deformation; nonlinear time series; local-region method; chaos; neural network

1 引言

在岩体开挖过程中, 通过对高边坡的长期监测, 可以得到现场的位移监测数据, 如何利用现场监测来预测高边坡的开挖变形是一件很有实用价值的工作^[1]。岩石的开挖位移是一个受到多种因素影响的

复杂的非线性动力系统, 如果直接通过建立开挖过程中的非线性动力学方程来进行相关分析或者是预测分析是一件很困难的事情, 寻找一种可以避开上述难题来解决开挖过程中的反分析问题成了很有实际意义的研究工作。近年来, 鉴于边坡变形的非线性特征和影响因素的模糊不确定性, 黄志全等^[2]提出了基于神经网络的边坡位移预测方法; 李邵军

收稿日期: 2005 - 11 - 05; **修回日期:** 2005 - 12 - 02

基金项目: 国家重点基础研究发展规划(973)项目(2002CB412707); 国家自然科学基金重点项目(50539110)

作者简介: 周家文(1982 -), 男, 2003 年毕业于华东交通大学建筑工程系, 现为博士研究生, 主要从事岩石力学方面的研究工作。E-mail: hhzjw@hhu.edu.cn

等^[3]提出了基于三维地理信息的边坡变形智能预测方法；杨成祥等^[4]提出了边坡位移的进化算法识别模型；蒋刚等^[5]应用灰色理论建立了边坡变形预测模型；应用分形理论^[6]、模糊数学、人工智能理论、系统控制论等方法进行边坡位移和稳定预测的研究发展也很快。非线性时间序列预测方法是20世纪80年代末发展起来的一种非线性预测方法，对于一维数据的预测，它已经在很多方面得到了应用^[7~14]，如电力系统的短期负荷预测、证券市场股价的预测、天气预报、边坡位移的预测等。

对三峡永久船闸高边坡现场监测的一维位移数据，首先采用一阶近似拟合局域法进行预测分析，可以得到需要预测的位移值。局域法的计算量比较大，而且计算时间较长；但是根据局域法这种思想，通过相空间重构，就可以确定输入层的神经元数目，然后构建一组学习样本，通过混沌神经网络^[15]来进行预测分析，可以节约大量的时间，并且还可以大大地减少计算量。神经网络是由大量简单的神经元相连而组成的复杂系统，它不需要建立非线性动力学方程，只是依靠过去的经验去学习，就可以很好地解决开挖过程中的非线性问题。本文采用目前应用最为广泛的BP神经网络(以下简称BP网络)，但在BP网络的计算过程中，存在2个缺陷：容易陷入局部最小和收敛速度过慢。引入模拟退火算法到BP网络中去就能很好地解决BP网络的2个缺陷，使得预测结果更加精确。根据监测数据分析变形演化规律，预测其发展趋势，已经成为设计施工的基本任务之一。

2 预测模型

岩石的开挖变形是一个受多种因素影响而发展演化的非线性混沌系统。在岩石的开挖过程中，很容易得到现场的位移与时间曲线，这就是一个非线性时间序列。而其他影响开挖变形的因素的非线性时间序列比较难以得到，因此，如何避开其他因素，只利用开挖过程中位移与时间的非线性时间序列 $x(t_1), x(t_2), \dots, x(t_n)$ 来建立合适的动态模型来预测 $x(t_{n+1})$ ，是一个很有实际应用价值的研究工作。

2.1 重构相空间

在非线性动力学的研究中，Packard等人建议用原始系统中的某变量的延迟坐标来重构相空间，Takens于1980年提出了由一维数据通过相空间重构来刻画整个系统。相空间的基本思想为：系统中

任一变量的变化都受到与之相关变量的影响，这些变量的变化过程就是整个系统的发展过程。

设单变量的时间序列为 $\{x(t_i), i=1, 2, \dots, n\}$ ，其相空间重构的具体算法如下：

根据如果吸引子的维数为 d ，要保证与原空间的相同状态，则 $m \geq 2d + 1$ ，然后由互信息法第1次到达的极小值来确定时间延迟 τ 。这样，时间序列 $\{x(t_i), i=1, 2, \dots, n\}$ 的相空间为

$$Y_i(t) = \{x(t_i), x(t_i + \tau), \dots, x(t_i + (m-1)\tau)\} \quad (i=1, 2, \dots, m) \quad (1)$$

2.2 基于相空间重构的预测方法

基于相空间重构的非线性时间序列预测方法有很多，根据拟合相空间中吸引子的方式可分为全域法和局域法。全域法是拟合轨迹中的全部点，找出时间序列的内部规律，用得到的预测函数来预测轨迹的走向。局域法是将相空间的最后一点作为中心点，把离中心点最近的几个点作为相关点，利用这些相关点来对轨迹的下一点做出预测。许多数值研究已经证明，局域法优于全域法。本文采用的预测算法是一阶近似拟合局域法，还有基于局域法的混沌神经网络法。

2.2.1 局域法

一阶近似拟合局域法的基本思想为：对于一个一维的非线性时间序列 $Y_M(t) = \{Y_1, Y_2, \dots, Y_M\}$ ，把时间序列的最后一点 Y_M 作为中心点，找出中心点的最小邻域(即邻近点)，假设第 M 点的小邻域为 j_1, j_2, \dots, j_n ，这几个邻近点必需满足如下的表达式： $|Y_M - Y_{j_i}| \leq |Y_M - Y_{M-j_i}| (i=1, 2, \dots, n; n < M; Y_{j_i} \in Y_M)$ 。而且还可知对应于这几个邻近点的下一点的数值(Y_{j_i+1})，根据 $Y_{j_i+1} = a + bY_{j_i}$ 的关系可以确定一个方程组，利用最小二乘法就可以解出 a 和 b 的值。然后利用中心点即时间序列上的最后一点 Y_M 的值，根据 $Y_{M+1} = a + bY_M$ 的关系式就可以确定下一点 Y_{M+1} 的值。接下来把 Y_{M+1} 作为中心点，按以上方法可以同样计算得到 Y_{M+1} 下一点 Y_{M+2} 的数值，如此反复，就可以得到所有需要预测的数值。

2.2.2 混沌神经网络

2.2.2.1 BP网络

人工神经网络^[16]的应用非常广泛，它不仅应用于工程、科学和数学领域，还可应用于医学、商业和文学等。人工神经网络是由大量简单的神经元相连而组成的复杂系统，它具有记忆、联想、归纳、概括和抽取以及自组织、自学习和自适应的能力，它不需要建立非线性动力学方程，即可很好地解决

开挖过程中的非线性问题。BP 网络即反向传播网络，该网络是目前使用最为广泛的神经网络。理论上已经证明一个 3 层的 BP 网络可以以任意精度去逼近任意非线性映射关系。典型的 BP 网络具有 3 层结构，即输入层、隐含层和输出层。

2.2.2.2 基于模拟退火算法的 BP 网络

模拟退火算法^[17~19]最早是由 Metropolis 在 1953 年提出的，这是一种改进的 Monte Carlo 方法。模拟退火算法是局部搜索算法的扩展，其基本思想是通过模拟高温物体退火过程的方法来寻找优化问题的全局最优解。在降温退火过程中，其能量函数服从 Boltzmann 分布规律： $P(\Delta E) \propto \exp(-\Delta E/T)$ ，其中 $P(\Delta E)$ 为系统能量变化时的概率， T 为系统的温度。

基于模拟退火算法的 BP 网络是利用模拟退火算法来修正权值向量的，如果发现计算陷入局部最小，则调用模拟退火算法子程序，这样通过模拟退火算法在解决局部最小问题方面的优势，能够很好地解决 BP 神经网络容易陷入局部最小的问题。而且模拟退火算法还可以大大提高程序的计算速度。进行优化 BP 神经网络，在预测过程中能够得到更精确的预测值。

模拟退火算法的子程序计算过程如下：设定系统初始温度为 T_0 ，迭代次数 $n=0$ ，对于当前的权值 W_1 (输入层到隐含层的权值)和 V_1 (隐含层到输出层的权值)，计算当前的能量值 E 。然后按照某一随机过程，产生一很小的扰动 δW_1 和 δV_1 ，并修改权值和偏差： $W_2 = W_1 + \delta W_1$ ， $V_2 = V_1 + \delta V_1$ ，计算该状态下的能量值 E_1 。若 $E_1 < E$ ，则接受该状态， $W_1 = W_2$ ， $V_1 = V_2$ ；若 $E_1 \geq E$ ，先计算能量改变值 ΔE ，再计算系统能量变化的概率 $P(P = \exp[-(E_1 - E)/T(t)])$ ， $T(t)$ 为此时的温度，产生 $[0, 1]$ 区间的一随机小数 $rand$ ，再按 Boltzmann 分布确定是否接受当前修改。若 $P > \varepsilon$ 则接受这次修改；若 $P \leq \varepsilon$ 则进入下一次的迭代计算， $n = n + 1$ ，并按给定的冷却方程对系统进行降温，直至冷却到给定的终止温度为止。通过模拟退火算法优化的 BP 网络可以跳出局部最小从而达到全局最小，并且大大提高计算精度。

3 预测算法

3.1 邻近点

对于一个非线性时间序列来说，寻找时间序列上某点的邻近点对于计算很重要，如果简单的去寻

找，则增加了不必要的麻烦，而且效率不高。因为本文所提到的 2 个预测算法都要寻找某点的邻近点，对于一个非线性时间序列来说，根据邻近点的关系式： $|Y_M - Y_{j_i}| \leq |Y_M - Y_{M-j_i}| (i=1, 2, \dots, n; n < M; Y_{j_i} \in Y_M =$ 编制了一个简单的 C 程序，从而提高了寻找邻近点的计算速度。

3.2 局域法

采用一阶近似拟合局域法进行预测，其基本预测过程为：用 $Y_M = a + bY_{M-1}$ 来拟合第 M 点的小邻域，假设第 M 点的小邻域为 j_1, j_2, \dots, j_n ，选择 n 个数很重要，一般令 $n > d + 1$ ，但又不应该过大，则

$$\begin{Bmatrix} Y_{j_1+1} \\ Y_{j_2+1} \\ \vdots \\ Y_{j_n+1} \end{Bmatrix} = a + b \begin{Bmatrix} Y_{j_1} \\ Y_{j_2} \\ \vdots \\ Y_{j_n} \end{Bmatrix} \quad (2)$$

用最小二乘法计算出式中的 a 和 b ，最后通过：

$$Y_{M+1} = a + bY_M \quad (3)$$

可以得到 Y_{M+1} 的预测值。然后把 Y_{M+1} 作为中心点，也可以得到它的小邻域，如上所述，得到另一组 a 和 b 值，利用得到的 Y_{M+1} 可以对下一未知量 Y_{M+2} 进行预测，如此下去，就可以得到所有需要预测的未知量。

3.3 混沌神经网络预测算法

混沌神经网络预测算法的基本计算过程如下：

(1) 对一个一维的非线性时间序列 $Y_M(t)$ ，利用相空间重构来确定输入层神经元的数目，通过对监测数据的计算，得到监测数据的嵌入维，可以得出输入层的神经元数目；对于隐含层的神经元数目来说，为了提高计算精度，这里尽量把隐含层的神经元数目设的多一点；对于输出层来说，因为就是 1 个输出，所以输出层的神经元数目为 1。

(2) 构造训练样本，来对神经网络进行训练。利用 $Y_M(t)$ 时间序列中前 $M - 1$ 个数据来构造一定数量的训练样本。对于其中的一点 $Y_j (1 < j \leq M - 1)$ 来说，首先找出 Y_j 的几个邻近点 $Y_{j_i} (1 \leq i \leq n)$ ，把 Y_{j_i} 作为网络的输入， Y_j 的下一点值 Y_{j+1} 作为网络的输出。将训练样本输入神经网络，计算输出值和监测值的均方误差，通过误差控制，如果计算结果达到允许的范围之内，就直接可以认为网络训练成功，如果误差没有达到允许的范围之内，还需对其进行判断，通过考虑训练的次数来判断陷入局部最小，如果陷入局部最小就调用模拟退火子程序。通过模

拟退火算法，来对权值和偏值进行修改，直到达到误差所允许的范围之内，即网络拟和达到了规定的要求。

(3) 混沌预测过程，对于所需要预测数值 Y_{M+1} ，首先利用 Y_M 来构造一个输入样本，构造方法与训练样本的构造方法一样，也是找到 Y_M 的几个邻近点，就可以构造出输入样本。将构造好的样本输入到训练好的神经网络中，就可以得到所需要预测的值，即 Y_{M+1} 。

(4) 对于下一点 Y_{M+2} 的预测，首先要更新训练样本，即把点 Y_M 构造出的训练样本添加到原来的训练样本中去，再对网络重新训练一次，然后利用 Y_{M+1} 构造出 Y_{M+2} 的输入样本即可对 Y_{M+2} 进行预测。如果不更新训练样本的话，虽然也可以对 Y_{M+2} 进行预测，但精度就有所降低。

4 工程实例

长江三峡工程永久船闸为双线五级船闸，在山体中深挖修建。由于三峡工程规模巨大、技术复杂、综合效益显著，在船闸南、北坡及中隔墩部位布置有大量的监测设施来对高边坡的变形进行监测。通过对监测数据的研究，来对开挖变形进行预测分析，具有很高的实用价值。用上述算法对三峡永久船闸三闸首高边坡 17 - 17 剖面的外观测点 TP/BM 28GP02 的位移监测数据进行了预测分析。TP/BM 28 GP02 的位移监测数据如图 1 所示，位移监测数据的时间是 1995 年 4 月 15 日~2004 年 4 月 14 日，监测时间的间隔基本上都为 1 个月，总共有 110 个数据点。为了提高预测的精度，这里只选取位移时间序列的后 20 个点进行预测分析，前面的 90 个点作为混沌神经网络的训练样本。对于 3 个方向的位




图 1 监测点 TP/BM28GP02 的位移曲线

Fig.1 Displacement curves of monitoring point TP/BM28GP02

移数据，选取 y 方向(沿临空方向)的位移数据进行预测分析，另外 2 个方向上的位移预测方法与 y 方向上的位移预测方法是一样的，这里就不再具体说明。

首先采用一阶近似拟合的局域法进行预测，进行局域法预测的过程中，选择邻近点的个数 n 很重要，一般令 $n > d + 1$ ，这里设 $n = 3$ 。在预测过程中， a 和 b 的值在不断的变化，其预测过程如下：

为了预测位移时间序列上的第 91 点位移值，先要找到中心点第 90 点的位移值 40.2 mm，然后找到这个点的小邻域(即 3 个邻近点 40.14, 40.25 和 40.54 mm)，构造出 1 个方程组：

$$\left. \begin{aligned} a + 40.14b &= 40.25 \\ a + 40.25b &= 40.54 \\ a + 40.54b &= 40.61 \end{aligned} \right\} \quad (4)$$

由此可以得到 a 和 b 的解为： $a = -65.573 6$ ， $b = 2.636 36$ ，根据第 90 点的位移值就可以推求下 1 点第 91 点的位移值为 40.408 2 mm。接下来把第 91 点作为中心点，找出这个点的小邻域(即 3 个邻近点 40.25, 40.54 和 40.59 mm)，构造出 1 个方程组：

$$\left. \begin{aligned} a + 40.25b &= 40.54 \\ a + 40.54b &= 40.61 \\ a + 40.59b &= 40.20 \end{aligned} \right\} \quad (5)$$

由此可以得到 a 和 b 的解为： $a = 30.824 5$ ， $b = 0.241 38$ ，根据第 91 点的位移值就可以推求第 92 点的位移值为 40.578 1 mm。

把第 92 点作为中心点，继续如上的计算，则可以计算得到第 93 点的位移值，如此反复往下操作，就可以得到后面所有点的位移数据，计算结果如表 1 所示，并作了误差分析。

再进行混沌神经网络的预测，根据相空间重构原理，计算出嵌入维数 $m = 3$ ，确定输入神经元的数目为 3，选取隐层的神经元数目为 10，输出层的神经元数目为 1。根据局域法的原理，用位移监测数据的前 90 个数据来构造出一组训练样本，数目有 50 个，如表 2 所示。把训练样本输入神经网络，待训练成功后，输入需要预测的样本，即第 91 点的输入样本(40.25, 40.14, 40.54)，可以得到需要预测的位移。对于下 1 点的预测，先要更新训练样本，对网络重新训练 1 次，然后输入需要预测的样本(输入

表1 监测点 TP/BM28GP02 的 y 方向位移数据

Table 1 Displacement data in y direction of monitor point TP/BM28GP02

序号	实测值 /mm	预测值 (局域法) /mm	误差 /%	预测值 (混沌神经网络) /mm	误差 /%
91	40.81	40.408	-0.985 050	40.59	-0.539 080
92	40.98	40.578	-0.980 970	40.63	-0.854 080
93	41.09	40.800	-0.705 770	40.73	-0.876 130
94	41.23	40.759	-1.142 370	40.81	-1.018 680
95	40.58	40.650	0.172 499	40.93	0.862 494
96	41.44	41.160	-0.675 680	41.01	-1.037 640
97	42.76	40.379	-5.568 290	41.32	-3.367 630
98	41.66	40.571	-2.614 020	41.54	-0.288 050
99	41.45	40.765	-1.652 590	41.68	0.554 885
100	42.03	40.853	-2.800 380	41.63	-0.951 700
101	41.58	40.617	-2.316 020	41.34	-0.577 200
102	41.11	40.995	-0.279 740	41.55	1.070 299
103	42.54	40.581	-4.605 080	41.72	-1.927 600
104	41.61	40.815	-1.910 600	41.51	-0.240 330
105	41.38	40.712	-1.614 310	41.62	0.579 990
106	40.92	40.995	0.183 284	41.32	0.977 517
107	41.11	41.200	0.218 925	41.43	0.778 399
108	41.47	40.337	-2.732 100	41.56	0.217 024
109	41.62	40.561	-2.544 450	41.68	0.144 161
110	41.49	40.715	-1.867 920	41.61	0.289 226

表2 第91点的训练样本

Table 2 Training samples of point No.91

序号	输入			输出					
1	14.99	15.13	15.22	14.99	26	25.21	26.68	26.77	26.99
2	14.99	15.13	15.19	14.30	27	26.68	26.74	26.99	27.28
3	14.99	15.13	14.99	14.97	28	27.64	28.38	29.48	33.14
4	14.99	15.13	14.99	14.99	29	28.38	29.48	31.21	33.58
5	14.99	15.13	14.99	15.28	30	29.48	31.21	33.14	35.57
6	15.13	15.22	15.19	16.94	31	31.21	33.14	33.58	35.71
7	15.22	15.19	15.28	17.76	32	33.14	33.58	35.57	35.93
8	15.22	15.28	16.94	19.11	33	35.71	35.93	35.57	36.04
9	15.28	16.94	17.76	19.25	34	35.71	35.93	36.03	34.16
10	16.94	17.76	19.11	19.77	35	33.58	35.71	35.57	34.48
11	17.76	19.11	19.25	20.34	36	33.58	35.57	34.16	32.40
12	19.25	19.77	20.34	20.21	37	31.21	33.14	33.58	33.90
13	19.77	20.34	20.60	19.63	38	34.78	36.66	36.31	38.23
14	19.11	19.25	19.77	19.58	39	37.86	38.23	38.6	37.29
15	19.25	19.77	19.63	19.74	40	38.23	37.29	38.05	36.22
16	19.77	19.63	19.58	19.86	41	37.29	37.39	37.24	38.58
17	19.63	19.77	19.74	19.86	42	38.60	38.23	38.05	38.61
18	19.77	19.74	19.86	21.04	43	38.23	38.05	38.58	39.11
19	20.34	20.60	20.21	22.09	44	38.60	38.58	38.61	38.58
20	20.34	20.60	21.04	23.44	45	38.60	38.61	38.58	39.36
21	20.6	21.04	22.09	24.50	46	37.86	37.39	37.49	38.97
22	21.04	22.09	23.44	25.21	47	39.36	40.25	40.14	40.61
23	22.09	23.44	24.50	26.68	48	40.25	40.54	40.61	40.59
24	23.44	24.50	25.21	26.77	49	40.54	40.61	40.25	40.20
25	24.50	25.21	26.68	27.64	50	39.36	40.25	40.14	40.61

样本也在不停的变化), 即可得到该点的预测值, 计算结果如表 1 所示, 并进行了误差分析。

由表 1 可知, 局域法和混沌神经网络得到的预测值与监测位移值相差很小, 局域法预测值的最大误差为 5.568 290%, 最小误差为 0.172 499%, 平均误差为 1.778 501%; 混沌神经网络预测值的最大误差为 3.367 630%, 最小误差为 0.144 161%, 平均误差为 0.857 610%。因为混沌神经网络是根据局域法的思想构造训练样本, 所以其计算结果与局域法的计算结果比较接近, 由于对神经网络进行了优化, 其计算精度有所提高。

根据计算结果, 可以画出监测点 TP/BM28GP02 的非线性时间序列预测曲线, 如图 2 所示。




图2 监测点 TP/BM28GP02 的非线性时间序列曲线
Fig.2 Nonlinear time series curves of monitoring point TP/BM28GP02

5 结 语

利用非线性时间序列可以很好解决高边坡开挖

变形过程中的非线性动力学特性,在预测分析过程中有很大的实用价值。本文利用非线性时间序列方法,对三峡船闸高边坡的开挖变形首先利用局域法进行了预测,得到了较好的预测结果。然后把局域法的思想引入到神经网络中去,通过局域法计算过程中寻找邻近点的思想构造了训练样本,并且混沌神经网络得到的预测值与局域法得到的预测值比较接近,精度比局域法高一些。计算结果表明,对于岩土工程中的一维监测数据,通过非线性时间序列的方法,可以对其进行较好的预测分析,对实际工程来说有较高的实用价值。

参考文献(References):

- [1] 杨林德. 岩土工程问题的反演理论与工程实践[M]. 北京: 科学出版社, 1996.(Yang Linde. Theory of Back Analysis and Engineering Application of Geotechnical Engineering Problem[M]. Beijing: Science Press, 1996.(in Chinese))
- [2] 黄志全, 崔江利, 刘汉东. 边坡稳定性预测的混沌神经网络方法[J]. 岩石力学与工程学报, 2004, 23(22): 3 808 - 3 812.(Huang Zhiquan, Cui Jiangli, Liu Handong. Chaotic neural network method for slope stability prediction[J]. Chinese Journal of Rock Mechanics and Engineering, 2004, 23(22): 3 808 - 3 812.(in Chinese))
- [3] 李邵军, 冯夏庭, 杨成祥, 等. 基于三维地理信息的滑坡监测及变形预测智能分析[J]. 岩石力学与工程学报, 2004, 23(21): 3 673 - 3 678.(Li Shaojun, Feng Xiating, Yang Chengxiang, et al. Landslide monitoring and intelligent analysis on deformation prediction based on three-dimensional geographic information[J]. Chinese Journal of Rock Mechanics and Engineering, 2004, 23(21): 3 673 - 3 678.(in Chinese))
- [4] 杨成祥, 冯夏庭, 刘红亮, 等. 非线性时间序列分析模型的进化识别[J]. 东北大学学报(自然科学版), 2004, 25(5): 497 - 500.(Yang Chengxiang, Feng Xiating, Liu Hongliang, et al. Evolutionary identification of analysis model for nonlinear displacement time series[J]. Journal of Northeastern University(Natural Science), 2004, 25(5): 497 - 500.(in Chinese))
- [5] 蒋刚, 林鲁生, 刘祖德, 等. 边坡变形的灰色预测模型[J]. 岩土力学, 2000, 21(3): 244 - 246.(Jiang Gang, Lin Lusheng, Liu Zhude, et al. Prediction grey model for slope displacement[J]. Rock and Soil Mechanics, 2000, 21(3): 244 - 246.(in Chinese))
- [6] 曾开华, 张忠坤, 吴九红. 分形在边坡预测中的应用[J]. 地下空间, 1999, 19(1): 35 - 39.(Zeng Kaihua, Zhang Zhongkun, Wu Jiuhong. Application of fractal theory to slope prediction[J]. Underground Space, 1999, 19(1): 35 - 39.(in Chinese))
- [7] 安鸿志, 陈敏. 非线性时间序列分析[M]. 上海: 上海科学技术出版社, 1998.(An Hongzhi, Chen Min. Nonlinear Time Series Analysis[M]. Shanghai: Shanghai Scientific and Technical Publishers, 1998.(in Chinese))
- [8] Torresa M E, Gamero L G. Relative complexity changes in time series using information measures[J]. Physica A, 2000, 286: 457 - 473.
- [9] Zhang G P, Patuwo B E, Hu M Y. A simulation study of artificial neural networks for nonlinear time-series forecasting[J]. Computers and Operations Research, 2001, 28: 381 - 396.
- [10] Timmer J. Parameter estimation in nonlinear stochastic differential equations[J]. Chaos, Solitons and Fractals, 2000, 11: 2 571 - 2 578.
- [11] Rico-Martinez R, Adomaitis R A, Kevrekidis I G. Noninvertibility in neural networks[J]. Computers and Chemical Engineering, 2000, 24: 2 417 - 2 433.
- [12] Timmer J, Rust H, Horbelt W, et al. Parametric, nonparametric and parametric modelling of a chaotic circuit time series[J]. Physics Letters A, 2000, 274: 123 - 134.
- [13] 邓兰松, 沈菲. 非线性时序的混沌特性分析与预测[J]. 天津大学学报, 2004, 37(11): 1 022 - 1 025.(Deng Lansong, Shen Fei. Analysis and predication of fund index of nonlinear time series[J]. Journal of Tianjin University, 2004, 37(11): 1 022 - 1 025.(in Chinese))
- [14] 唐璐, 齐欢. 混沌和神经网络结合的滑坡预测方法[J]. 岩石力学与工程学报, 2003, 22(12): 1 984 - 1 987.(Tang Lu, Qi Huan. Predication of landside based on chaos and neural networks[J]. Chinese Journal of Rock Mechanics and Engineering, 2003, 22(12): 1 984 - 1 987.(in Chinese))
- [15] Kwok T, Smith K A. Experimental analysis of chaotic neural network models for combinatorial optimization under a unifying framework[J]. Neural Networks, 2000, 13: 731 - 744.
- [16] 陈炳瑞, 冯夏庭, 丁秀丽, 等. 基于模式-遗传-神经网络的流变参数反演[J]. 岩石力学与工程学报, 2005, 24(4): 553 - 558.(Chen Bingrui, Feng Xiating, Ding Xiuli, et al. Back analysis of rheological parameters based on pattern-genetic-neural network[J]. Chinese Journal of Rock Mechanics and Engineering, 2005, 24(4): 553 - 558.(in Chinese))
- [17] Sexton R S, Dorsey R E, Johnson J D. Optimization of neural networks: a comparative analysis of the genetic algorithm and simulated annealing[J]. European Journal of Operational Research, 1999, 114: 589 - 601.
- [18] Sadighi M, Setayeshi S, Salehi A A. PWR fuel management optimization using neural networks[J]. Annals of Nuclear Energy, 2002, 29: 41 - 51.
- [19] 刘先珊, 费文平, 张林. 一种大坝渗透系数分区反演新方法研究[J]. 岩土力学, 2004, 25(11): 1 823 - 1 827.(Liu Xianshan, Fei Wenping, Zhang Lin. A study on a new method for divisional of dam seepage coefficient[J]. Rock and Soil Mechanics, 2004, 25(11): 1 823 - 1 827.(in Chinese))