

# 基于BP神经网络-马尔科夫链模型的 隧道围岩位移预测

龙浩,高睿,孔德新,刘鹏

(武汉大学土木建筑工程学院,武汉 430072)

**摘要:**在隧道工程施工中,围岩位移预测起着很重要的作用。将BP神经网络-马尔科夫链模型引入到隧道围岩位移预测中来,通过对训练样本的学习,利用BP神经网络实现了对位移时间序列的滚动预测,同时得到了实测值与预测值的相对误差;在此基础上利用马尔科夫链对相对误差进行修正,有效地提高了预测结果的精度。并将该模型应用于某公路隧道拱顶下沉位移时序预测中,结果表明该模型具有精度高、科学可靠的特点,为隧道围岩变形的预测提供了新的途径。

**关键词:**位移预测;BP神经网络;马尔科夫链;隧道围岩

**中图分类号:**TU45

**文献标志码:**A

**文章编号:**1001-5485(2013)03-0040-04

## 1 研究背景

隧道工程由于受开挖方法、地质条件以及支护时机、方法等诸多因素的影响,受力特点极其复杂,其围岩的位移变形在多因素的共同作用下具有一定的随机波动特征<sup>[1]</sup>。现场监测虽然可以获得隧道围岩即时的变形特点,但是其耗费的人力物力较大,且耗时长。因此,变形预测在隧道设计和施工中发挥了重要的作用。随着计算机技术的发展,许多智能预测方法被用到变形预测当中来,如回归分析、灰色理论、数据平滑处理、时间序列分析等<sup>[2-3]</sup>。这些方法各有其优缺点,如回归模型的优点是模型简单,容易确定参数,但其需要的原始数据比其他方法要多,导致计算量大;灰色模型则具有需要原始数据较少的优点,对于短期内的预测精度较高,但远期预测有失真的趋势,故难以进行长期预测<sup>[4]</sup>。

BP(Back Propagation)神经网络是一种按分层传播的前馈型网络结构<sup>[5]</sup>,由于其能准确描述输入值和输出目标之间的映射关系,BP神经网络已广泛应用于图像处理、经济预测、信号处理、岩土工程等领域。马尔科夫链MC(Markov Chain)<sup>[6]</sup>由于不受过去状态的影响,对于受多种因素影响的时间序列预测具有一定的优越性。为了提高预测的准确性,

更好地发现和模拟隧道围岩位移时间序列的内在规律,本文将综合2种预测方法的BP神经网络-马尔科夫链预测模型(BP-MC)引入到隧道围岩位移预测中来,并将该预测模型应用于鹰嘴岩隧道拱顶下沉位移预测研究中,结果表明该模型预测精度高并且求解快捷,在工程实践中具有一定的推广应用价值。

## 2 BP-MC 预测模型构建

### 2.1 BP神经网络预测模型

BP神经网络对非线性预测来说是一个强有力的工具,从理论上讲,一个3层的BP网络能够在保证精度的情况下实现对任意连续函数的逼近<sup>[7]</sup>,其结构见图1。对于非连续函数来说,如果隐含层包含足够多的结点,也可以实现逼近。因此,BP神经网络可以用来建立高度非线性的围岩位移时程模型<sup>[8]</sup>。




图1 BP网络示意图

Fig. 1 Structure of the BP neural network

收稿日期:2012-04-23

基金项目:国家自然科学基金资助项目(51178358);湖北省自然科学基金重点资助项目(2010CDA057)

作者简介:龙浩(1989-),男,湖南永州人,硕士研究生,主要从事岩土工程方面研究,(电话)13037109909(电子信箱)longhao202@yahoo.cn。

通讯作者:高睿(1975-),男,湖北鄂州人,教授,博士,主要从事交通岩土工程方面的研究,(电话)13397129120(电子信箱)gaorui@whu.edu.cn。

BP神经网络预测模型参数(如隐含层数,最大训练次数,学习精度,隐节点数,初始权值、阈值等)的确定要靠网络训练来实现。训练步骤可表述如下,流程见图2:

- (1) 随机给定连接权值和阈值的初始值。
  - (2) 在网络中提供输入值  $P_k$  和目标输出值  $T_k$ ,并计算出实际输出值  $T'_k$ 。
  - (3) 对权重进行修正。权重的修正采取梯度法,输出与样本理想输出的误差函数为
- $$E = \frac{1}{2} \sum_{k=1}^n (T_k - T'_k)^2. \tag{1}$$
- 权值修正函数
- $$w_{ij} = w_{ij} + \Delta w_{ij} = w_{ij} + \eta \delta_{qi} \gamma_{qi}. \tag{2}$$
- 式中: $\eta$ 为学习因子; $q$ 为第 $q$ 个学习样本; $i$ 为输出或隐结点; $\delta_{qi}$ 为误差修正系数。
- (4) 训练误差达到设定好的收敛误差  $\varepsilon$ ,则停止训练;否则计算出实际输出值  $T'_k$ ,重复步骤(3),直到训练误差  $E$  小于预先设定的收敛误差  $\varepsilon$ 。

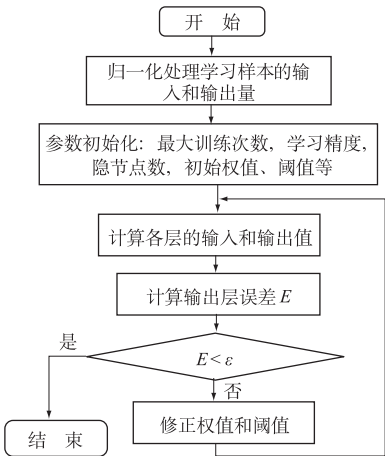


图2 BP算法程序流程图

Fig.2 Flowchart of the BP algorithm program

2.2 滚动预测

根据经典预测理论可知,预测时步越多,预测值与实际值之间的误差越大<sup>[9]</sup>。因此,对于单一的时间序列需要采用滚动预测的方法来减少误差,滚动预测在单一时间序列中的应用可以表述为<sup>[1]</sup>:假设要对单一时间序列  $\{x_t\}$  进行预测,滚动预测是利用已知的  $s$  个时序预测其后的  $p$  个时序;当获得要预测的  $p$  个时序实测值后,用其代替  $s$  个时序中最前面的  $p$  个时序,用以进行下一次  $p$  个时序的预测。滚动预测可以利用最新的实测数据对后面的时序进行预测,大大地提高了预测的精度。

2.3 MC 误差修正模型

马尔科夫链(Markov chain)是应用随机过程理论来描述事件的发展规律以及预测可能的结果<sup>[10]</sup>,

其自20世纪初被Markov提出后经100多年发展,已被广泛地应用于交通、通信、岩土等领域。

根据马尔科夫链理论,首先应该把预测值相对误差区间根据相对误差的大小和分布密度划为  $n$  个状态,记为  $S = [S_1, S_2, \dots, S_n]$ ,相对误差状态从  $S_i$  经  $m$  时步转移到状态  $S_j$  的概率为<sup>[11]</sup>

$$P_{ij}^{(m)} = \frac{M_{ij}(m)}{M_i} \quad (i, j = 1, 2, \dots, n) \tag{3}$$

式中: $M_{ij}(m)$ 为  $S_i$  经  $m$  时步转移到  $S_j$  的次数; $M_i$  为相对误差处于状态  $S_i$  的个数,在统计  $M_i$  时,由于无法确定最后时序的发展状态,因此要把最后的  $m$  个状态去掉。

则第  $m$  时步时序状态转移矩阵  $P(m)$  可表示为

$$P(m) = \begin{bmatrix} P_{11}^{(m)} & P_{12}^{(m)} & \cdots & P_{1n}^{(m)} \\ P_{21}^{(m)} & P_{22}^{(m)} & \cdots & P_{2n}^{(m)} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1}^{(m)} & P_{n2}^{(m)} & \cdots & P_{nn}^{(m)} \end{bmatrix}.$$

(4)

在建立状态转移矩阵  $P(m)$  后,可根据  $P(m)$  来修正基于BP神经网络得到的预测值以减少误差。首先选取离预测时步最近的  $N$  个实测值,一般取  $N = n$ <sup>[12]</sup>,依据状态转移矩阵中得到第  $i(i = 1, 2, \dots, n)$  个实测值经  $m(m = n, n - 1, \dots, 1; m + i = n + 1)$  时步转移到预测时步状态的概率,并把所得到的  $n$  个概率求和,最大值所处的误差状态即可认为是预测时步相对误差所处的状态。

确定预测时步的误差状态,也就确定了BP神经网络预测值相对误差的变化范围,本文认为该区间的中点就是最可能的预测值相对误差。则最可能的位移时序预测值为

$$F(x) = (1 + \bar{\Delta})f(x) = \left[ 1 + \frac{(\Delta_U + \Delta_D)}{2} \right] \times f(x).$$

(5)

式中: $F(x)$ 为修正后的预测值; $f(x)$ 为BP神经网络滚动预测值; $\Delta_U$ 与  $\Delta_D$  分别为预测值相对误差所处区间的上下限值; $\bar{\Delta}$ 为平均相对误差。

2.4 BP-MC 模型预测步骤

本文构造出用于隧道围岩位移预测的BP-MC串联模型,其预测步骤为:

- (1) 根据现场监控所测得的隧道拱顶下沉位移数据,以前5次位移量为一组,构造出BP网络训练样本空间;
- (2) 对每一个训练样本进行多次迭代,使收敛误差达到设定值,确定神经网络的参数,并用检验样

本检验该网络的适用性;

(3) 计算出隧道拱顶下沉位移实测值和预测值的相对误差;

(4) 对相对误差进行分类,利用马尔科夫链计算出第  $m$  步状态转移矩阵;

(5) 用 BP 神经网络对隧道位移时间序列进行滚动预测,并对其进行修正相对误差实现隧道拱顶下沉的最终预测。

3 工程实例

为了验证 BP - MC 模型在隧道围岩位移预测中的有效性和适用性,本文结合文献[13]给出的鹰嘴岩隧道拱顶下沉的位移观测时间序列进行了验证。

鹰嘴岩<sup>[13]</sup>隧道位于重庆东南部,为一座上、下行分离的 4 车道高速公路特长隧道,右线全长 3 310 m(桩号 YK39 + 470 至 ZK42 + 780),左线全长 3 247 m(桩号 ZK39 + 520 至 ZK42 + 767),均属特长隧道,隧道最大埋深 349 m。根据地质资料显示,隧道所处围岩岩石坚硬,大部分为石灰岩,强度高,水文地质条件中等,除断层破碎带和岩溶发育带围岩稳定性较差外,大部分地段为Ⅳ和Ⅴ类围岩,围岩比较稳定。在同一垂直开挖断面内,夏冲<sup>[13]</sup>选择如图 3 所示的测点布置形式,其中 3 号测点设在拱顶,1 号、2 号测点设在起拱线附近,4 号、5 号测桩设在隧道底面以上 1.5 m 左右;A、B、C、D 代表测线,该布置形式可很好地记录和反映隧道开挖断面围岩变形情况,同时其对隧道右线进口桩号为 YK39 + 660 的断面进行了实时监测,位移监测结果见表 1。




图 3 测点布置形式

Fig.3 Layout of measuring points

3.1 BP 神经网络拱顶下沉预测

本文以 2006 年 12 月 19 至 2007 年 2 月 13 该隧道拱顶下沉的监测数据作为分析对象,监测时间间隔为 2 d,总计 29 个时步。将实测的 29 组数据分成 2 个部分,前 25 组为 BP 神经网络的学习样本,后 4 组为 BP - MC 预测模型的检验样本,BP 神经网络中相关参数设置为:输入层为 5 个结点、隐含层为 1 层(包含 11 个结点)、输出层为 1 个结点,即表示在滚动预测中  $s = 5, p = 1$ ;最大训练次数为 1 000 次,最大循环间隔数为 50 次;训练收敛误差为 0.001。表 1 列出了 25 时步各学习样本的位移实测值、BP 神经网络预测值、绝对误差和相对误差。

表 1 拱顶实际下沉及 BP 神经网络预测值

Table 1 Measured and predicted values of vault settlement

时间	时步	实测值/ mm	预测值/ mm	绝对误差/ mm	相对误差/ %	所处 状态
2006-12-19	1	0.75				
2006-12-21	2	1.78				
2006-12-23	3	2.52				
2006-12-25	4	2.94				
2006-12-27	5	3.42				
2006-12-29	6	4.13	4.08	0.05	1.21	$S_4$
2006-12-31	7	4.47	4.52	-0.05	-1.12	$S_1$
2007-01-02	8	4.85	4.82	0.03	0.62	$S_3$
2007-01-04	9	4.92	4.95	-0.03	-0.61	$S_2$
2007-01-06	10	5.21	5.10	0.11	2.11	$S_4$
2007-01-08	11	5.42	5.41	0.01	0.18	$S_3$
2007-01-10	12	5.48	5.50	-0.02	-0.36	$S_2$
2007-01-12	13	5.65	5.60	0.05	0.88	$S_3$
2007-01-14	14	5.78	5.76	0.08	1.38	$S_4$
2007-01-16	15	5.83	5.85	-0.02	-0.34	$S_2$
2007-01-18	16	5.92	5.88	0.04	0.68	$S_3$
2007-01-20	17	5.9	5.92	-0.02	-0.34	$S_2$
2007-01-22	18	5.97	5.98	-0.01	-0.17	$S_2$
2007-01-24	19	6.04	6.03	0.01	0.17	$S_3$
2007-01-26	20	6.08	6.06	0.02	0.33	$S_3$
2007-01-28	21	6.07	6.08	-0.01	-0.16	$S_2$
2007-01-30	22	6.05	6.08	-0.03	-0.50	$S_2$
2007-02-01	23	6.10	6.08	0.02	0.33	$S_3$
2007-02-03	24	6.09	6.12	-0.03	-0.49	$S_2$
2007-02-05	25	6.12	6.20	-0.08	-1.31	$S_1$

3.2 MC 残差修正

根据实测值与 BP 网络预测值之间相对误差的大小和分布密度,将其划分为 4 个状态,见表 2。根据表 2 可以确定训练样本相对误差所处的状态,结果见表 1。

表 2 相对误差状态划分表

Table 2 Classification of relative errors

状态编号	相对误差界限/%
$S_1$	$[-4, -1)$
$S_2$	$[-1, 0)$
$S_3$	$[0, 1)$
$S_4$	$[1, 4)$

根据表 1 和表 2,由式(2)和式(3)可以计算出  $m$  步( $m = 1, 2, 3, 4$ )状态转移矩阵为:

$$P(1) = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 3/8 & 4/8 & 1/8 \\ 0 & 5/7 & 1/7 & 1/7 \\ 1/3 & 1/3 & 1/3 & 0 \end{bmatrix};$$
$$P(2) = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 2/7 & 4/7 & 1/7 \\ 1/7 & 4/7 & 1/7 & 1/7 \\ 0 & 1/3 & 2/3 & 0 \end{bmatrix};$$

$$P(3) = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 1/7 & 5/7 & 1/7 & 0 \\ 0 & 1/6 & 4/6 & 1/6 \\ 0 & 2/3 & 1/3 & 0 \end{bmatrix};$$
$$P(4) = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 1/6 & 2/6 & 3/6 & 0 \\ 0 & 4/6 & 2/6 & 0 \\ 0 & 1/3 & 0 & 2/3 \end{bmatrix}。$$

以第 26 时步为例,选取离第 26 时步最近的 4 个时步(第 22,23,24,25 时步)为样本来预测第 26 时步相对误差所处的状态,结果见表 3。由表 3 可知,第 26 时步相对误差最有可能处于  $S_3$  状态,则根据式(5),可计算出第 26 时步 BP - MC 模型的预测值:

$$F(x) = (1 + \Delta)f(x) = (1 + \frac{1 - 0}{2}\%) \times 6.08 = 6.12 \text{ mm}。$$

此时第 26 时步的实测值为 6.11 mm, BP 神经网络预测值为 6.08 mm,由此可见, BP - MC 预测模型可以有效地提高预测精度。

表 3 第 26 时步的相对误差状态预测  
Table 3 Forecast of relative error state at the 26<sup>th</sup> time step

时步	转移步数	起始状态	状态编号			
			$S_1$	$S_2$	$S_3$	$S_4$
25	1	$S_1$	0	0	1	0
24	2	$S_2$	0	0.286	0.571	0.143
23	3	$S_3$	0	0.167	0.666	0.167
22	4	$S_2$	0.167	0.333	0.500	0
合计			0.167	0.786	2.737	0.310

根据计算第 26 时步预测值的步骤,用 BP - MC 预测模型对 27—29 时步进行滚动预测,结果见表 4。由表 4 可知, BP - MC 预测模型相比单一的 BP 预测模型而言,可以较大地提高预测值的精度。

表 4 实测值与预测值的比较  
Table 4 Comparison of measured and predicted values

时步	实测值/mm	BP 模型		BP - MC 模型	
		预测值/mm	相对误差/%	预测值/mm	相对误差/%
26	6.11	6.08	0.49	6.12	-0.16
27	6.13	6.18	-0.82	6.15	-0.33
28	6.15	6.23	-1.30	6.11	0.65
29	6.16	6.25	-1.46	6.13	0.49

4 结 语

基于 BP 神经网络和马尔科夫链 2 种预测方法,本文建立了新的隧道围岩位移预测模型。采用 BP 神经网络预测隧道拱顶下沉位移的发展规律,再用马尔科夫链进行残差修正,提高了预测的精度和有效性,同时克服了地质条件、开挖方式等因素对围

岩位移预测的影响。通过在工程实例中的应用,相比单一的 BP 神经网络预测方法其结果更接近实测值,表明该模型是可行的,在岩土工程中有一定的推广应用价值。

参考文献:

[1] 徐 飞,徐卫亚. 基于支持向量机 - 马尔可夫链的位移时序预测[J]. 岩土力学, 2010, 31(3):944 - 948. (XU Fei, XU Wei-ya. Prediction of Displacement Time Series Based on Support Vector Machines-Markov Chain [J]. Chinese Journal of Rock Mechanics and Engineering, 2010, 31(3): 944 - 948. (in Chinese))

[2] 李晓红. 隧道新奥法及其量测技术[M]. 北京:科学出版社, 2002. (LI Xiao-hong. NNM and Measure Technology for Tunnel [M]. Beijing: Science Press, 2002. (in Chinese))

[3] 徐干成,白洪才,郑颖人,等. 地下工程支护结构[M]. 北京:中国水利水电出版社,2002. (XU Gan-cheng, BAI Hong-cai, ZHENG Ying-ren, et al. Support Structure for Underground Engineering [M]. Beijing: China Water Power Press, 2002. (in Chinese))

[4] 郝 哲,刘庆恩,刘 斌. 公路隧道开挖围岩位移预测及稳定性预报[J]. 公路, 2004, (8): 197 - 203. (HAO Zhe, LIU Qing-en, LIU Bin. Displacement Prediction and Stabilization Forecast of Surrounding Rock of Highway Tunnel Excavation [J]. Highway, 2004, (8): 197 - 203. (in Chinese))

[5] 阎平凡. 人工神经网络与模拟进化计算[M]. 北京:清华大学出版社, 2000. (YAN Ping-fan. ANN and Simulated Evolutionary Computation Theory [M]. Beijing: Tsinghua University Press, 2000. (in Chinese))

[6] 崔锦龙,邓姝杰. 基于马尔可夫模型的降水预测及其利用[J]. 资源开发与市场, 2008, 24(2): 115 - 117. (CUI Jin-long, DENG Shu-jie. Precipitation Forecast by Markov Model and Its Application [J]. Resource Development & Market, 2008, 24(2): 115 - 117. (in Chinese))

[7] 刘 刚. 基于 BP 神经网络的隧道围岩稳定性分类的研究与工程应用[D]. 合肥:合肥工业大学土木与水利工程学院, 2008. (LIU Gang. Classification of Surrounding Rock Stability in Tunnels and Its Engineering Application Based on BP Neural Network [D]. Hefei: Scholl of Civil Engineering in Hefei University of Technology, 2008. (in Chinese))

[8] 丁德馨,张志军. 位移反分析的自适应神经模糊推理方法[J]. 岩石力学与工程学报, 2004, 23(18):3087 - 3092. (DING De-xin, ZHANG Zhi-jun. ANFIS-Based Approach for Back Analysis of Displacements [J]. Chinese Journal of Geotechnical Engineering, 2004, 23(18): 3087 - 3092. (in Chinese))