

基于神经网络的大断面软土隧道收敛安全监测的预测方法

郝 飞，孙全胜，周晓杰

(东北林业大学，哈尔滨 150040)

摘要：在软土隧道的施工工程中，隧道的收敛变形是一个十分复杂的过程，影响因素很多，为了能够合理地模拟隧道施工后的收敛变形，指导隧道的安全施工，采用BP神经网络方法以时间和里程2个方面为出发点，对软土隧道的收敛变形进行预测。以哈尔滨市保健路打通工程为实例，证明了利用BP网络的预测结果能够很好地指导软土隧道的施工，精度更准确，对实际工程有更好地指导意义。

关键词：大断面软土隧道；收敛；神经网络；预测方法

DOI：10.3973/j.issn.1672-741X.2012.02.009

中图分类号：U 456.3

文献标志码：A

文章编号：1672-741X(2012)02-0175-05

Prediction of Convergence of Large Cross-section Soft Soil Tunnels Based on Neural Network

HAO Fei, SUN Quansheng, ZHOU Xiaojie

(Northeast Forestry University, Harbin 150040, China)

Abstract: The convergence of soft soil tunnels is very complex. In the paper, the convergence of soft soil tunnels is predicted by means of BP neural network method, with the construction of the tunnel on Baojian Road in Harbin as an example, so as to simulate the convergence of soft soil tunnels and to provide guidance for the safe construction of soft soil tunnels. The practice proves that the results of prediction by BP neural network are accurate and can provide guidance for the construction of soft soil tunnels.

Key words: large cross-section soft soil tunnel; convergence; neural network; prediction method

0 引言

在隧道施工中，隧道收敛位移量测是判断围岩状态的最主要的测量项目，收敛位移可以为判断隧道空间的稳定性提供可靠的信息，用于指导现场施工^[1]。在隧道施工过程中，隧道内部的变形是一个复杂的非线性动态过程，利用传统的方法和技术很难揭示其内在的规律^[2]。近十几年发展起来的神经元网络理论是一门迅速兴起的非线性科学，它试图模拟人脑的一些基本特性，在处理信息十分复杂、背景知识不清楚、推理规则不明确的问题时，对数据进行分析处理^[3-5]。以前绝大部分对隧道围岩收敛的研究仅仅是从时间历程一个角度出发，利用BP神经网络建立隧道在不同地质条件下的收敛时间历程曲线，这种做法仅仅是将隧道径向围岩简化为统一的等级^[1-10]，而实际中的工程并非这样，所以以前的分析方法预测结果并不是很准确。本文首次利用BP神经网络对软土隧道工程的

隧道收敛监测从时间、里程2个角度预测分析，并与其他多种收敛预测方法进行了对比分析，避免了以前单因素分析的不合理等缺点，以期对收敛监测预测有更加科学严谨的分析。

1 工程概况

保健路路桥工程位于哈尔滨市南岗区和香坊区，隧道采用暗挖法穿越省森林植物园，并相继下穿哈平路、马家沟及三合路，在旭升街以西接地。隧道的范围西起K0+460，东至K2+120，全长1660 m。暗挖隧道为双连拱软土隧道，按城市主干路标准设计，设计车速为60 km/h，隧道采用双向双车道，单孔宽度8.75 m，界限高度4.5 m。哈尔滨地基底为古老的松辽地块，市区第四系松散堆积物分布普遍，厚度40~80 m，由更新统及全新统地层组成。建设场地地貌形态为哈尔滨岗阜状平原地带（马家沟两侧为马家沟漫滩），其成因为第四纪冲积、洪积作用下的黏性土和砂类土。建设

收稿日期：2011-11-14；修回日期：2012-02-27

作者简介：郝飞（1986—），男，河北张家口人，东北林业大学在读硕士，从事桥梁与隧道方面的研究工作。

场地地下水为第四纪空隙潜水,勘察期间场地地下水初见水位埋深26.5~30.5m,稳定水位埋深25.0~29.5m。本区地下水变化规律如下:3~5月为枯水期,7~9月为丰水期。隧道横断面示意图如图1所示,隧道测点布置如图2所示。



图1 隧道横断面示意图

Fig. 1 Cross-section of tunnel

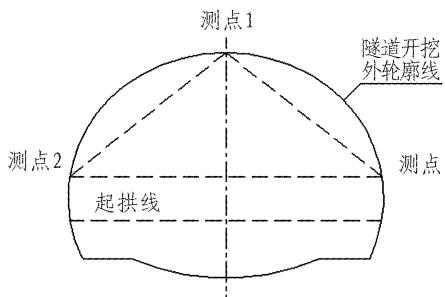


图2 隧道测点布置图

Fig. 2 Layout of monitoring points

2 BP 神经网络预测方法

BP网络(Backpropagation Neural Network),是建立在误差反向传播和梯度下降法的基础上的前馈神经网络^[6]。

2.1 BP 网络的基本结构

BP神经网络是相对成熟且应用广泛的一种神经网络模型。典型的BP网络有3层,即输入层、隐含层和输出层,各层之间实现完全连接,基本结构如图3所示^[7]。当学习样本提供给网络后,神经元将从输入层经过隐含层向输出层进行传播,在输出层的神经元得到响应后,将以目标输出与实际输出之间误差减小的方向,从输出层反向传播回到输入层,这一过程将逐渐修正各连接权值,这就是所谓的误差反向传播。随着误差反向传播的不断进行,输出层的正确率也得到不断的上升。

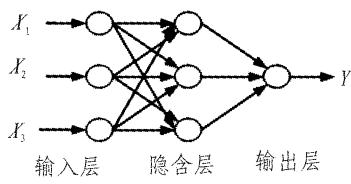


图3 BP 网络结构示意图

Fig. 3 Structure of BP network

BP神经网络是信息由输入端进入网络,然后从输入层传播到隐藏层的每个神经元中,经过激活函数后,再把隐藏层每个神经元节点的输出信息传播到输出节

点,最后得到输出结果。不同层的不同神经元节点之间通过权值连接。信息在同一层内的不同节点之间不传播。

2.2 BP 神经网络的计算过程

以3层BP神经网络为例,介绍BP网络的计算过程。

1) 网络初始化。给每个连接权值 w_{ij} 、 v_{jt} 、阈值 θ_j 和 γ_t 赋予区间(-1,1)内的随机值。

2) 随机选一组输入和目标样本 $P_k = (x_1^k, x_2^k, \dots, x_n^k)$ 、 $T_k = (s_1^k, s_2^k, \dots, s_n^k)$ 提供网络。

3) 用输入样本 $P_k = (x_1^k, x_2^k, \dots, x_n^k)$ 、连接权 w_{ij} 和阈值 θ_j 计算中间层各单元的输入 s_j ,然后用通过传递函数计算中间层各单元的输出 a_j 。

$$s_j = \sum_{i=1}^p w_{ij} x_i - \theta_j \quad (j=1, 2, \dots, p), \quad (1)$$

$$a_j = f(s_j) \quad (j=1, 2, \dots, p). \quad (2)$$

4) 利用中间层的输出 a_j 、连接权 w_{ij} 和阈值 γ_t 计算输出层各单元的输出 L_t ,然后通过传递函数计算输出层各单元的响应 B_t 。

$$L_t = \sum_{j=1}^p v_{jt} a_j - \gamma_t \quad (t=1, 2, \dots, q), \quad (3)$$

$$B_t = f(L_t) \quad (t=1, 2, \dots, q). \quad (4)$$

5) 利用网络目标向量、网络的实际输出,计算输出层的各单元一般化误差

$$d_t^k = (\gamma_k^t - B_t) \cdot B_t (1 - B_t) \quad (t=1, 2, \dots, q). \quad (5)$$

6) 利用连接权 v_{jt} 、输出层的一般化误差 d_t 和中间层的输出 a_j ,计算中间层各单元的一般化误差

$$e_j^k = [\sum_{t=1}^q d_t \cdot v_{jt}] a_j (1 - a_j). \quad (6)$$

7) 利用输出层各单元的一般化误差 d_t^k 于中间层各单元的输出 a_j 来修正连接权值 v_{jt} 和阈值 γ_t 。

$$v_{jt}(N+1) = v_{jt}(N) + \alpha \cdot d_t^k \cdot a_j, \quad (7)$$

$$\gamma_t(N+1) = \gamma_t(N) + \alpha \cdot d_t^k. \quad (8)$$

式中: $t=1, 2, \dots, q$; $j=1, 2, \dots, p$; $0 < \alpha < 1$ 。

8) 利用中间层各单元的一般化误差 e_j^k 、输入层各单元的输入 $P_k = (x_1, x_2, \dots, x_n)$ 来修正连接权 w_{ij} 和阈值 θ_j 。

$$w_{ij}(N+1) = w_{ij}(N) + \beta e_j^k x_i, \quad (9)$$

$$\theta_j(N+1) = \theta_j(N) + \beta e_j^k. \quad (10)$$

式中: $i=1, 2, \dots, n$; $j=1, 2, \dots, p$; $0 < \beta < 1$ 。

9) 随机选取下一个学习样本向量提供给网络,返回到步骤3),直到 m 个训练样本训练完毕。

10) 重新从 m 个学习样本中随机选取一组样本和目标样本,返回步骤3),直到网络全局误差小于预先设定的一个极小值,即网络收敛,学习结束^[8-9]。如果学习次数大于预定设计的值,网络就无法收敛。

通过对连接权和阈值的反复修正,网络的输出与

目标输出的误差达到预期值,从而得到满意的连接权和阈值^[10]。学习后即可得到稳定的网络结构连接权和阈值。

网络经学习训练后,将待预测样本的输入向量代入网络,利用已获得的稳定网络结构、连接权和阈值对该样本进行预测^[11]。

2.3 隧道变形的BP网络模型

由于该隧道工程区域土质较差,在实际的监控量测中设有多组断面,现根据建模需要取12#主洞的收敛数据进行模拟。本文在总结前人研究成果的基础上,结合实际工程的工程概况,从不同的角度出发,利用不同的建模机制建立了2种不同的预测方案。

1)12#主洞已经测量120 d,从收敛变形稳定的断面曲线中选取2个具有代表性的曲线(K1+440和K1+490)进行试验,验证预测效果。

首先以上述2个断面测试数据的前80 d数据作为学习样本以输入向量的形式输入模型进行训练,然后利用训练好的模型输出后40 d的预测数据,同实际测得数据进行对比,验证BP网络的预测效果。为保证输入数据的绝对值不影响网络的学习性能,对输入数据采用式(11)进行归一化处理,输入数据见表1和表2。

$$X = (X - X_{\min}) / (X_{\max} - X_{\min}) \quad (11)$$

式中X为归一化的值。

表1 12#主洞K1+440输入数据

Table 1 Input data at K1+440 of No. 12 main tunnel mm

时间/d	收敛值	时间/d	收敛值
1	2.23	27	7.65
2	1.79	28	8.34
3	2.28	29	8.92
4	0.58	30	9.86
5	1.21	32	11.10
6	-0.16	34	10.39
7	2.51	36	10.01
8	0.85	38	10.02
9	1.90	40	10.94
10	2.20	42	12.53
11	2.40	44	14.24
12	2.77	46	15.78
13	2.78	48	16.18
14	1.95	50	17.41
15	2.82	52	19.39
16	2.67	54	20.75
17	4.78	56	21.22
18	5.29	58	21.39
19	5.64	60	20.57
20	5.95	63	21.85
21	6.47	66	21.06
22	7.09	69	21.71
23	6.74	72	21.51
24	6.49	78	21.35
25	7.15	80	21.70
26	7.40		

表2 12#主洞K1+490输入数据

Table 2 Input data at K1+490 of No. 12 main tunnel mm

时间/d	收敛值	时间/d	收敛值
1	-1.03	27	3.91
2	0.88	28	4.60
3	-0.78	29	4.91
4	-0.31	30	5.89
5	-1.32	32	6.08
6	-1.81	34	5.77
7	0.45	36	5.86
8	-0.49	38	6.38
9	0.81	40	6.08
10	-0.56	42	6.24
11	-1.50	44	6.55
12	-2.51	46	7.30
13	-2.11	48	8.10
14	-1.79	50	9.91
15	-1.37	52	9.03
16	-1.61	54	8.81
17	-0.28	56	9.39
18	-0.57	58	8.88
19	-2.01	60	9.16
20	-2.12	63	10.73
21	-2.21	66	10.61
22	-0.34	69	13.25
23	0.34	72	14.23
24	1.22	78	14.49
25	1.87	80	15.81
26	3.23		

根据Occam,srazor原则,在选择网络层数时应使满足要求的网络尽量简单。1989年Robet Heat Nielson也证明了具有一个隐层的3层BP网络可以很有效地逼近任意连续函数。本文中采用一个隐层的3层BP网络,在BP网络训练时间步长选用1 d,于是要对输入数据再进行直线内插;在输出阶段,模型又选用了时间窗口滚动技术,可以更加准确地进行预测。预测结果与实际数据的对比见表3和表4。实测值与预测值的对比如图4和图5所示。

表3 12#主洞K1+440预测结果

Table 3 Prediction results at K1+440 of No. 12 main tunnel

时间/d	实际值/mm	统计回归预测		BP网络预测	
		预测值/mm	相对误差/%	预测值/mm	相对误差/%
84	22.52	24.30	7.89	23.42	4.00
88	22.28	20.39	8.49	21.77	2.30
92	22.62	24.10	6.54	23.19	2.50
96	22.45	23.61	5.15	21.75	3.10
100	22.74	21.61	4.98	23.33	2.60
104	22.93	21.73	5.23	23.39	2.00
108	23.00	24.48	6.45	23.16	0.69
112	23.73	25.45	7.25	23.44	1.23
116	22.94	21.68	5.48	23.44	2.18
120	23.21	24.52	5.64	23.29	0.34

表4 12#主洞K1+490预测结果

Table 4 Prediction results at K1+490 of No. 12 main tunnel

时间/d	实际值/mm	统计回归		BP网络	
		预测值/mm	相对误差/%	预测值/mm	相对误差/%
84	15.58	16.61	6.59	16.08	3.24
88	16.33	15.22	6.78	15.98	2.12
92	16.69	17.56	5.24	16.88	1.15
96	16.74	17.52	4.64	16.56	1.05
100	16.78	15.83	5.68	17.17	2.30
104	17.02	15.66	7.98	17.30	1.64
108	17.30	18.76	8.45	17.34	0.24
112	17.23	18.86	9.45	17.00	1.34
116	17.53	16.52	5.79	17.83	1.69
120	17.93	19.18	6.98	18.04	0.64

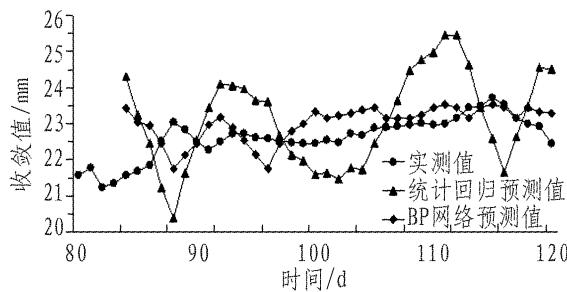


图4 12#主洞K1+440 实测值与预测值对比图

Fig. 4 Comparison and contrast between convergence values measured at K1+440 of No. 12 main tunnel and prediction results

表5 训练和预测的实际工程数据

Table 5 Training and prediction of engineering data

里程	软土强度/kPa	软土厚度/m	含水量/%	隧道埋深/m	施工工期/d	距下导洞距离/m	钢支撑距离/m	实测收敛值/mm
K1+400	28.4	6.4	47	22.5	120	22	0.34	14.22
K1+410	16.1	6.8	46	23.5	120	21	0.4	25.34
K1+420	14.3	7.2	47	22.4	118	23	0.28	29.24
K1+430	11.1	6.5	46	24.6	90	24	0.34	24.45
K1+440	30.8	7.4	46	23.5	120	22	0.3	23.21
K1+450	24.1	6.1	45	24.1	106	23	0.29	28.19
K1+460	27.3	6.9	49	22.6	114	23	0.24	17.55
K1+470	30.9	8.5	48	23.5	114	25	0.25	20.46
K1+480	28.4	9.4	52	22.6	126	26	0.26	26.44
K1+490	28.4	5.1	50	23.4	120	24	0.3	17.93
K1+500	30.1	10.3	49	26.8	116	23	0.31	16.29
K1+510	20.4	6.9	47	26.4	118	21	0.25	22.56
K1+520	20.4	8.6	46	25.9	109	26	0.25	24.29
K1+530	23.2	9.7	45	24.6	108	29	0.31	14.22

其中K1+400~+490作为训练数据以输入向量的形式输入到BP网络中进行训练,为保证输入数据的绝对值不影响网络的学习性能,对输入数据利用式(11)进行归一化处理,训练结束后将会得到影响参数和收敛值的非线性函数,然后利用K1+500~+530

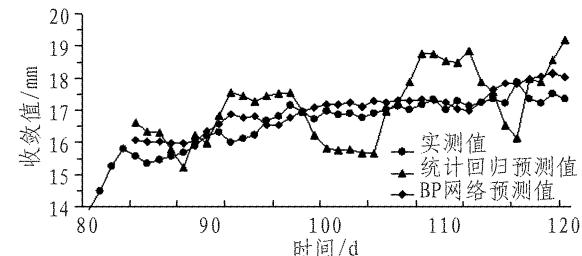


图5 12#主洞K1+490 实测值与预测值对比图

Fig. 5 Comparison and contrast between convergence values measured at K1+490 of No. 12 main tunnel and prediction results

从表3和表4、图4和图5分析可以看到:BP网络的收敛预测最大相对误差为4%,最小为0.24%,平均值也不超过2%;传统的统计回归预测最大相对误差9.45%,最小4.98%,平均6.5%。在预测隧道收敛变形方面,与传统的预测方法比较,BP网络的预测误差不超过5%,误差更小,与实际数据能够更好地吻合,在预测方面显示出它的优越性。

2)通过大量的实测数据,利用BP神经网络的训练学习,建立影响隧道收敛变形的参数与收敛变形值之间的一个非线性关系,再将要预测的断面的影响参数输入到BP网络中,得到要预测断面的预测值,通过该值与实际测量值的比较,评定BP网络的预测效果。

通过试验资料和观察资料,确定影响收敛变形的参数有软土强度、软土厚度、含水量、隧道埋深、施工工期、距下导洞距离和钢支撑距离等。用以训练和预测的实际工程数据见表5。

作为预测数据输入到已经训练好的BP网络中,输出其预测值,可以与实际的测量值进行比较,评定BP网络的预测效果。预测结果与实际数据的对比见表6,实测值与预测值对比图如图6所示。

表6 K1+500~+530 预测结果

Table 6 Prediction results from K1+500 to K1+530

里程	实测收敛值/mm	预测值/mm	绝对误差/mm	相对误差/%
K1+500	16.29	16.66	0.37	2.3
K1+510	22.56	22.90	0.34	1.5
K1+520	24.29	23.97	0.32	1.3
K1+530	20.52	20.70	0.18	0.9

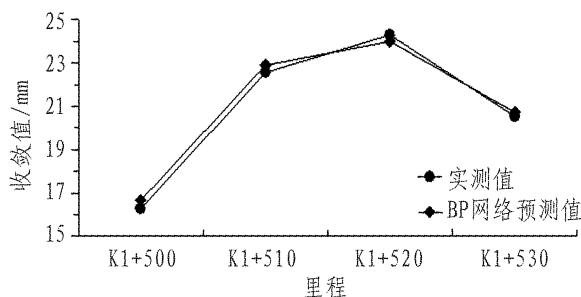


图6 主洞实测值与预测值对比图

Fig. 6 Comparison and contrast between measured data and prediction data of main tunnel

从表6可以看到: BP网络的预测值最大相对误差为2.3%,最小为0.9%,平均值为1.5%,在隧道围岩收敛预测方面有着很好的预测效果,基本上与实测数据相吻合。

3 结论与讨论

1) 通过对哈尔滨市保健路下穿工程的实例分析,很好地证明了从时间和里程2个方面综合考虑,利用BP神经网络对大断面隧道的收敛预测的准确性和快速性。工程实例中BP神经网络应用的成功为以后BP在实际工程中的广泛采用提供了参考。

2) BP网络很大程度属于“暗箱”操作,无法解释其结果产生的原因,而且其计算结果很大程度上依赖于训练样本的采集,对训练样本的要求很高。

3) BP网络在隧道围岩收敛中的作用,区别于以往隧道研究人员从单一时间因素考虑。首次从时间和里程2个角度对大断面隧道的收敛进行了预测分析,从理论上对隧道大断面的收敛分析进行了创新和补充,对隧道收敛分析理论有积极的作用;在实际工程的收敛预测方面考虑得更加充分详细,预测的结果更加准确,对实际工程的指导意义更大。

4) BP神经网络在对软土隧道收敛预测中,只需要利用实测数据,对高度复杂的非线性软土的结构直接建模,不需要像传统方法一样假设一些条件,避免了传统方法的弊病,计算精度高,泛化性能强,操作简单。

5) BP神经网络在隧道收敛方面下一步研究的重点是对BP神经网路参数的选定研究和BP神经网络计算方法的理论化研究。

参考文献(References):

- [1] 丁祥,林宝龙,朱永全. 堡镇隧道围岩变形的神经网络预测[J]. 石家庄铁道学院学报, 2007, 20(1): 39–43. (DING Xiang, LIN Baolong, ZHU Yongquan. Neural network prediction of Baozhen tunnel surrounding rock deformation [J]. Journal of Shijiazhuang Railway Institute, 2007, 20(1): 39–43. (in Chinese))
- [2] 涂敏,张梦喜. 基于神经网络的双连拱隧道拱顶下沉和周边位移的滚动预测[J]. 上海大学学报, 2005, 11(2): 186–191. (TU Min, ZHANG Mengxi. Neural roll-prediction of vault sink and horizontal displacement of bi-arch tunnel based on neural network [J]. Journal of Shanghai University, 2005, 11(2): 186–191. (in Chinese))
- [3] 国威. 基于神经网络理论的公路隧道围岩变形预测与稳定性分析[D]. 重庆:重庆大学安全技术及工程专业, 2009. (GUO Wei. Prediction of rock deformation and analysis of rock stability of tunnel based on the neural network [D]. Chongqing: Chongqing University Safety Technology and Engineering, 2009. (in Chinese))
- [4] 徐林生. 阳宗隧道围岩变形的神经网络技术预测[J]. 重庆交通大学学报, 2006, 25(3): 32–35. (XU Linsheng. Neural network prediction of Yangzong tunnel surrounding rock deformation [J]. Journal of Chongqing Jiaotong University, 2006, 25(3): 32–35. (in Chinese))
- [5] 王树栋,刘开云. 大长隧道软弱围岩施工大变形智能预测方法[J]. 中国铁道科学, 2008, 29(2): 82–89. (WANG Shudong, LIU Kaiyun. Intelligent prediction method of weak rock deformation construction in large tunnel [J]. China Railway Science, 2008, 29(2): 82–89. (in Chinese))
- [6] 李元松,李新平,张成良. 基于BP神经网络的隧道围岩位移预测方法[J]. 岩石力学与工程学报, 2006, 25(S1): 2969–2972. (LI Yuansong, LI Xinping, ZHANG Chengliang. Displacement prediction method of surrounding rock in tunnel based on BP neural network [J]. Chinese Journal of Rock Mechanics and Engineering, 2006, 25(S1): 2969–2972. (in Chinese))
- [7] 肖智旺,钟登华. 基于RBF神经网络算法的连拱隧道围岩变形预测方法研究[J]. 中国工程科学, 2008, 10(7): 77–81. (XIAO Zhiwang, ZHONG Denghua. Research on multi-arch tunnel surrounding rock deformation prediction method based on the RBF neural network algorithm [J]. China Engineering Science, 2008, 10(7): 77–81. (in Chinese))
- [8] 金豫杰. 基于BP神经网络的公路隧道交通量预测[J]. 广西工学院学报, 2005, 16(S3): 28–31. (JIN Yujie. Traffic volume forecast of highway tunnel based on BP neural network [J]. Journal of Guangxi University of Technology, 2005, 16(S3): 28–31. (in Chinese))

(下转第187页)

- [2] 杨海,林宣财,吴善根,等.长大陡坡路段改造工程总体方案研究[J].公路,2008(7):35-37.
- [3] 马智品.长大陡坡有轨斜井辅助正洞施工组织[J].公路隧道,2009(4):38-42.
- [4] 王占龙,李庚许,陈梅初.长大陡坡斜井快速施工平导的设备配套技术[J].铁道标准设计,2005(6):95-98.
- [5] 张梦华.对旅客列车在长大下坡道上平稳操纵方法的探讨[J].机车电传,2002(3):59-61.
- [6] 姜杰.特长公路隧道大坡度斜井提升施工技术[J].公路交通科技:应用技术版,2010(6):209-211.

(上接第179页)

- [9] 李怀国.BP神经网络与模糊控制在隧道施工中的预测与应用[J].建筑工程,2008,5(20):77-81. (LI Huaiguo. Prediction and application of BP neural network and fuzzy control in the construction of tunnel[J]. Architectural Engineering, 2008,5(20): 77-81. (in Chinese))
- [10] 林敏.基于人工神经网络的隧道监测数据预测模型仿真研究[D].西安:长安大学机械设计及理论专业,2010. (LIN Min. The study of model prediction for highway simulation of data monitoring tunnel based on neural network [D]. Xi'an: Machinery Design and Theory, Chang'an University, 2010. (in Chinese))
- [11] 杨茜.BP神经网络预测方法的改进及其在隧道长期沉降预测中的应用[J].北京工业大学学报,2011,37(1):92-97. (YANG Qian. Improvement and application of BP neural network prediction method in long-term tunnel settlement prediction[J]. Journal of Beijing University of Technology, 2011,37(1): 92-97. (in Chinese))

(上接第183页)

- [7] 陈洪,李国富.膨润土防水材料的防水机理及基本性能指标的测定[J].徐州工程学院学报:自然科学版,2009,24(2):38-39. (CHEN Hong, LI Guofu. Waterproof mechanism of bentonite-based waterproof material and measurement method of the basic performance index[J]. Journal of Xuzhou Institute of Technology: Natural Sciences Edition, 2009,24(2):38-39. (in Chinese))
- [8] 周正兵,王钊,王俊奇.GCL——一种新型复合土工材料的特性及应用综述[J].长江科学院院报,2002,19(1):35-38. (ZHOU Zhengbing, WANG Zhao, WANG Junqi. An overview about properties and application of a new geocomposite——GCL[J]. Journal of Yangtze River Scientific Research Institute, 2002,19(1):35-38. (in Chinese))
- [9] 李宪,束一鸣,武良今,等.新型防渗材料GCL的一些特性试验[C]//全国第六届土工合成材料学术会议论文集.北京:中国土工合成材料工程协会,2004:416-422. (LI Xian, SHU Yiming, WU Liangjin, et al. Some performance tests of the new waterproof material GCL[C]//National Sixth Geotextile Academic Conference Proceeding. Beijing: CTAG, 2004:416-422. (in Chinese))
- [10] 陈彤,黄琦.新型防水产品——膨润土防水毯[J].江西建材,2005(3):23-25. (CHEN Tong, HUANG Qi. A new waterproof material——GCL[J]. Jiangxi Building Materials, 2005(3):23-25. (in Chinese))