

土石坝渗流的神经网络监控模型

何勇军¹,薛宝林²

(1.河海大学水利水电工程学院,江苏 南京 210098;2.松辽委察尔森水库管理局,内蒙古 乌兰浩特 137400)

摘要 通过对土石坝渗流的成因分析,应用人工神经网络原理,并结合某土石坝的实测资料建立了渗流监控模型,给出了模型的输入输出因子和模型结构.该模型具有再学习能力,在应用过程中,可以用新的观测资料对模型不断地进行学习训练,以提高模型的精度.
关键词 人工神经网络;土石坝;渗流;监控模型
中图分类号 TV641 **文献标识码** A **文章编号** 1000-1980(2001)02-0079-04

坝体和坝基渗流监测是土石坝运行监控中不可缺少的重要组成部分^[1].众所周知,任何土石坝的坝身、坝基在水头作用下都有不同程度的渗透.在坝体和坝基的适当部位设置一定数量的测压管,并进行观测,可以了解坝体的浸润线和各点渗压力的大小,以综合反映土石坝的运行性态.这对坝体的稳定分析和渗流分析都具有很大的实用意义.

土石坝渗流分析一般采用统计学模型、确定性模型(有限元分析)、混合模型以及由灰色系统理论建立的预测模型等^[2].由于人工神经网络具有独特的非线性映射能力和很强的环境适应能力,因此,人工神经网络已在语言识别、模式识别、图像处理和自动控制等领域获得了比较成功的应用,并已成为解决一些工程实际问题的有效工具之一.

1 模型因子选择^[2~4]

测压管水位是由上下游水位差、降雨等因素引起的.而测压管水位高低与上下游水位变化幅度、降雨强度大小和筑坝材料的渗透性能等因素有关.在渗透过程中,渗流水克服土粒之间的阻力,从上游渗到测压管位置需要一定的时间,所以,测压管水位还与前期库水位的变化有关.此外,土体固结使土体颗粒结构排列形式发生的改变以及上游坝前淤积对渗流状态的影响等都是测压管水位的可能影响因素.测压管中的前期水位对后期水位的变化也起影响作用.由于埋设在土石坝内的浸润线测压管水位的变化与库水位变化不同步,管水位变化达到峰(谷)值时刻往往比库水位达到峰(谷)值的时刻来得晚,存在着时间差,这种时间差称之为“滞后时间”,在因子选择时应考虑其影响.

综合上述分析,采用库上下游水位差(或坝前水位)分量 H 、时效分量 T 、降雨分量 P 及上时刻测压管中水位 Z 作为模型因子集.用数学式子表达为

$$V_j = f_H^j(H_0, H_1, \dots, H_{19}) + f_P^j(P_0, P_1, \dots, P_{19}) + f_T^j(T, \ln T) + f_Z^j(Z_1, Z_2, \dots, Z_8)$$
$$j = 1, 2, \dots, 8$$

式中: H_i ——计算时刻前第 i 天的上下游水位差或坝前水位值, $i = 0, 1, \dots, 19$; P_i ——计算时刻前第 i 天的降雨量, $i = 0, 1, \dots, 19$; T ——时效,从观测日起算,每天取 0.001; Z_i ——上时刻测压管中水位值, $i = 1, 2, \dots, 8$; V_j ——计算的测压管中水位值, $j = 1, 2, \dots, 8$.

一般说来,上述函数关系是非线性的,且很复杂,目前尚无精确的显式函数来表达.根据神经网络理论可

收稿日期 2000-01-19
作者简介:何勇军(1963—),男,辽宁营口人,高级工程师,博士研究生.主要从事智能遥控技术在大坝安全监控中的应用研究.

知,误差逆传播神经网络具有极强的非线性映射能力,因此,用误差逆传播神经网络来拟合上述函数关系.

2 神经网络模型^[5~7]

2.1 BP神经网络原理

BP神经网络是误差逆传播网络的简称,典型的BP网络是3层前馈阶层网络,即:输入层、隐含层(也称中间层)和输出层.各层之间实行全连接.BP网络的学习采用广义 δ 规则,由4个过程组成:输入层经中间层向输出层的“模式顺传播”过程;输出层经中间层向输入层逐层修正连接权的“误差逆传播”过程;“模式顺传播”与“误差逆传播”的反复交替进行的网络“记忆训练”过程;网络趋向收敛即网络的全局误差趋向极小值的“学习收敛”过程.归结起来为:“模式顺传播”→“误差逆传播”→“记忆训练”→“学习收敛”过程.

2.2 网络模型

网络结构为“62-30-8”,学习规则为广义 δ 规则,各神经元激活函数为S函数(Sigmoid函数).其结构如图1所示.

考虑到S函数的输出在[0,1]之间,其中,在0,1处,输入很大,这样使网络校正进程十分缓慢.因此,在给网络赋值之前,将学习模式对的输入值与输出值进行归一化处理,对其数值进行压缩.

归一化处理:

$$H'_k=(H_k-H_{\min})(H_{\max}-H_{\min})$$

$$P'_k=(P_k-P_{\min})/P_{\max}$$

$$Z'_k=(Z_k-Z_{\min})(Z_{\max}-Z_{\min})$$

$$V'_k=(V_k-Z_{\min})(Z_{\max}-Z_{\min})$$

式中: k ——学习模式对数; $k=0,1,\dots,m$; $H_{\max}$ ——设计洪水位; $H_{\min}$ ——死水位; $P_{\max}$ ——历史最大日降雨; $Z_{\max}$ ——管中历史最高水位; $Z_{\min}$ ——管中历史最低水位.

S函数为 $f(x)=1/(1+e^{-x})$.

2.3 模式顺传播

中间层各神经元的输入为

$$S_j=\sum_{i=1}^n\omega_{ij}a_i-\theta_j\quad j=1,2,\dots,p$$

式中: ω_{ij} ——输入层至中间层的连接权; n ——输入层神经元数; θ_j ——中间层神经元的阈值; p ——中间层神经元数.

中间层各神经元输出

$$b_j=f(S_j)=1/(1+e^{-S_j})\quad j=1,2,\dots,p$$

输出层各神经元的输入、输出

$$L_t=\sum_{j=1}^p\nu_{jt}b_j-\gamma_t\quad C_t=f(L_t)=1/(1+e^{-L_t})\quad t=1,2,\dots,q$$

式中: ν_{jt} ——中间层至输出层的连接权; γ_t ——输出层神经元的阈值; L_t ——输出层神经元输入; C_t ——输出层神经元输出; q ——输出层神经元数.

2.4 误差逆传播

误差逆传播的第一步是进行误差计算.这里输出层的校正误差为

$$d_t=(V'_t-C_t)f'(L_t)\quad t=1,2,\dots,q$$

为完成误差向中间层的传递,需要按下式计算中间层各神经元的校正误差:




图1 神经网络监控模型结构

Fig.1 Structure of Neural Network Monitoring Model

$$e_j = [\sum_{i=1}^q v_{ji}d_i]f'(S_j) \qquad j = 1 \ 2 \ \dots \ p$$

得到校正误差 d_i 与 e_j 之后 ,沿逆方向调整输出层至中间层、中间层至输入层之间的连接权 ,以及各神经元的输出阈值.其调整量为

$$\Delta v_{ji} = \alpha d_i b_j \qquad \Delta \gamma_i = \alpha d_i \qquad \Delta \omega_{ij} = \beta e_j a_i \qquad \Delta \theta_j = \beta e_j$$

$$i = 1 \ 2 \ \dots \ n \qquad j = 1 \ 2 \ \dots \ p \qquad t = 1 \ 2 \ \dots \ q$$

式中 : α , β ——学习系数 $0 < \alpha < 1$ $0 < \beta < 1$; Δv_{ji} ——输出层连接权校正量 ; $\Delta \gamma_i$ ——输出层神经元的阈值校正量 ; $\Delta \omega_{ij}$ ——中间层连接权校正量 ; $\Delta \theta_j$ ——中间层神经元的阈值校正量.

为了加快网络校正速度 ,减小振荡 ,实际校正量采用惯性校正法 ,即

$$\Delta \alpha(N) = \Delta \omega_{ij} + \eta \Delta \alpha(N - 1)$$

$$\Delta \gamma(N) = \Delta v_{ji} + \eta \Delta \gamma(N - 1)$$

式中 : $\Delta \alpha(N - 1)$ $\Delta \gamma(N - 1)$ ——前次校正量 ; $\Delta \alpha(N)$ $\Delta \gamma(N)$ ——本次应得校正量 ; η ——惯性系数 $0 < \eta < 1$.

2.5 模型的实现

采用 Visual Basic 6.0 编程语言 ,应用上述理论编制了模型软件.为了能够在实际中得到应用 ,并与大坝安全监测自动化系统联机运行 ,做到实时监控和预报 ,采用 SQL Server 7.0 建立了历史和实时数据库.软件可定时从数据库中读取新的观测数据 ,进行监控和预报计算 ,并可用新的观测数据对模型进行进一步学习训练.

3 算 例

某土坝坝顶长 1 712 m ,坝高 39.7 m ,坝体设置了 11 个断面共 67 支浸润线测压管.现选择其主要坝段 0 + 274和 1 + 474 两断面的实测资料及同期库水位、降雨资料建立渗流监控模型.

用 1996 ~ 1999 年的实测资料 ,共选择了 190 组学习模式对 ,对建立的监控模型进行学习训练.采用变学习系数法 ,初选学习系数 $\alpha = \beta = 0.70$,每学习 200 次后将 α , β 减小 0.10 , α , β 减小到 0.40 时将不再减小. η 取为 0.50.

实际输出值为 $\widetilde{V}_k = V_k' \times (Z_{\max} - Z_{\min}) + Z_{\min}$.

全局误差计算式为

$$E = \sum_{t=1}^m \sum_{i=1}^8 | \widetilde{V}_{kt} - V_{kt} |$$

式中 : $\widetilde{V}_{kt}$ ——模型计算值 ; V_{kt} ——实测值.

通过实际计算 ,当网络学习 823 次后 ,全局误差为 0.048 6 m ,小于预先给定值 0.15 m ,说明网络收敛 ,学习过程结束.

用该模型对 1999 年 5 月的观测数据进行计算 ,所得结果与实际测量结果比较如表 1 所示.

表 1 计算成果比较

Table 1 Comparison of calculated results

测压管号	1998-05-13(1 断面)			1998-05-13(2 断面)			1998-07-22(1 断面)			1998-07-22(2 断面)		
	实测值 /m	计算值 /m	误 差 /m	实测值 /m	计算值 /m	误 差 /m	实测值 /m	计算值 /m	误 差 /m	实测值 /m	计算值 /m	误 差 /m
1	345.42	345.32	-0.08	347.41	347.49	0.08	346.92	346.85	-0.07	347.95	347.99	0.04
2	355.21	355.15	-0.06	353.58	353.66	0.08	353.33	353.24	-0.09	353.42	353.34	-0.08
3	350.23	350.30	0.07	351.77	351.87	0.10	351.24	351.29	0.05	351.79	351.70	-0.09
4	341.98	342.04	0.06	346.85	346.80	-0.05	342.39	342.47	0.08	346.84	346.90	0.06
5	333.72	333.65	-0.07	333.20	333.27	0.07	333.71	333.65	-0.06	333.35	333.30	-0.05
6	332.43	332.39	-0.04	333.15	333.21	0.06	332.43	332.36	-0.07	333.47	333.57	0.10
7	342.04	342.09	0.05	336.60	336.55	-0.05	344.37	344.46	0.09	336.60	336.55	-0.05
8	331.98	332.06	0.08	332.83	332.76	-0.07	332.41	332.49	0.08	332.90	332.99	0.09

4 结 语

a. 以上列出了部分计算值,从模型的实际计算情况看,当前期无降水或降水较小时,计算精度较高,基本在模型拟合误差范围内,但当前期降水较大时,某些测压管的计算误差较大.若在资料处理时将降水影响从观测系列中扣除,应能得到高精度的模型.但总体来说,结果是令人满意的.此模型可作为该坝浸润线测压管的观测监控模型和预报方程应用到实际工作中.

b. 现有资料的计算结果说明,模型的建立是合理的,但模型的内插计算误差明显好于外延预报的计算误差.这个问题需作进一步的研究,可从两个方面进行:一是模型的输入因子,在将数据输入给模型前可对其进行预处理以消除降雨的影响,合理选择时效因子等;二是对模型的结构进行优化,比如采用动态隐层和动态 BP 算法等.

c. 在模型的建立过程中,中间层数的选取直接影响模型的计算精度和计算时间,中间层数越多,计算时间也越长,但中间层太少,模型精度达不到要求,甚至在模型的学习过程中无法收敛.此模型中间层选取 30 个,也带有一定的人为因素.

d. 由于采用人工神经网络建立的渗流监控模型具有再学习能力,所以在使用此模型的过程中,可以用新的观测资料对模型不断地进行学习训练,以提高模型的精度.

参考文献:

- [1] 张启岳.土石坝观测技术[M].北京:水利电力出版社,1993.87~117.
- [2] 吴中如,沈长松,阮焕祥.水工建筑物安全监控理论及其应用[M].南京:河海大学出版社,1990.121~144.
- [3] 吴中如,顾冲时.大坝安全综合评价专家系统[M].北京:北京科学技术出版社,1997.53~60.
- [4] 毛昶熙.渗流计算分析与控制[M].北京:水利电力出版社,1990.92~116.
- [5] 包约翰.自适应模式识别与神经网络[M].北京:科学技术出版社,1992.285~319.
- [6] 焦李成.神经网络系统理论[M].西安:西安电子科技大学出版社,1992.243~286.
- [7] Russll C Eberhart, Yuhui Shi. Evolving artificial neural networks[A]. ICNN&B '98[C]. 1998. PL-5.

Seepage Monitoring Model for Earth Rockfill Dams with Artificial Neural Network

HE Yong-jun¹, XUE Bao-lin²

(1. College of Water Conservancy and Hydropower Engineering, Hohai Univ., Nanjing 210098, China;
2. Chaersen Reservoir Management Bureau, Ulanhaote 137400, China)

Abstract :By use of the artificial neural network, a seepage monitoring model for earth rockfill dams is established in combination with the observed data of an earth rockfill dam and through the analysis of the cause of seepage. Its input factor, output factor and structure are presented. The calculation results show its effectiveness. The model can be trained sequentially with new observed data in further application, so the the accuracy of the model can be improved.

Key words :artificial neural networks; earth rockfill dam; seepage; monitoring model