

神经网络模型在面板坝堆石体施工期 沉降变形预测中的应用

李金凤^{1,2}, 杨启贵², 徐卫亚¹

(1. 河海大学岩土工程研究所, 江苏 南京 210098; 2. 长江水利委员会设计院, 湖北 武汉 430010)

摘要 在分析面板坝堆石体施工期坝体沉降影响因素的基础上, 将影响沉降的主要因素作为网络输入参数, 以测点沉降量作为网络的输出, 建立了神经网络模型. 以水布垭面板坝堆石体为例, 将模型预测值与实测结果进行了对比, 结果表明, 预测值与实测结果比较接近, 该神经网络能很好地反映面板坝堆石体施工期沉降变形与其影响因素之间的非线性映射关系, 预测结果可作为后期填筑反馈设计的依据, 同时可通过网络输入参数的调整检验某一因素对坝体沉降的影响程度.

关键词 面板坝堆石体 沉降 神经网络 预测

中图分类号 TV641.4

文献标识码 A

文章编号 1000-1980(2007)05-0563-04

在设计高面板坝堆石体之前, 尽量了解堆石体各时期应力变形特性的方法, 除常用的理论分析方法、数值计算方法和模型试验方法外, 根据大坝填筑现场的原型监测信息, 加强施工期和运行期的反馈分析, 是目前采用的另一主要方法. 该方法对准确预测大坝的工作性态、优化大坝的设计方案(如作为确定坝料的设计压实指标、坝体分区、面板及接缝止水结构、施工程序、安全监测仪器等的依据之一)、指导大坝的运行与管理、确保大坝的安全具有一定的现实意义.

本文利用原型观测资料探讨堆石体施工期沉降变形的规律并进行预测分析. 考虑到工程类比法或其他经验方法的预测模型误差较大, 在分析面板坝堆石体施工期沉降影响因素的基础上, 采用神经网络预测模型进行堆石体施工期沉降预测分析.

1 面板坝堆石体施工期沉降影响因素分析

研究表明, 堆石体的沉降与坝型、坝高、大坝填筑料特性、压实质量、洒水量、坝址地形地质条件、水库蓄水位的变动等因素之间的对应关系是客观存在的, 而且十分复杂^[1], 建立一种能反映所有影响因素影响程度关系的模型是不可能的.

理论上, 堆石体的沉降是在坝体自重和水压力的作用下产生的向下的沉降变形. 在施工期, 面板坝堆石体沉降变形过程其实是堆石体的固结过程. 堆石体的固结, 是指堆石体中土质防渗体的渗透固结(也称主固结)和坝体填料随时间的压缩过程与土粒骨架的蠕变性能、矿物颗粒的重新排列及自身变形的固结(次固结). 堆石体内的孔隙之大足以使得孔隙内的水能自由排放. 在施工以及运行过程中, 渗水通过堆石体内的孔隙很快被排走, 堆石体内基本上不产生孔隙压力, 所以堆石体一般在施工期已渗透固结. 在运行期, 堆石体在水荷载作用下继续产生次固结过程. 综合而言, 堆石体在施工期的沉降包括外力作用下产生的全部主固结过程和部分与时间相关的次固结过程.

沉降机理研究表明, 施工期面板坝堆石体沉降主要影响因素是外力作用和时间效应. 若施工期不蓄水, 只需考虑填筑分量和时效分量, 但高面板坝堆石体面板通常分 2 期或 3 期浇筑. 下部面板浇筑后, 水库开始蓄水, 上部面板坝堆石体填筑同时进行, 这样, 下部测点填筑分量和水压分量都不是常量, 因此对高坝而言, 沉降变形中除了应同时考虑填筑分量和水压分量, 还应该考虑填筑分量与时效分量的耦合影响以及水压分量与时效分量的耦合影响. 统计比较分析各工程实例发现, 除了外力作用和时间效应这 2 个直接影响面板坝

堆石体沉降的因素外,还有其他因素的影响.如在面板坝堆石体施工期,压缩模量是面板坝堆石体施工质量的综合反映,在分析施工期面板坝堆石体沉降影响因素时,应考虑压缩模量的影响.

虽然有限元计算是分析面板坝堆石体沉降影响因素的主要方法和手段,但目前能够反映堆石体蠕变变形的堆石体本构模型的研究仍处于初期阶段,利用有限元反演正算进行变形预测还有一定困难.所以本文在对面板坝堆石体沉降影响因素进行客观分析的基础上,建立神经网络预测模型,将主要的影响因素作为网络输入,进行网络训练与检验,最后利用精度较高的模型来预测面板坝堆石体的后期变形.

2 堆石体施工期沉降的神经网络预测模型

沉降曲线是与很多因素相关的非线性函数.统计预测模型等将面板坝堆石体沉降变形与这些影响因素表示为简单的函数关系,因而带来较大的误差.采用有限元方法进行分析时,由于计算参数与实际参数存在差异,计算结果与实际观测值有时相去甚远.神经网络法具有模拟多变量而不需要对输入变量进行复杂的相关假定的能力.只利用观察到的数据,就可以从训练过程中通过学习来抽取和逼近隐含的输入/输出非线性关系^[2].研究发现,相对于各种统计预测模型,神经网络预测模型可获得更高的精度.

2.1 BP 人工神经网络建模原理

本文采用的 BP 人工神经网络,即误差逆传播神经网络.它是一种具有 2 层或 2 层以上的阶层型神经网络,上下层实行全连接,即下层的每一个单元与上层的每一个单元都实现权连接,而每层单元各神经元之间无连接.网络按有教师示教的方式进行学习,属于正向建模过程,其中神经网络与待辨识的系统并联,两者的输出误差用作网络的训练信号,实际系统作为教师,向神经网络提供算法所需的期望输出.正向建模结构如图 1 所示.图 1 中: u 为网络输入; y 为网络应有输出; y_N 为网络实际输出; e 为输出误差; d 为描述环境状态的信号; d' 为动态系统响应.




图 1 神经网络正向建模结构

Fig.1 Forward modeling structure of neural network

当一对学习模式提供给网络后,神经元的激活值从输入层经中间层向输出层传播.在输出层的各神经元获得网络的输入响应后,按减小希望输出与实际输出误差的方向,从输出层经中间层逐层修正各连接权,最后回到输入层.随着这种误差逆传播修正的不断进行,网络对输入模式响应的正确率也不断上升,直到在允许的误差范围内.整个过程可归结为:“模式顺传播”—“误差逆传播”—“记忆训练”—“学习收敛”的过程^[3].




图 2 BP 人工神经网络结构

Fig.2 Structure of BP artificial neural network

为实现误差逆传播,要求神经元的传播函数必须连续可导,从而可实现非线性识别问题.同时还要求该函数有一个剧烈的变化范围,最常用的是 Sigmoid 函数. Sigmoid 的导函数可用其自身来表示,对训练机制(或称学习规则)的设计^[4-6]有利.最常用的学习规则按梯度下降来调整,其他的都是在梯度下降的基础上加以修正,以提高学习效率,如共轭梯度法、加动量项法.在连接权的调整过程中,学习律的调整也很重要,通常在开始训练时取小

一些,然后可逐步调大,也可以自适应调整. BP 人工神经网络结构如图 2 所示.图 2 中: $A^k = (a_1^k, a_2^k, \dots, a_n^k)$ 为输入模式向量; $S^k = (s_1^k, s_2^k, \dots, s_p^k)$ 为中间层神经元输入向量; $B^k = (b_1^k, b_2^k, \dots, b_p^k)$ 为中间层输出向量; $L^k = (l_1^k, l_2^k, \dots, l_q^k)$ 为输出层神经元输入向量; $C^k = (c_1^k, c_2^k, \dots, c_q^k)$ 为输出层输出向量; $Y^k = (y_1^k, y_2^k, \dots, y_q^k)$ 为希望输出向量; $\{w_{ij}\}$ 为输入层至中间层连接权; $\{v_{jt}\}$ 为中间层至输出层连接权; $\{\theta_j\}$ 为中间层各神经元输出阈值; $\{\gamma_t\}$ 为输出层各神经元输出阈值; $i = 1, 2, \dots, n$; $j = 1, 2, \dots, p$; $t = 1, 2, \dots, q$; $k = 1, 2, \dots, m$.

通过信息的正向传播与误差的反向传播不断循环进行网络训练,训练好的网络即可以用来进行相关的预测分析.

2.2 堆石体施工期沉降的神经网络建模

面板坝堆石体未蓄水前的施工期沉降主要考虑填筑分量和时效分量.在取得足够的监测资料以后,以填筑高度和沉降时间为输入参数,相应的沉降量为输出参数,建立的 BP 人工神经网络模型经过训练和检验后即可应用.

BP 人工神经网络的建立过程如下 : (a) 数据规范化. 输入层数据应先规范化, 即对于输入层各个神经元的数 据, 先估计出各神经元数据可能变化的范围, 然后都变化到 $[0, 1]$ 或 $[-1, 1]$ 区间, 这是由 Sigmoid 函数在 $[-1, 1]$ 内变化敏感、容易识别决定的. 同理, 为了保持输出层和隐含层神经元的一致性, 由 Sigmoid 函数的值域 $(0, 1)$ 或 $(-1, 1)$ 决定了必须对输出层数据也进行规范化处理. (b) 按图 2 建立 BP 人工神经网络结构, 取影响坝体沉降的 2 个因素作为输入层 (即输入层个数为 2), 取坝体沉降量为输出层, 因而输出层为 1, 而隐含层 (或称特征抽取层, 即中间层) 神经元个数必须多取才能识别, 根据文献 [7-8] 以多于 2 倍输入层神经元个数为宜. 然后设定学习规则、输入层到隐含层及隐含层到输出层的传播函数、学习律. (c) 网络训练. 对连接权和阈值在 $[-1, 1]$ 内随机赋初值, 这样有利于训练. 设定好收敛容差后, 便可训练. 训练过程中要不断调整学习律, 以提高训练效率.

3 实例分析

3.1 网络的训练及检验样本

用 MATLAB 语言编制程序, 实现网络的建模与仿真. 本文通过使用 MATLAB 提供的函数 newff 创建前馈神经网络, 隐含层及输出层激活函数都采用较常用的 Sigmoid 函数, 使用 train 函数对网络进行训练, 然后用 sim 函数对网络进行仿真.

本文数据为水布垭面板坝堆石体施工期末蓄水前的监测成果, 监测点位于大坝 0 + 212 断面 235 m 高程中轴上, 其测点布置如图 3 所示. 网络训练样本和检验样本采用 2004 年 9 月 ~ 2005 年 5 月的观测数据. 所用数据中的沉降时间和沉降量都是 2004 年 8 月 31 日测值的相对值.

先通过程序以及表 1 数据对本文建立的网络进行训练, 再用表 2 的数据对网络进行检验. 将表 2 对网络的预测结果与实际结果进行对比, 并计算了其相对误差. 由计算结果可以看出, 网络预测结果与实测结果的最大相对误差为 6.31%, 最小相对误差仅为 1.70%, 可见训练后的网络能较真实地反映面板坝施工期坝体沉降与沉降影响因素之间的非线性映射关系.

表 1 网络训练样本

Table 1 Network training samples

取样序号	取样日期	输入数据		输出数据: 沉降量/ mm
		上覆填筑 高度/m	沉降 时间/d	
1	2004-09	53.7	24	45
2	2004-10	61.9	52	77
3	2004-11	66.7	88	151
4	2004-12	79.8	119	175
5	2005-01	82.2	150	247
6	2005-02	84.6	180	285
7	2005-03	92.0	211	326
8	2005-04	95.0	237	352
9	2005-05	95.0	264	367




图 3 0 + 212 断面 235 m 高程坝体沉降
监测仪器布置

Fig.3 Layout of settlement monitoring
instruments in cross-section 0 + 212 at altitude 235 m

表 2 网络检验样本

Table 2 Network checking samples

取样序号	取样日期	填筑 高度/m	沉降 时间/d	实测沉 降量/mm	预测沉 降量/mm	相对 误差/%
11	2005-01	82.2	150	247	238	3.64
12	2005-02	84.6	180	285	267	6.31
13	2005-03	92.0	211	326	315	3.37
14	2005-04	95.0	237	352	346	1.70
15	2005-05	95.0	264	367	352	4.09

3.2 运用网络进行预测及结果对比分析

在本文训练好并通过检验的网络中, 建立只考虑施工期末蓄水前影响坝体沉降的填筑分量和时效分量的两因素模型. 实际上, 影响沉降的因素是十分复杂的. 为了进行对比分析, 用本文建模方法建立另一模型, 输入参数中加入压缩模量, 网络结构按本文规则进行相应的调整, 采用同样测点和时间段的数据对网络进行训练和检验, 完成后的模型为三因素模型. 用两因素模型和三因素模型 2 种预测模型对坝体的后期填筑沉降量进行预测. 将预测结果与常规统计回归模型进行对比分析, 结果见表 3.

表 3 对比结果表明: BP 人工神经网络模型预测精度明显高于一般的统计模型; 三因素模型预测精度要高于两因素模型, 说明在施工期间施工质量对坝体沉降的影响很大, 但在数据足够长且可靠的前提下, 加入其他影响因素, 精度是否会提高还需进一步验证.

4 结 语

a. 在客观分析面板坝堆石体沉降机理的基础上,找出影响堆石体沉降变形的主要因素,建立 BP 人工神经网络预测模型,再利用沉降观测数据对模型进行训练和检验后就可对面板坝堆石体后期变形进行预测.工程应用表明,采用本文方法建立的 BP 人工神经网络预测模型具有很高的预测能力.

b. 影响面板坝堆石体沉降的因素是复杂多样的,为了简化问题,一般只考虑主要影响因素.在条件允许的前提下,是否考虑的影响因素越多,模型预测精度就越高,还需通过多因素 BP 神经网络预测模型来验证.通过在建立的 BP 神经网络预测模型输入层中加入某一影响因素,验证加入前后精度变化的过程可检验某一因素对面板坝堆石体沉降的影响程度.本文实例中,BP 人工神经网络考虑了施工质量的影响,这提高了模型的预测能力,说明施工期施工质量对面板坝堆石体沉降影响较大.

表 3 预测结果对比分析

Table 3 Comparative analysis of predicted results

取样 序号	取样 日期	实测沉 降量/mm	BP 神经网络预测模型				统计回归模型	
			两因素模型		三因素模型		计算沉降 量/mm	误差/ %
			计算沉降 量/mm	误差/ %	计算沉降 量/mm	误差/ %		
1	2005-06	371	357	3.77	363	2.16	350	5.66
2	2005-07	406	381	6.17	392	3.45	370	8.87
3	2005-08	455	430	5.49	441	3.08	411	9.67
4	2005-09	498	484	2.81	487	2.21	473	5.02
5	2005-10	628	609	3.03	614	2.23	596	5.10
6	2005-11	638	615	3.60	612	4.08	598	6.27

参考文献:

[1] 夏富洲,王长德.面板堆石坝沉降变形预测的神经网络方法[J].武汉大学学报 工学版,2005,38(6):24-28.
[2] 徐卫亚,蒋晗,谢守益,等.三峡永久船闸高边坡变形预测人工神经网络分析[J].岩土力学,1999,20(2):27-31.
[3] 闻新.MATLAB 神经网络仿真与应用[M].北京:科学出版社,2003:30-100.
[4] HOPFIELD J J,TANK D W. Simple“neural”optimization networks:an A/D converter,signal decision circuit and a linear programming circuit[J]. IEEE Trans Circuit Systems,1986,33:533-541.
[5] BERKE L,PATNAIK S N,MURTHY P L N. Optimum design of aerospace structural components using neural networks[J]. Computers and Structures,1993,48(6):1001-1010.
[6] ADELI H,PARK H S. Hybrid CPN-neural dynamics model for discrete optimization of steel structures[J]. Microcomputers in Civil Engineering,1996,11(5):355-366.
[7] HUNG S,ADELI H. A model of perception learning with a hidden layer for engineering design [J]. Neuro-Computing,1991,3(1):3-14.
[8] HUSH D,SALAS J. Improving the learning rate of back-propagation with the gradient reuse algorithm[C]//Proceedings of the IEEE Inter Conf on Neural Networks. San Fransisco:IEEE,1988:441-447.

Application of neural network model to prediction of settlement deformation of rockfill body of CFRD during construction period

LI Jin-feng^{1,2}, YANG Qi-gui², XU Wei-ya¹

(1. Geotechnical Research Institute of Hohai University, Nanjing 210098, China ;
2. Design Institute, Changjiang Water Resources Committee, Wuhan 430010, China)

Abstract Based on analysis of the influencing factors on the settlement of concrete face rockfill dams (CFRD) during the construction period, a BP neural network model for settlement prediction was developed. In the model, the main influencing factors on settlement were taken as the input parameters of the network, and the settlement at measurement points was taken as the output of the model. Case study on Shuibuya CFRD shows that the predicted result is much close to the measured data, and that the neural network can well reflect the nonlinear relationship between the settlement deformation of CFRD and its influencing factors. The predicted result can provide a basis for feedback design of concrete filling at the later stage, and the influence analysis of each factor on the settlement could be made by adjustment of input parameters of the network.

Key words concrete face rockfill dam (CFRD); settlement; neural network; prediction