

基于人工神经网络的崩岸预测模型研究

王 媛¹, 陈尚星¹, 汪华安²

(1. 河海大学岩土工程研究所, 江苏 南京 210098; 2. 广东省电力设计院, 广东 广州 510600)

摘要: 针对崩岸影响因素众多、难以定量评价等问题, 采用一种基于人工神经网络的崩岸预测方法, 介绍了其基本原理. 在研究崩岸诸多影响因素的基础上, 选取 11 种主要影响因素建立崩岸预测模型. 以随机构造的 20 个岸坡模型为训练样本, 以 5 个随机岸坡模型为检验样本, 实现了岸坡稳定性的人工神经网络预测. 初步结果表明, 神经网络方法可以应用于崩岸的预测.

关键词: 崩岸; 预测; 人工神经网络

中图分类号: TU413.6 **文献标识码:** A **文章编号:** 1000-1980(2007)05-0514-04

崩岸是一种十分复杂的岸坡破坏过程, 与岸坡土层结构、土体的材料性质、岸坡形态、降雨、岸坡堆载、水流冲刷、水位变化和护岸工程等众多因素有关, 并且在不同的情况下, 崩岸的诱发因素都不相同. 目前的研究大多从单方面因素去预测崩岸的发生, 如何综合考虑多种因素的影响是一个亟待解决的问题. 而神经网络能考虑多种因素, 并且具有高度的非线性映射能力.

人工神经网络(artificial neural network, ANN)是在生物神经系统的启发下发展起来的一种信息处理方法^[1]. 人工神经网络与人脑相似, 是由大量简单的神经元彼此相互连接而成的大规模非线性系统, 具有高度非线性和并行处理能力. 人工神经网络能够向不精确并带有噪音的数据学习, 具有良好的容错能力和联想记忆能力^[2], 广泛应用于信息处理、智能控制、模式识别等许多工程技术和社会经济领域. BP 人工神经网络在土木、水利领域用得较多, 如用于水力发电过程的辨识和控制、河川径流预测、河流水质分类、混凝土性能评估、拱坝优化设计、砂土液化预测^[3]、岩爆预测^[1-2]等. 本文即采用 BP 人工神经网络进行崩岸的预测.

1 BP 人工神经网络及改进模型

1.1 BP 人工神经网络的模型结构和工作原理

BP 人工神经网络是一种前向人工神经网络, 其全称是误差逆向传播神经网络(error back propagation neural network). BP 人工神经网络的基本结构包括 3 层, 即输入层、隐含层和输出层, 各层之间实现全连接. 按隐含层的个数可分为 3 层(包含 1 个隐含层)和多层(包含 2 个或 2 个以上隐含层)BP 人工神经网络. 尽管数学家已经证明 3 层前向网络可以精确地逼近任何复杂的函数^[1-2, 4], 但其隐含的节点数不能任选, 且对样本数据携带的噪音的鲁棒性极差^[5], 所以有时采用深层前向网络可能会更好^[6]. BP 人工神经网络的工作原理是通过 BP 人工神经网络的非线性逼近能力, 尽可能地使网络的输出与期望输出一致. 这主要是通过不断调整各神经元的连接权和阈值来实现的. 调整各神经元的连接权和阈值的方法也叫学习规则. 通常采用的学习规则是最小二乘学习规则(LMS, Least Mean Square), 也称线性修正规则^[6], 其算法过程如下.

定义一个能量函数 E

$$E = \frac{1}{n} \sum_{p=1}^n E_p \quad E_p = \frac{1}{2} \sum_{j=1}^m (O_j(x_p) - D_j(x_p))^2 \quad (1)$$

式中: $O_j(x_p)$ ——学习样本 p 在网络输出节点 j 上的计算输出; $D_j(x_p)$ ——学习样本 p 在网络输出节点 j 上的期望输出; m ——网络输出节点的个数; n ——学习样本的个数.

网络学习的过程就是使能量函数 E 最小的过程. 其计算过程可以表述如下 (a) 初始化网络权值 W 及阈值 B . (b) 激活输入层的所有节点, 计算各层的节点输出. (c) 计算各层节点的一般化误差和参考误差. (d) 调整连接权值和阈值. (e) 计算能量 E_p 和 E , 若其小于某一精度值 ϵ , 则保留权值和阈值, 学习过程结束; 否则, 转到第 (b) 步继续学习, 直到达到计算精度要求为止.

1.2 BP 人工神经网络的改进

BP 神经网络是一个不完善的人工神经网络模型, 它在实际应用中存在如下问题 (a) 学习收敛速度很慢, 一个比较简单的问题也需要几千次甚至上万次的训练才能收敛, 不能满足人们对时间和速度的要求; (b) 有陷入局部最小的可能, 不能保证收敛到全局最小点 (c) 如果网络的学习误差设得过小, 则网络可能出现学习过头的现象, 即用已经训练好的网络对未参与学习的样本进行预测时会出现很大误差.

因此有必要从以下两方面对 BP 神经网络模型进行改进 (a) 采用启发式学习算法 (b) 采用更有效的优化算法^[6]. 由于 BP 算法的实质是一种无约束的优化计算方法, 因此许多优化算法都可以用于 BP 神经网络的学习过程. 如全局优化算法 (Gauss-Newton) 是利用样本的全部信息, 求出连接权的修正值, 再对连接权进行修正. 遗传算法 (genetic algorithm) 是根据模拟达尔文的遗传选择和进化来确定网络的连接权, 还有模拟退火算法、交替迭代算法等^[1]. 本文应用 Levenberg-Marquardt 算法来调整连接权和阈值. Levenberg-Marquardt 算法比梯度下降法的收敛速度快得多, 缺点是占用的内存比较大^[6]. 其算法如下:

$$JJ = JW \times JW \quad (2)$$

$$JE = JW \times E \quad (3)$$

$$\Delta W = -(JJ + \mu I)^{-1} JE \quad (4)$$

式中: JW ——由误差对各神经元的连接权和阈值微分组成的雅可比矩阵; E ——网络误差向量; I ——单位矩阵; ΔW ——网络权值 W 的修正量; μ ——一标量, 称为自适应调整量.

1.3 μ 的选取

变量 μ 的选取决定了学习算法是牛顿法还是梯度下降法^[6]. 只要迭代过程中误差有增加, μ 也会增加, 并且 μ 增加到误差不再增加为止. 随着 μ 的增加, 式 (4) 中的 JJ 可以忽略不计, 所以在学习过程中主要采用梯度下降法, 即 $JE\mu^{-1}$ 项起作用. 但是 μ 太大会使网络的学习停止 (因 $JE\mu^{-1}$ 趋向于 0), 因此给 μ 取一个很大的上限值 (如 10^8), 若 μ 大于该上限值, 则网络停止学习. 本文 μ 初始值取为 0.001, 上限值取为 10^8 . 在网络的学习过程中, μ 采用如下的动态调整方法:

$$\begin{cases} 10\mu(t) & \text{MSE}(t+1) < \text{MSE}(t) \\ \mu(t+1) = 0.1\mu(t) & \text{MSE}(t+1) > \text{MSE}(t) \\ \mu(t) & \text{MSE}(t+1) = \text{MSE}(t) \end{cases} \quad (5)$$

式中: t ——第 t 次训练; $\text{MSE}(t)$ ——均方差 (Mean Square Error).

2 崩岸预测的神经网络模型

2.1 崩岸的影响因素

影响崩岸的因素众多, 本文将崩岸的影响因素分为受水流冲刷控制和受非水流冲刷控制两类因素.

a. 受水流冲刷控制因素 (a) 岸坡土体的抗冲性, 采用起动流速 $v_{\text{起动}}$ 表示 (b) 水流的流速 v 、流量 Q .

b. 受非水流冲刷控制的因素有 (a) 岸坡外形. 斜坡的存在是崩岸产生的先决条件, 而岸坡的外形直接影响岸坡的稳定程度 (用坡高 H 坡角 θ 表示). (b) 岸坡土体性质. 岸坡土体的性质是影响岸坡稳定性的内在因素, 选用黏聚力 c 、内摩擦角 φ 和土体的渗透系数 k . (c) 水的作用. 崩岸不同于一般的滑坡, 受水的作用非常明显. 这里所考虑的水的作用主要是水位的升降类型 (快速涨水、缓慢涨水、快速退水、缓慢退水). (d) 地震作用. 地震能够使可液化地层发生液化, 岸坡土体抗剪强度降低, 同时地震会增加岸坡土体的下滑力, 促使岸坡向破坏的方向发展. (e) 降雨作用. 强度大的暴雨和持续时间长的连阴雨, 常会导致岸坡不同程度的坍塌, 对岸坡的稳定影响很大, 且降雨强度越大, 持续时间越长, 岸坡崩塌得越厉害. 通常选用降雨量 q 作为输入指标. (f) 人为因素. 如开挖坡脚、坡顶加载、不恰当的护岸工程、人为破坏岸坡表层植被等都对岸坡的稳定构成影响.

综上所述, 崩岸的影响因素众多, 不仅具有随机性, 而且具有模糊性, 崩岸是众多因素综合作用的结果.

应从各种影响因素中选取主要因素,忽略次要因素.本文选取岸坡土体抗冲性 $v_{启动}$ 、水流流速 v 、流量 Q 、坡高 H 、坡角 θ 、土体渗透系数 k 、土体密度 ρ 、黏聚力 c 、内摩擦角 φ 、降雨量 q 、水位的涨退类型共 11 种具有代表性的指标作为 ANN 网络的输入神经元.网络输出为崩岸发生与否.

2.2 崩岸预测神经网络模型的建立

虽然 3 层前向网络可以精确地逼近任何复杂的函数,但往往存在迭代次数多、收敛慢等缺点,所以本文采用多层前向网络,隐含层取 2 层.选取上述 11 种崩岸影响因素作为输入层神经元,输出层取 2 个神经元,取值分别是 (1 0) (0 1) 表示崩、不崩,本文采用一组正交向量表示,使之尽量分开以便识别.需要说明的是,对于水位的作用,在模型输入时取值为 (1 0 0 0), (0 1 0 0) (0 0 1 0) (0 0 0 1) 分别表示快速涨水、缓慢涨水、快速退水、缓慢退水,同样采用一组正交向量来表示.模型中隐含层的神经元为 23 个,激活函数为正切 Sigmoid 函数,隐含层到输出层也采用正切 Sigmoid 函数.其网络的拓扑结构见图 1,其中 w_1, w_2, w_3 表示权值, b_1, b_2, b_3 表示阈值.

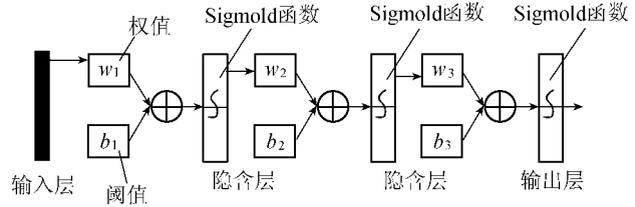


图 1 神经网络模型的拓扑结构

Fig.1 Topological structure of ANN model

2.3 算例

2.3.1 样本的构造

由于崩岸资料的匮乏,要同时获得上述 11 种崩岸影响因素的实测资料非常困难,所以本文采用以下方法构造样本 (a) 鉴于收集水流方面实测资料困难,为使问题简化,本文选取坡高、坡角、土体密度、黏聚力、内摩擦角、水位变化类型共 6 种影响因素 (b) 确定上述影响因素的可能取值范围,并随机产生岸坡模型样本,如土体的黏聚力 c 通常取值在 2~35 kPa 之间,则在 2~35 kPa 之间产生若干个随机数作为岸坡土体的黏聚力,如此可以产生任意多个岸坡模型 (c) 采用极限平衡法计算上述随机产生的岸坡模型的稳定性,于是可以产生一系列的可用于神经网络学习的样本^[7].

2.3.2 样本的计算

基于本文样本构造方法,共构造 25 个样本,见表 1,其中前 20 个样本用于网络的学习,后 5 个样本用于网络的检验^[8].网络的输入神经元取 6 个,分别是坡高 H 、坡角 θ 、土体密度 ρ 、黏聚力 c 、内摩擦角 φ 、水位变化类型.输出层取 2 个神经元,隐含层取 13 个神经元,建立神经网络模型.对所建立的网络进行学习,通过 289 次的学习,误差小于 0.001,可以认为网络已满足实际应用的要求.若需达到同样的精度,采用附加动量法的梯度下降法,则需要学习 8956 次.样本的参数与预测的结果见表 1.表中水位变化类型 (1 0 0 0) (0 1, 0 0) (0 0 1 0) (0 0 0 1) 分别表示快速涨水、缓慢涨水、快速退水、缓慢退水.表中的 (1 0) 和 (0 1) 分别表示岸坡稳定和不稳定(崩、不崩).

由表 1 可以看出,用于预测的 5 个样本,只有样本 23 判断错误,其余 4 个均判断正确,正确率达 80%.由此可见,采用神经网络方法预测崩岸是可行的.笔者曾采用较少的样本进行训练,预测余下的样本,其判断正确率较低;当训练样本较多时,预测精度提高.由此可见,用于训练的样本越多,BP 人工神经网络的预测精度越能得到提高.

3 结 语

本文基于 BP 神经网络方法预测崩岸的基本思路,从影响崩岸的诸多因素中,挑选 11 种主要影响因素作为 BP 人工神经网络的输入神经元.针对传统人工神经网络的缺点,采用 Levenberg-Marquardt 算法加以改进,加快了网络的收敛速度.由于崩岸实际资料的缺乏,本文采用随机方法构造了 25 个岸坡模型样本来验证所建立的 BP 神经网络崩岸预测方法的有效性和可行性.在实际工程应用中,应收集大量的崩岸实际数据,根据崩岸发生时的岸坡水文条件、地质条件及其他因素,来建立崩岸的实际样本,但目前尚有一定的难度.此外在崩岸预测中,水流冲刷因素、土层结构条件也都是不可忽视的.

表 1 神经网络学习样本与预测样本

Table 1 Studying and predicting samples of ANN model

序号	密度 $\rho(\text{g}\cdot\text{cm}^{-3})$	黏聚力 c/kPa	内摩擦角 $\varphi(^{\circ})$	坡角 $\theta(^{\circ})$	坡高 H/m	水位 变化类型	实测 结果	网络预测 结果
1	1.4	6	30	54	5	(0.1 0.0)	(1.0)	(1.0)
2	1.6	6	31	7	5	(0.1 0.0)	(1.0)	(1.0)
3	1.7	11	27	6	5	(0.0 1.0)	(1.0)	(1.0)
4	1.7	5	28	8	6	(0.0 1.0)	(0.1)	(0.1)
5	1.8	13	22	57	6	(1.0 0.0)	(1.0)	(1.0)
6	1.7	19	27	74	4	(0.0 1.0)	(1.0)	(1.0)
7	1.5	7	31	60	4	(0.0 1.0)	(1.0)	(1.0)
8	1.6	6	33	73	6	(0.1 0.0)	(0.1)	(0.1)
9	1.7	17	24	58	7	(0.1 0.0)	(1.0)	(1.0)
10	1.5	19	20	60	8	(0.0 1.0)	(0.1)	(0.1)
11	1.8	5	33	58	5	(0.0 0.1)	(1.0)	(1.0)
12	1.6	15	28	56	5	(0.0 0.1)	(1.0)	(1.0)
13	1.7	9	32	76	7	(0.0 1.0)	(0.1)	(0.1)
14	1.5	17	34	40	5	(0.1 0.0)	(1.0)	(1.0)
15	1.6	6	23	50	7	(1.0 0.0)	(0.1)	(0.1)
16	1.8	12	24	3	8	(0.0 1.0)	(1.0)	(1.0)
17	1.5	18	24	68	7	(0.1 0.0)	(1.0)	(1.0)
18	1.7	23	21	65	7	(1.0 0.0)	(1.0)	(1.0)
19	1.6	19	30	80	4	(0.0 1.0)	(1.0)	(1.0)
20	1.7	7	23	60	5	(0.0 0.1)	(0.1)	(0.1)
# 21	1.7	14	33	55	7	(0.0 1.0)	(1.0)	(1.0)
# 22	1.6	18	23	50	6	(0.0 0.1)	(1.0)	(1.0)
# 23	1.6	12	23	65	8	(0.0 0.1)	(1.0)	(0.1)
# 24	1.7	8	35	70	7	(1.0 0.0)	(0.1)	(0.1)
# 25	1.7	19	27	55	7	(0.1 0.0)	(1.0)	(1.0)

注 :# 表示预测样本.

参考文献 :

[1] 赵林明, 胡浩云, 魏德华 等. 多层前向人工神经网络 [M]. 郑州: 黄河水利出版社, 1999 :1-140.
 [2] 陈海军, 郦能惠, 聂德新 等. 岩爆预测的人工神经网络模型 [J]. 岩土工程学报, 2002 (2) :229-232.
 [3] 张晓军, 吴亚萍, 尚伟宏 等. 利用模糊神经网络进行砂土液化势评判 [J]. 工程地质学报, 2001 (9) :209-213.
 [4] 冯夏庭, 王泳嘉, 卢盛松. 边坡稳定性的神经网络估计 [J]. 工程地质学报, 1995 (4) :54-61.
 [5] 高玮. 岩土工程监测位移预测的神经网络模型研究 [J]. 岩土工程师, 2002 (2) :8-12.
 [6] 闻新, 周露, 王丹力 等. MATLAB 神经网络应用设计 [M]. 北京: 科学出版社, 2001 :1-333.
 [7] 孙广中. 中国典型滑坡 [M]. 北京: 科学出版社, 1988 :1-366.
 [8] 邢文训, 谢金星. 现代优化计算方法 [M]. 北京: 清华大学出版社, 1999 :1-298.

Artificial neural network-based bank collapse prediction model

WANG Yuan¹, CHEN Shang-xing¹, WANG Hua-an²

(1. Geotechnical Research Institute of Hohai University, Nanjing 210098, China ;
 2. Guangdong Electric Power Design Institute, Guangzhou 510600, China)

Abstract : In consideration of many influencing factors and some difficulties in quantitative evaluation, the artificial neural network (ANN)-based bank collapse prediction method was adopted, and its principle was introduced. By selection of 11 main influencing factors, a bank collapse prediction model was established. Then 20 bank-slope models, which were randomly generated, were taken as training samples, and 5 random bank-slope models as testing samples, the bank-slope stability was predicted by use of the present model. The result shows that the ANN method can be used for bank collapse prediction.

Key words : bank collapse ; prediction ; artificial neural network (ANN)