

砂土地震液化的神经网络预测

陈 奎, 刘兴昌

(西北大学环境科学系, 陕西 西安 710069)

摘要: BP 网络具有很强的非线性映射和自适应学习功能, 可用于模式识别和预测评估等领域. 在简要分析 BP 算法的基础上, 选取砂土的平均粒径 (d_{50}/mm)、相对密度 ($D_r/\%$)、标准贯入击数 ($N_{63.5}/\text{击}$)、上覆有效压力 (σ_v/kPa)、地震烈度 (I_0) 作为指标, 应用 BP 神经网络的理论与方法, 预测砂土在地震作用下液化的可能性, 取得了较好的预测效果. 说明将 BP 网络用于沙土液化预测是可行的.

主题词: 砂土液化; 地震; BP 神经网络

中图分类号: P315.9 **文献标识码:** A **文章编号:** 1000-0844(2000)02-0167-05

0 引言

砂土地震液化指饱和和松散砂土或粘聚力较弱的轻亚粘土在地震作用下产生急剧的状态改变和强度丧失, 表现出类似液体性状的现象. 其产生是孔隙水压力不断升高, 土骨架承受的有效应力不断降低, 土体由固体向液体转化的结果. 砂土液化具有很大的危害性, 表现为喷砂冒水、地面沉陷、诱发高速滑坡、地基失稳等. 因而, 砂土地震液化预测是地震工程、岩土工程和自然灾害防治工程的一项重要基础性研究工作, 经过几十年的研究, 已经有了很多方法, 如经验公式法、Seed 简化分析法、概率与统计方法、动力反应分析方法等^[1]. 但由于影响砂土液化的因素具有复杂性和多样性, 相互间的线性关系不明显, 结论的可靠性还需提高. 近年来许多研究人员使用模糊数学和灰色理论等非线性方法进行预测. 用模糊评判方法需要对各选取指标赋予不同的权重, 权值的选取不可避免地带有主观性和随意性, 导致结果失真^[2]; 用灰色理论进行预测, 当原始数据序列波动较大且信息过于分散时则预测精度将会降低^[3]. 而神经网络具有很强的非线性映射和自适应学习功能^[4], 特别是 BP 网络近年来广泛应用于模式识别、预测评估等领域并取得良好效果. 故本文采用 BP 网络对砂土地震液化进行预测.

1 BP 网络及 BP 算法

BP 网络目前在神经网络中运用较多, 它是一单向传播的多层前向网络, 可看成是从输入到输出的高度非线性映射: $F: R^n \rightarrow R^m, f(x) = y$. 通过对简单的非线性函数进行多次拟合, 可近似模拟复杂的函数(图 1).

BP 网络学习算法包括正向计算和误差反向传播两




图 1 BP 神经网络模型
Fig. 1 The back-propagation neural network model.

个过程.在正向学习过程中,输入信息经隐层处理后传向输出层,如果在输出层不能得到期望的输出,则转入反向传播,将误差信号沿原来的通路返回,修正各层神经元的权值和阈值使误差信号最小(图 2).




图 2 BP 网络算法图示

Fig. 2 The BP network algorithm pattern.

```

/* 正向处理 */
/* 设置输入层单元的输出 */
for (k = 0; k < IN; k++)
  ot_in[k] = (double) indata[ loop] .input[ k] ;
/* 计算中间层单元的输出 */
for(k = 0; k < HN; k++) { iniva = 0.0;
for(m = 0; m < IN; m++)
  inival += (w_in_hd[ k] [ m] * ot_in[ m] );
  inival += cw_hd[ k] ; /* 对中间层单元k的输入 */
  a_hd[ k] = sigmf( inival ); /* 中间层单元输出 */
/* 计算输出层单元的输出 */
for(k = 0; k < ON; k++) { iniva = 0.0;
for(m = 0; m < HN; m++)
  inival += (w_hd_ot[ k] [ m] * ot_hd[ m] );
  inival += cw_ot[ k] ; /* 对输出层单元k的输入 */
  ot_ot[ k] = sigmf( inival ); /* 输出层单元k输出 */

```

假设共有 m 层(不包括输入层), l 层的节点数为 n , $y_k^{(l)}$ 代表第 l 层节点 k 的输出, 则:

$$\bar{y}_k^{(l)} = W_k^{(l)} \cdot y^{(l-1)} = \sum_{j=1}^{n_{l-1}} W_{kj}^{(l)} \cdot y_j^{(l-1)}$$

$$y_k^{(l)} = f(\bar{y}_k^{(l)}) \quad k = 1, 2, 3, \dots, n$$

$W_k^{(l)}$ 为连接第 $l-1$ 层节点到第 l 层节点 k 的权向量, $y^{(0)} = x$, $f(\cdot)$ 是响应函数, 一般采用 sigmoid 函数:

$$f(x) = 1 / (1 + \exp(-x)).$$

给定训练样本 (X, Y) , 调整网络权

值, 使下列准则函数(LMS)最小:

$$E(W) = \frac{1}{2} \cdot \| Y - \hat{Y} \|^2 = \frac{1}{2} \cdot \sum_{k=1}^n (Y_k - \hat{Y}_k)^2 \quad Y_k = \hat{Y}_k^{(m)} \text{ 为网络的输出.}$$

```

/* 反向处理 */
/* 误差计算 */
for( m = 0; m < ON; m++) {
  teach[m] = (double) indata[ loop] .tch[ m] ;
  wk = ot_ot[ m] ;
  wkb = teach[m] - wk ; /* 教师信号和输出的差 */
  del_ot[m] = wkb * ruo * wk * (1.0 - wk); }
/* 误差计算 */
for(k = 0; k < HN; k++) { iniva = 0.0;
for(m = 0; m < ON; m++)
  inival += (del_ot[ m] * w_hd_ot[ m] [ k] );
  wk = ot_hd[ k] ;
  del_hd[ k] = inival * ruo * wk * (1.0 - wk); }

```

根据梯度下降法求取 $E(W)$ 的梯度来修正权值, 权向量 $W_i^{(l)}$ 的修正值由下式获得:

$$\Delta W_i^{(l)} = -a \cdot \frac{\partial E}{\partial W_i^{(l)}} = a \cdot \delta_i^{(l)} \cdot y^{(l-1)} \quad (1)$$

$$\begin{cases} \delta_i^{(l)} = (Y_i - Y_i^{(m)}) \cdot f'(Y_i^{(m)}) & (\text{对于输出层}) \\ \delta_i^{(l)} = \sum_{j=1}^{n_{l+1}} W_{ij}^{(l+1)} \cdot \delta_j^{(l+1)} f'(Y_i^{(l)}) & (\text{对其它层}) \end{cases}$$

$$(l = 1, 2, 3, \dots, m - 1)$$

式中 a 为学习率. 对于给定的样本, 按此算法不断反复修正权值, 可使网络的实际输出接近希望的输出. BP 网络学习算法的核心程序如左面框图所示.

2 BP 算法分析及优化

BP 算法是一种简单的最速下降静态寻优算法, 主要缺点表现在以下几方面: ① 采用残差平方和最小作为目标函数, 会过分地突出极大值的影响; ② 由于采用基于梯度的搜索方法, 就需要很好定义的可微曲面, 因而难以解决具有局部极小点的复杂的欺骗性问题, 尤其当求取一般非凸目标函数的全局最优解时更是如此; ③ 学习算法的收敛速度很慢, 通常需要较长时间才能收敛. 有许多寻优算法可用于 BP 网络的改进, 例如: 模拟退火算法、Tabu search 算法及遗传算法等. 根据以上分析, 本文对 BP 算法作了一定的优化, 采用基于梯度下降法的动量法和学习速率自适应调整算法来修正网络权值. 调整后的(1)式可表达如下:

$$\begin{cases} W_{i+1}^{(D)} = W_i^{(D)} + a_i \cdot [(1 - \eta) \cdot D_i + \eta \cdot D_{i-1}] & (2) \\ a_i = 2^\lambda \cdot a_{i-1} & (3) \\ \lambda = \text{sign}(D_i \cdot D_{i-1}) & (4) \end{cases}$$

$W_i^{(D)}$ 为权值, $D_i = -\frac{\partial E}{\partial W_i^{(D)}}$ 是负梯度, a_i 是学习率, η 为动量因子, $0 \leq \eta < 1$.

动量法((2)式)可以降低网络对于误差曲面局部细节的敏感性, 有效地抑制网络陷于局部极小, 动量项实质上相当于阻力项, 它减少了学习过程的振荡趋势, 从而改善了收敛性. 标准 BP 算法收敛速度慢的一个重要原因是学习率 a 选择不当, 过小则收敛太慢, 过大则有可能修正过头, 导致振荡以至发散. (3) 和 (4) 式表示当两次迭代的梯度方向相同时, 说明下降速度太慢, 这时可调整学习率 a 使其加倍, 当连续两次迭代梯度方向相反时, 表明下降速度过快, 则减半学习率 a .

3 砂土地震液化的 BP 网络预测

考虑到砂土液化的特点, 本文采用三层 BP 网络根据以上算法编制程序对砂土地震液化进行预测. 网络隐层节点数的选取目前尚无理论上的指导, 若选择过少, 则网络的非线性映射功能和容错性差; 选择过多, 又使得学习时间增加, 学习误差也不一定最佳. 一般通过检验模型评价能力来确定, 经多次运算并比较实验数据与经过辨识得到的模型计算值间的误差平方和后选取为 5, 传递函数分别采用正切 sigmoid 函数和纯线性函数, 学习率 a 初值 0.01, 动量常数 η 选为 0.9. 资料来源于文献[2], 通过整理而得, 训练样本 22 个, 其中液化 9 个, 未液化 13 个, 检验样本 4 个. 影响砂土液化的因素很多, 可分为土性条件、埋藏条件、动荷条件三大方面. 考虑到砂土液化最基本的制约因素是砂土的本身特性及指标选取的简单性、容易性和代表性, 选取砂土的平均粒径 (d_{50}/mm , 实际运算时单位取 μm)、相对密度 ($D_r/\%$)、标准贯入击数 ($N_{63.5}/\text{击}$)、上覆有效压力 (σ_v/kPa)、地震烈度 (I_0) 作为指标. 对砂土液化的数值处理可分为两个标准: 液化取 1、未液化取 0. 具体数据和运算结果列于表 1.

4 结语

(1) 比较表 1 的实际数据与预测数据可看出, 训练样本的输出值与实际值误差很小(仅 5 号较大, 为 6%, 其余均小于 3%). 4 个样本预测结果与实际情况一致(准确率为 4/4), 网络泛化性能良好, 且结论直观. 说明运用 BP 网络进行砂土地震液化预测是可行的.

(2) BP 网络还有以下突出优点: ① 由于采取大容量训练, 可避免偶然性引起的误差, 即使在条件比较复杂或应用单因素不易判断时, 也可获得明显效果; ② 数据信息采取分布式存储

和处理, 可避免个别单元损坏而引起错误, 因而用 BP 网络进行预报时容错能力强, 可靠性高. BP 网络有望成为砂土地震液化预测的一种有效手段.

表 1 学习样本及预测结果

序号	地震烈度 I_0	平均粒径 d_{50}/mm	相对密度 $D_r/\%$	标准贯入击数 $N_{63.5}/\text{击}$	上覆有效压力 σ_v/kPa	现场数据	BP 网络预测数据
1	VII	0.065	58	6	20	1	1.020 8
2	VII	0.090	88	11	60	1	0.992 6
3	VII	0.092	70	12	114	0	0.027 0
4	VII	0.105	60	14	175	0	0.018 5
5	VII	0.107	82	15	70	0	0.060 0
6	VIII	0.130	80	20	50	1	0.999 8
7	VII	0.180	75	43	130	0	0.017 8
8	VIII	0.180	80	25	50	1	0.998 1
9	IX	0.140	77	20	100	1	1.004 5
10	VIII	0.290	75	15	150	0	0.006 5
11	X	0.260	90	25	150	0	0.035 2
12	IX	0.330	77	25	100	1	0.980 8
13	XI	0.550	90	30	200	0	0.005 9
14	X	0.280	80	20	150	1	0.978 1
15	X	0.150	70	15	100	1	1.004 5
16	VIII	0.180	90	40	200	0	0.005 9
17	VII	0.180	75	43	210	0	0.005 9
18	VIII	0.135	64	10	110	1	1.007 9
19	VII	0.120	75	15	150	0	0.020 0
20	VII	0.106	75	17	88	0	0.015 4
21	VII	0.094	70	15	132	0	0.012 6
22	VII	0.065	58	6	100	1	1.025 7

表 2 检验样本及预测结果

序号	地震烈度 I_0	平均粒径 d_{50}/mm	相对密度 $D_r/\%$	标准贯入击数 $N_{63.5}/\text{击}$	上覆有效压力 σ_v/kPa	现场数据	BP 网络预测数据
1	VII	0.107	82	20	100	0	0.012 8
2	VIII	0.135	64	13	150	1	0.974 5
3	VIII	0.230	95	42	200	0	0.005 0
4	X	0.180	70	20	100	1	1.004 5

表 3 输入层到隐层的权值和阈值

序号	权值(1)					阈值(1)
	1	2	3	4	5	
1	0.325 1	-0.029 7	-0.035 3	0.025 5	-0.014 4	-3.969 9
2	-0.150 7	-0.563 0	0.991 7	-1.116 2	0.214 3	2.830 6
3	-0.916 7	-0.003 0	0.127 2	-0.263 1	0.002 1	-1.669 0
4	5.091 7	-0.023 6	-0.508 2	0.211 7	-0.074 9	5.148 4
5	-0.383 7	-0.037 6	-0.054 7	-0.004 8	-0.024 5	4.376 8

表 4 隐层到输出层的权值和阈值

序号	权值(2)					阈值(2)
	1	2	3	4	5	
1	-0.853 7	0.001 3	0.971 8	0.499 3	-0.896 4	-0.325 7

(3) BP 网络用于砂土液化预测的缺点: ① 运用 BP 网络进行预测需要较多的训练样本, 若数据量太少或预测指标选得不当时, 会影响预测精度, 甚至达不到预定的目的. 本文选取训练样本不多, 误差平方和仅取 0.02, 如果增加训练样本, 精度还可以提高; ② 所选数据最好成正态分布, 数据正态分布不强时会影响网络的学习效果, 对此可对数据进行非线性变换, 常用的变换函数 $f(x)$ 有 x^n 、 $\ln(x)$ 、 e^x 等; ③ 应尽量避免出现奇异值, 奇异值的出现会影响预测的准确性; ④ 本文对砂土液化标准仅作二值处理, 因而 BP 网络预测结果未能反映出砂土液化的程度, 对此, 可改为多值进行处理; ⑤ 由于 BP 网络采用黑箱型的学习模式, 学习完成后, 其所获得的输入/输出关系无法用易被人接受的方式表达出来.

[参考文献]

- [1] 陈文化, 孙巨平, 徐兵. 砂土地震液化的研究现状及发展趋势[J]. 世界地震工程, 1999, 15(1): 16~24.
- [2] 翁焕学. 砂土地震液化综合评判实用方法[J]. 岩土工程学报, 1993, 15(2): 74~79.
- [3] 陈新民, 罗国煜. 砂土地震液化可能性的非确定性灰色预测方法[J]. 桂林工学院学报, 1997, 17(2): 106~109.
- [4] 赵振宇, 徐用懋. 模糊理论和神经网络的基础与应用[M]. 北京: 清华大学出版社, 南宁: 广西科学技术出版社, 1997. 105~106.

PREDICTION OF SAND SOIL LIQUEFACTION DURING EARTHQUAKES BY THE BP NEURAL NETWORK

CHEN Kui, LIU Xing-chang

(*Department of Urban and Resource Science, Northwest University, Xi'an 710069, China*)

Abstract: The BP neural network is applied to predicting the potential of sand soil liquefaction. The mean diameter, relative density, standard penetration number and effective over burden pressure are selected as the indices. The forecasting results show that the method is feasible.

Key words: Liquefaction of sand soil; Earthquake; BP neural network