

基于自组织神经网络的砂土液化评价

薛新华

(浙江大学岩土工程研究所,浙江杭州 310027)

【摘要】 在分析自组织特征映射(SOFM)神经网络基本学习算法的基础上,从提高算法收敛速度和性能出发,提出了一种改进算法;根据实际应用并结合专家经验确定初始连接权值;采用高斯函数作为拓扑邻域函数;将算法分为粗调整和细调整两个阶段,分别采用不同的学习率和邻域函数,然后采用改进后的SOFM算法对砂土液化进行评价。实例研究表明,应用SOFM神经网络评价砂土液化高效可行,为砂土液化评价提供了新方法。

【关键词】 自组织特征映射;神经网络;砂土液化

【中图分类号】 TU 441; TP 183

Evaluation of Sand Liquefaction Based on SOFM Neural Network

Xue Xinhua

(Institute of Geotechnical Engineering, Zhejiang University, Hangzhou Zhejiang 310027 China)

【Abstract】 An improved algorithm for self-organizing feature map neural network is presented. In this algorithm, the expert experience and actual state are considered using training weight vectors, the Gauss weight neighborhood function is used to replace the square or circular function, and different descending functions of learning rate and neighborhood width are used in two learning periods. The improved algorithm is used to evaluate the sand liquefaction. The testing results of practical examples show that the method based on SOFM neural network is feasible and effective, and it provides a new approach to research sand liquefaction potential.

【Key Words】 self-organization; neural network; sand liquefaction

0 引言

砂土液化是在地震引起的循环荷载作用下,饱和砂土层孔隙水位升高,有效应力降低,造成土体承载力部分或者全部丧失,形成的一种破坏性严重的区域性地质灾害^[1]。砂土液化具有很大的危害性,常伴有喷砂冒水、地面沉陷、诱发高速滑坡、地基失稳等现象,给人们的生命财产带来极大的损失^[2]。准确可靠地进行液化预测具有重要的现实意义。

液化判别涉及到地震和土的参数等多种定性、定量变量,且这些变量与评价结论往往呈高度非线性关系,传统的判别方法如动力反应分析法^[3]、经验公式法^[4]、灰色聚类法^[5]等都存在着不可避免的弊端,自身适应性差,预测效果不很理想。因此,建立一种人为影响因素小,能容定量与定性指标于一体的多参数综合评判模型非常必要。

神经网络方法从模拟人脑的形象思维入手,具

有非线性、并行性、鲁棒性和强泛化性等特点,对于处理具有强噪声、模糊性、非线性的地质体信息,具有广阔的应用前景^[4]。目前用于地质体的神经网络主要是BP网络,大部分模型只进行了液化与否的识别,没有进行液化危害等级的划分,限制了BP网络的准确性及可靠性。为了改善和提高砂土液化评价的智能性,本文提出用改进的自组织特征映射(SOFM)神经网络来建立砂土液化评价模型,对砂土液化进行分析,以求在砂土液化评价的问题上开拓一条新思路。

1 SOFM网络原理^[6]

自组织特征映射神经网络一般分为两大类:一类是由Von Der Malsburg^[6]提出的主要思路为输入模式的维数与输出模式的维数相等的网络结构模式;一类是1982年由芬兰科学家Kohonen^[7]提出的高维输入模式到低维输出模式的压缩映射网络结

构。由于后者不仅可以用于分类,也可以用于信息压缩,其应用范围更广,这种网络称为SOFM(Self-Organizing Feather Map)神经网络。

SOFM神经网络的算法基于无监督学习,即训练全部由数据来驱动,与基于监督学习的网络需要已知输入矢量的期望值不同,SOFM可用于在不知道输入数据的类成员时作聚类分析。因此,SOFM能够用来探寻问题的本质特性。SOFM网络的主要性能为:1)自组织排序性,即拓扑保持能力;2)自组织概率分布特性;3)对输入数据有聚类作用,将高维数据映射到低维空间,用输出节点的权向量代表原输入,具有数据压缩和特征提取的作用;4)以若干神经元同时反映分类结果,具有容错性;5)具有自联想功能。

SOFM神经网络由输入层和竞争层组成(见图1)。其自组织学习过程可以描述为:对于每一个网络的输入,只调整一部分权值,使权矢量更接近或更偏离输入矢量,这一调整过程就是竞争学习。随着不断学习,所有权矢量都在输入矢量空间相互分离,形成各自代表输入空间的一种模式,即为网络的自组织聚类功能。SOFM网络的学习步骤如下:




图1 SOFM神经网络结构示意图

①初始化 将网络数值向量集 $\{W_{ij}\}$ 赋予 $[0, 1]$ 区间随机值,确定学习率初始值 $\eta(0)$ $(0 < \eta(0) < 1)$,确定邻域初始值 $N_g(0)$,确定总学习次数 T 。

②从输入向量集中随机选取向量 P_k 提供给网络输入层,并进行归一化处理。

$$P_k = P_k / \|P_k\| = \frac{(p_1^k, p_2^k, \dots, p_n^k)}{[(p_1^k)^2 + (p_2^k)^2 + \dots + (p_n^k)^2]^{1/2}} \quad (1)$$

③对权值向量 $W_j = (W_{j1}, W_{j2}, \dots, W_{jn})$ 归一化,计算 W_j 和 P_k 之间的欧式距离。

$$W_j = W_j / \|W_j\| = \frac{(w_{j1}, w_{j2}, \dots, w_{jn})}{[(w_{j1})^2 + (w_{j2})^2 + \dots + (w_{jn})^2]^{1/2}} \quad (2)$$

$$d_j = \left| \sum_{i=1}^n (P_i^k - W_{ji})^2 \right|^{1/2} \quad j=1, 2, \dots, M \quad (3)$$

④找出最小距离 d_g ,确定获胜神经元 g 。

$$d_g = \min(d_j) \quad j=1, 2, \dots, M \quad (4)$$

⑤调整连接权 对竞争层邻域 $N_g(t)$ 内所有神经元与输入层神经元之间的连接权进行修正。

$$W_{ji}(t+1) = W_{ji}(t) + \eta(t) \cdot [P_i^k - W_{ji}(t)] \quad (j \in N_g(t), j=1, 2, \dots, M) \quad (5)$$

式中: $\eta(t)$ $(0 < \eta(t) < 1)$ 为 t 时刻的学习速率。

⑥选另一学习模式提供给网络的输入层,返回步骤③,直至 q 个模式全部提供给网络。

⑦更新学习速率 $\eta(t)$ 及邻域 $N_g(t)$ 。

$$\eta(t) = \eta(0) \cdot (1 - t/T) \quad (6)$$

式中: $\eta(0)$ 为初始学习率, t 为学习次数, T 为总的学习次数。

$$N_g(t) = \text{INT}[N_g(0)(1 - t/T)] \quad (7)$$

式中:INT $[\]$ 为取整符号, $N_g(0)$ 为 $N_g(t)$ 的初始值。

⑧令 $t=t+1$,返回步骤②,直至 $t=T$ 为止。

通过上述学习过程可将需要记忆的信息存储在连接权中,学习后的网络可按照下式进行回想:

$$\begin{cases} a_g = 1, \text{当 } d_g = \min_j^M [d_j] \\ a_i = 0, i=1, 2, \dots, M, i \neq g \end{cases} \quad (8)$$

当再有与学习模式相似的输入模式提供给网络输入层时,网络按上述方法进行“回想”,找出竞争层中连接权矢量与输入模式最接近的神经元 g ,该神经元的状态即为对输入模式的分类。

2 SOFM算法的改进

SOFM学习算法的效率往往取决于学习率、邻域半径大小的选择以及连接权值的初始值等,选择不当则不能达到快速学习的目的,甚至导致学习的失败。因此,应从改进学习率、邻域半径大小等方面来提高网络的性能。

改进点1 SOFM算法中学习率和邻域采取何种递减方式,对学习的收敛速度和聚类精度都很关键。当学习率和邻域范围以线性递减时,虽然聚类结果较好,但学习收敛慢;而以指数形式递减时,聚类结果不理想甚至导致不收敛;幂函数递减,聚类结果最好,收敛也快。本文采用下式改进学习率:

$$\eta(t+1) = \eta_0 (\alpha / \eta_0)^{t/T_1} \quad (9)$$

式中: α 为常数,一般取0.5。

改进点2 对邻域函数进行正确估计的目标是

使 SOFM 实现拓扑特性的映射,即 SOFM 阵列中各个神经元的几何距离越小则相应的权向量的欧氏距离也越小,反之亦然。合理选择邻域函数对网络权值训练有直接影响。高斯拓扑邻域比矩形或圆形拓扑邻域更合适。选择高斯拓扑邻域作为邻域函数使 SOFM 算法的收敛速度比矩形或圆形邻域更快。因此,本文采用高斯函数作为邻域函数

$$N_{ic}(t) = \exp\left[-\frac{|r_i - r_c|^2}{2\sigma^2(t)}\right] \quad (10)$$

式中: $|r_i - r_c|$ 为竞争层神经元 i 和 c 的距离,在二维网格中有:

$$|r_i - r_c| = \sqrt{(i_x - c_x)^2 + (i_y - c_y)^2} \quad (11)$$

式中: i_x, i_y 为神经元 i 在二维网格上的坐标; c_x, c_y 为神经元在二维网格上的坐标; $\sigma(t)$ 为邻域半径,采用指数衰减函数

$$\sigma(t) = \sigma_0 \times \exp(-t/T_1) \quad (12)$$

式中: σ_0 为邻域半径的初始值。

改进点 3 SOFM 网络连接权值的初始值对网络学习的正确性有很大影响,某些初始状态可能会导致网络的效率急速下降。但是目前尚无确定连接权值的理论方法,因此应当根据实际应用结合专家知识选择初始连接权值。

改进点 4 对 SOFM 网络而言,网络的学习分为粗调整和细调整 2 个阶段。粗调整阶段是大致确定输入模式在竞争层的映射位置,因此学习率应递减较快,可采用幂函数形式,邻域从较大值递减为较小值。在精细调整阶段,网络学习集中对较小范围内的神经元的连接权值进行调整,其学习率递减缓慢,可采用线性函数形式。网络的竞争层神经元的个数根据 Melssen's 1994 年建议的

$2M_n < M_e \times P$ 确定。 M_n 为竞争层神经元数目, M_e 为期望的隐含于输入数据中的分类数, P 为样本的个数。

3 砂土液化危害性等级评价

液化危害性评价是指对未经抗震设计和加固处理的已建房屋和地基基础在地震作用下可能因液化引起的破坏程度做出评价。这种评价有两种作用:

①为制定城市和重大工程防灾规划提供基础性资料或依据;②为确定某一工程的抗震措施提供依据^[8]。目前,液化等级评价的方法主要有规范规定的液化指数法、计算震陷值法及计算震陷值和谱烈度比法相结合等。

3.1 液化指数法

我国抗震规范利用液化指数法^[9]对液化危害性做出评价。规范 4.3.5 条定义了液化指数 I_{LE} 的定义如下:

$$I_{LE} = \sum_{i=1}^n \left[1 - \frac{N_i}{N_{cri}} \right] d_i W_i \quad (13)$$

式中: n 为在判别深度范围内每一个钻孔标准贯入点总数; N_i, N_{cri} 分别为 i 点标准贯入锤击数的实测值和临界值,当实测值大于临界值时应取临界值的数值; d_i 为 i 点代表的土层厚度, m , 可采用与该标准贯入试验点相邻的上、下两标准贯入试验点深度差的一半,但上界不高于地下水位深度,下界不深于液化深度。 W_i 为 i 土层单位土层厚度的层位影响权函数值, m^{-1} 。

规范规定的液化等级划分见表 1。建筑物的相应危害程度见表 2。

表 1 液化等级表

液化等级	轻 微	中 等	严 重
判别深度为 15 m 时的液化指数	$0 < I_{LE} \leq 5$	$5 < I_{LE} \leq 15$	$I_{LE} > 15$
判别深度为 20 m 时的液化指数	$0 < I_{LE} \leq 6$	$6 < I_{LE} \leq 18$	$I_{LE} > 18$

表 2 液化等级和对建筑物的相应危害程度

液化等级	地 面 喷 水 冒 砂 情 况	对 建 筑 物 的 危 害 程 度
轻 微	地面无喷水冒砂,或仅在洼地、河边有零星的喷水冒砂点	危害性小,一般不至引起明显的震害
中 等	喷水冒砂可能性大,从轻微到严重均有,多数属中等	危害性较大,可造成不均匀沉陷和开裂,有时不均匀沉陷可达 200 mm
严 重	喷水冒砂严重,地面变形很明显	危害性大,不均匀沉陷可能大于 200 mm,高重心结构可能产生不容许的倾斜

3.2 SOFM 神经网络评价砂土液化

3.2.1 评价指标和分类方案的选取

影响砂土液化动态因素很多,但大体分为:砂土特性,如土的种类、平均粒径及密实度;地质环境特征,如地下水位及土层埋深等;地震因素,如震级等。根据已有的研究资料并参考规范及研究液化作用机理,本文选取上覆土层厚度 d_s 、液化层厚度 d 、地下水位 d_w 、粘粒含量 ρ_c 、标贯击数 $N_{63.5}$ 及地震烈度 I 等 6 个指标对液化危害性进行预测。在确定评价方案时,将液化等级分为三大类: I 类为严重、II 类为中等和 III 类为轻度。

3.2.2 模型的建立和评价

将上述 6 个评价指标作为 SOFM 神经网络的输入因子,以分类方案为基准,将液化等级分为 3 级,即网络竞争层的神经元定义为 3×1 ,网络初始学习率为 0.9,最大迭代次数为 200,初始权重值赋予相同的值为 0.5,这样可以减少输入模式在最初阶段对连接权值的挑选余地,尽快校正连接权值与输入模式之间的偏差。据文献[10]中提供的砂土液化数据为训练样本,应用 Matlab6.5 中的神经网络工具箱提供的函数进行编程计算,经过 150 次迭代,误差达到 0.001(见表 3)。

表 3 基于 SOFM 网络的砂土液化势评价结果

编号	I	d_s/m	d/m	d_w/m	ρ_c	$N_{63.5}$	实测值	网络值	规范结果 I_E
1	8	2.5	7.0	0.8	0.082	4.8	I	I	32.66
2	8	3.5	6.6	0.8	0.082	6.32	I	I	21.46
3	8	10.0	0.5	1.02	0.064	5.5	III	III	1.5
4	8	2.7	3.3	0.54	0.082	7.86	II	I	4.88
5	8	3.0	4.67	0.54	0.082	8.4	II	II	6.53
6	8	5.2	5.5	1.0	0.082	6.64	I	I	19.02
7	8	6.0	2.4	1.0	0.082	6.3	III	III	8.37
8	8	2.7	3.3	0.5	0.082	9.06	III	III	0.725
9	8	6.55	1.75	1.64	0.064	6.25	II	II	6.35
10	8	2.8	8.3	1.0	0.082	6.0	I	I	29.44

由表 3 可知,在 10 个聚类样本中,只有样本 4 与实测值不相符,模型准确率达 90%,而规范液化指数法判别则有 4、7 两点误判,准确率为 80%,SOFM 网络判别结果令人满意,验证了 SOFM 神经网络应用于砂土液化评价的可行性,同时得出了输出神经元与液化等级的一一对应关系,从而建立了

SOFM 神经网络的砂土液化模型。

在输入新样本对其判别时,网络通过“回想”确定输出层的获胜单元,该单元的状态即为待判别样本的液化等级。为了验证 SOFM 神经网络砂土液化模型的智能性和泛化能力,用其余的三个样本对网络进行检验(见表 4)。

表 4 预测样本

编号	I	d_s/m	d/m	d_w/m	ρ_c	$N_{63.5}$	实测值	网络值	规范结果 I_E
11	8	5.6	4.0	1.0	0.082	4.4	II	II	18.01
12	8	6.49	3.51	1.43	0.064	3.86	I	I	16.67
13	8	3.5	6.6	0.8	0.082	6.32	I	I	21.46

由表 4 可以看出,SOFM 神经网络预测砂土液化结果与实测值完全一致,而用液化指数法判别,编号 11 的样本与实测值不一致。由此可以看出,SOFM 神经网络判别精度高于规范规定的液化指数法,其原因分析如下:

1)液化指数法是依据宏观震害现象如喷冒、沉降和不均匀沉降等统计得出的,反映的是场地土的

液化程度,没有考虑上部建筑物的作用,而地震经验表明,在烈度和场地相似的情况下,不同类型的建筑物震害情况不同。如:①砖石等刚性基础,抗弯、抗拉强度小,地震时易产生不均匀沉降、断裂、错动等,加重房屋震害;而钢筋混凝土筏形、箱形基础等柔性基础,具有较高的抗弯、抗拉性能,整体性

(下转第 102 页)

从上述数据分析,帽梁水平位移已较平稳,基坑外建筑物已趋于平稳。由于各种原因,本工程地下部分结构施工拖延时间较长,造成基坑临近建筑物沉降不断加大,时间效应对基坑及其周边环境产生了不利影响,在设计与施工中应予以充分重视。现主体结构已施工完毕,基坑使用效果良好。

5 结论

本次基坑支护设计方案综合考虑了基坑深度、轮廓、场地工程地质条件、周边环境情况等多种因素,本着安全、经济、方便施工的原则,以确保基础施工的顺利进行及业主对周边环境合理要求为原则,通过多方论证,反复优化,采用了一道连拱式支撑体系,取得了较好的效果。

收稿日期:2005-12-29

参 考 文 献

- [1] 龚晓南,高有潮主编. 深基坑工程设计施工手册[M]. 北京:中国建筑工业出版社,1998. 6.
- [2] 詹集明. 连拱形基坑支护体系——对一种新型支护体系的探讨[J], 岩土工程技术, 2000(3): 147-151; 179.
- [3] 张士乔,张仪萍,龚晓南. 基坑单支撑拱形围护结构性状分析[J], 岩土工程学报, 2001, 23(1): 99-103.
- [4] GB 50010—2002 混凝土结构设计规范[S]. 北京:中国建筑工业出版社, 2002.
- [5] YB 9258—97 建筑基坑工程技术规范[S].
- [6] JGJ 120—99 建筑基坑支护技术规程[S].

(上接第 66 页)

强,地震时仅仅发生倾斜,不易产生不均匀沉降和断裂错动,此时液化减震作用似乎更加明显。②建筑物的破坏与其自振特性、场地特性、地震特性有关,坚硬场地上刚性建筑物震害大,软弱场地上柔性结构物震害大;烈度相似的情况下,处在大震级远震中距的柔性建筑,其震害要比中、小震级近震中距的情况严重的多。③抗震设计的房屋抗震性能明显高于未经抗震设计的房屋,因此液化等级评价的标准也应该区别对待。液化指数方法考虑的仅仅是与场地、地震等有关且容易获得的指标,而有些重要而复杂因素均不涉及,故出现一定的误判概率。

2)神经网络预测方法比液化指数方法简单的多,且结论直观,通过自学习功能获得影响因素与液化等级的内在而难以公式化的关系,对预测样本可以实现快速、准确地评价。SOFM 神经网络方法为液化等级的评价提供了一条新的思路。

4 结论

利用改进的 SOFM 神经网络进行砂土液化评价,具有较高的分类能力,可以更精确地描述砂土液化的结果,克服了 BP 网络在应用时会出现训练精度高,测试效果差的缺点,使 SOFM 神经网络具有更强的泛化能力和鲁棒性。将 SOFM 神经网络用于砂土液化评价中是可行的,为砂土液化评价提供了一条新思路。

参 考 文 献

- [1] 顾晓鲁,钱鸿缙. 地基与基础[M]. 北京:中国建筑工业出版社,1996.
- [2] 陈奎,刘兴昌. 砂土地震液化的神经网络预测[J]. 西北地震学报, 2000, 22(2): 167-171.
- [3] Davis R O, Berrill J B. Energy dissipation and seismic liquefaction in sands[J]. Earthquake Engineering and Structure Dynamics, 1982, 10(1): 68-70.
- [4] 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(2): 16-24.
- [5] 陈新民,罗国煜. 地震砂土液化可能性的非确定性灰色预测法[J]. 桂林工学院学报, 1997, 17(2): 106-109.
- [6] D J Willshaw. How patterned neural connections can be set up by self-organization[J]. Proc Roy. Soc London B, 1976, 194: 431-445.
- [7] T Kohonen. Self-organized formation of topologically correct feature maps[J]. Biol, 1982, 43: 59-69.
- [8] 石兆吉,张荣祥,顾宝和. 砂土液化判别和评价综合方法研究[J]. 地震工程与工程振动, 1997, 19(1): 82-87.
- [9] GB 50011—2001 建筑抗震设计规范[S].
- [10] 任文杰. 人工神经网络在地基土液化判别及等级评价中的应用[D]. 天津:河北工业大学, 2002.

收稿日期:2006-01-11