

AFSs-RBF 神经网络模型在轻亚黏土地震液化判别中应用研究

陈 榕^{1,2}, 郝冬雪^{1,2}, 栾茂田^{*1,2}, 李学慧³

(1. 大连理工大学 海岸和近海工程国家重点实验室, 辽宁 大连 116024;
2. 大连理工大学 土木水利学院 岩土工程研究所, 辽宁 大连 116024;
3. 惠州市城乡建筑工程有限公司, 广东 惠州 516001)

摘要:以自适应模糊系统 AFSs 为基础,运用径向基高斯函数 RBF 所建立的 AFSs-RBF 神经网络模型能够同时容纳模糊系统的推理功能和自适应性,动态调节隐节点数即模糊规则数,具有广泛的适用性. 将这种模型应用于轻亚黏土地震液化评价中,选择震中距、上覆有效应力、黏粒含量、标贯击数、地下水位、循环应力比等 6 个与地震和场地条件有关的影响因子作为网络输入参数,对于轻亚黏土场地的液化势判别具体地建立了模糊神经网络模型 AFSs-RBF. 以唐山 7.8 级地震中天津某地区的轻亚黏土液化数据为训练样本,经验证和应用表明,这种 AFSs-RBF 网络具备更高的自适应性和非线性映射能力.

关键词:轻亚黏土液化势;模糊神经网络;等级判别;AFSs-RBF
中图分类号:TU435 **文献标识码:**A

0 引言

饱和松砂的地震液化问题已得到广泛的研究. 浅层饱和轻亚黏土的地震液化问题在 1976 年唐山地震中得到认识,随后我国学者对此进行了一定的专门探索.

轻亚黏土一般指塑性指数 I_p 为 3 ~ 10 的低塑性土. 在饱和状态下轻亚黏土的地震液化与地震、局部地质和土层分布、埋藏深度、土质特性等多种因素有关,这些影响因素存在着很大的不确定性,因此在液化判别中必须考虑这种不确定性. 在评判砂土液化势的非确定性方法基础上,针对含有不同程度黏粒含量的粉土或轻亚黏土的液化判别,何广纳等^[2]应用基于模糊数学的综合评判方法,针对不同的因素构造了不同等级所对应的隶属函数,以此建立了评判矩阵,并根据不同因素的权重,运用模糊数学求积算子对 $(\cdot, +)$ 进行模糊矩阵运算,进而基于评判等级的内涵,考虑了液化与非液化的总偏重,将后两部分的隶属度叠加,对粉土场地的地震液化势进行了预测. 陈国兴等^[3]引进模糊烈度概念,对规范中对于砂土和粉

土所建议的液化评判法进行了修正,从而在已知地面加速度情况下进行液化判别.

场地液化势非线性地依赖于地震烈度或震级等地震参数与 SPT 或 CPT 贯入击数、上覆有效压力、地下水位、土质特性及黏粒含量等场地参数及其他因素. 为了合理地描述液化势与地震及场地土参数之间的复杂非线性关系,人工神经网络方法等现代非线性科学方法开始在液化势评判中得到应用. 蔡煜东^[4]、Goh^[5, 6] 分别基于场地的 SPT、CPT 贯入击数实测数据,利用反向传播神经网络算法,建立了液化势评判的人工神经网络模型. 最近有研究者将遗传算法、混合遗传算法等全局优化方法与 BP 模型结合进行液化评判研究^[7, 8]. 评价效果表明:人工神经网络具有较强的自适应学习能力,适宜于场地的液化势评判. 在液化危害等级划分中需要许多规则知识,而人工神经网络往往缺乏表达规则知识的能力,从而不能有效地利用先验知识. 将模糊信息逻辑与神经网络系统相结合,既能运用定性知识,又能通过自适应学习有效地利用定量数据. 张晓晖等^[9]利

收稿日期: 2006-04-05; 修回日期: 2007-09-01.

基金项目: 国家自然科学基金资助项目(50579006); 教育部跨世纪优秀人才培养计划研究基金资助项目(教技函 1998[2]号).

作者简介: 陈 榕(1979-), 男, 博士生, E-mail: rongchen@yahoo.cn; 栾茂田^{*}(1962-), 男, 博士, 教授, 博士生导师, E-mail: mtluan@dlut.edu.cn.

用模糊神经网络,在液化危害等级划分的基础上,规则层按规定的模糊规则连接正则化层和输出层,依此构造了砂土液化势识别模型. 基于非学习样本对模型的验证表明,模糊神经网络能够有效地评判砂土液化势. 陈国兴等^[10] 同样通过径向基函数神经网络模型进行砂土地震液化分析,其通过大量实测数据给出了液化概率判别方法,使工程场地的砂土液化概率判别如同确定性砂土液化判别一样简单、方便,从而使砂土液化概率判别方法用于工程实践和纳入有关规范成为可能. Chen 等^[11] 考虑含有少量黏粒的砂土的地震分析,以自适应共振理论 (adaptive resonance theory, ART) 为基础,结合模糊系统理论,提出模糊推理类的神经网络模型 Fuzz-ART,并由此对台湾集集大地震中员林地区的液化势进行了预测. 以反向传播进行参数学习,以模糊自适应共振理论为结构学习机制,工程实例分析表明,这种模型的预测结果比传统类神经网络更为准确和有效,但是在这种模型中没有考虑液化危害等级划分,对于抗液化设计及其工程防护不能提供建设性建议.

为此,本文针对轻亚黏土地,同时容纳模糊系统的推理功能和自适应性,将自适应模糊系统 AFSs 与径向基函数 RBF 相结合,根据学习样本,动态地调节隐节点数即模糊规则数,建立 AFSs-RBF 液化评判模型.

1 基于 AFSs 的径向基高斯函数网络

1.1 网络结构

基于 AFSs 的 RBF 网络模型由前提和结论两部分构成,且每一部分都包含一个可调整的参数集. 采用下列的非线性高斯函数表示已知输入和被存储前提事件之间的映射关系^[12]

$$R_i(x) = \exp\left[-\sum_{j=1}^n \frac{|x_j - c_{ji}|^2}{2\sigma_{ji}^2}\right] = \prod_j A_{ji}(x)$$
 (1)

其中 $A_{ji}(x) = \exp\left(-\frac{|x_j - c_{ji}|^2}{2\sigma_{ji}^2}\right)$, c_i 为第 i 个规则的中心.

当结论为常值时,设共有 m 个模糊规则. 若每个规则对应 n 个输入和 p 个输出,则第 i 个规则可表述为

Rule i : if $(x_1 \text{ is } a_{1i}) \text{ and } \cdots \text{ and } (x_n \text{ is } a_{ni})$
then $(y_1 \text{ is } a_{i1}) \text{ and } \cdots \text{ and } (y_p \text{ is } a_{ip})$

式中 a_{ik} 为常数. 则通过这一等价推理结论,得到其推理输出

$$y_k = \frac{\sum_{i=1}^m R_i(x) a_{ik}}{\sum_{i=1}^m R_i(x)} = \sum_{i=1}^m \hat{R}_i(x) \quad (3)$$

图 1 给出了这种基于 AFSs 的 RBF 网络模型结构.




图 1 输出为常值的 AFSs-RBF 网络结构
Fig. 1 Structure of AFSs-RBF network for constant-value output

1.2 学习算法

AFSs-RBF 网络的学习过程即是确定最小知识规则数和调节隐层参数矢量,学习算法能使网络从样本数据中估计出未知的规则. 网络是否产生新的径向基节点,由有效半径的大小来确定. 第 i 个隐节点的有效半径 r_i 可用一个超球面 H 表达.

$$H(r_i) = \left\{ x \mid d(x, c, \sigma) = \frac{(x - c)^2}{\sigma^2} \leq r_i^2 \right\} \quad (4)$$

1.2.1 自组织学习算法 网络采用误差反向传播法,学习过程如下:

- (1) 设 $i = 1, n = 1, i$ 和 n 分别代表隐节点个数和第 n 个训练样本;
- (2) 用第 n 个训练样本估计 $|y_n - t_n|$, 这里 y_n 和 t_n 分别为第 n 个样本的网络输出值和期望值;
- (3) 如果 $|y_n - t_n| > E, E$ 为误差界,则转第(5)步,否则转第(7)步;
- (4) 如果有一个隐节点使训练样本落入超球体 H 内,则转第(5)步,否则,产生新的隐节点,转向第(6)步,新的隐节点的参数按下述方法确定: 设 $i = i + 1$; 均值向量 c_i = 训练样本的输入; 标准偏差 $\sigma_i = \sigma_{init}$;
- (5) 应用下面给出的修正方法调节参数向量;
- (6) 转第(2)步;
- (7) 等待新的数据样本,然后转第(1)步.

1.2.2 参数向量修正方法 基于训练模式,学习算法采用误差函数的负梯度下降方法,不断地

更新网络参数,第 n 个训练模式误差函数为 $E_n = \frac{1}{2} \sum_{k=1}^p (t_{nk} - y_{nk})^2$, 这里 p 为输出单元个数. 网络参数向量定义为

$$\boldsymbol{v}_i = (\boldsymbol{c}_{ji}^T \quad \boldsymbol{\sigma}_{ji}^T \quad \boldsymbol{a}_{ji}^T)^T$$

参数的更新修正规则为

$$v_i^{\text{new}} = v_i^{\text{old}} + \eta \Delta v_i = v_i^{\text{old}} - \eta \frac{\partial E_n}{\partial v_i} \tag{5}$$

其中 η 为学习速率.

在这种情况下,第 k 个元素的输出

$$y_k = \frac{\sum_{i=1}^m R_i(x) a_{ik}}{\sum_{i=1}^m R_i(x)} = \frac{u(c_{ji}, \sigma_{ji}, a_{ik})}{z(c_{ji}, \sigma_{ji})} \tag{6}$$

进一步地,可以计算误差函数 E 关于每个参数的负梯度^[9]

$$\Delta c_{ji} = - \frac{\partial E}{\partial c_{ji}} = - \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial R_i} \frac{\partial R_i}{\partial c_{ji}} = (t_k - y_k) \frac{a_{ik} - y_k}{z} R_i \frac{x_j - c_{ji}}{\sigma_{ji}^2} \tag{7}$$

$$\Delta \sigma_{ji} = - \frac{\partial E}{\partial \sigma_{ji}} = - \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial R_i} \frac{\partial R_i}{\partial \sigma_{ji}} =$$

$$(t_k - y_k) \frac{a_{ik} - y_k}{z} R_i \frac{(x_j - c_{ji})^2}{\sigma_{ji}^2} \tag{8}$$

$$\Delta a_i = - \frac{\partial E}{\partial a_{ik}} = - \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial u} \frac{\partial u}{\partial a_{ik}} = (t_k - y_k) \frac{1}{z} R_i \tag{9}$$

2 轻亚黏土液化势评判网络模型

2.1 轻亚黏土液化势影响因素的选择

与砂土液化势的影响因素分类相似,轻亚黏土液化势的影响因素一般可分成主要和次要等 2 类因素. 其中主要因素包括:(1) 地震动的特性:震级、震中距、地震烈度等;(2) 场地条件:初始应力状态、地下水位等;(3) 土质特性:土的密实性、结构性、颗粒直径和级配等. 由于影响因素较多,本文仅考虑在轻亚黏土液化评判中主要的、且易获得数据的因素. 例如,在震级相同的条件下,选择震中距、上覆有效应力、黏粒含量、标贯击数、地下水位、循环应力比等 6 个参数作为轻亚黏土液化模型的输入指标. 如表 1 所示,液化等级^[10]划分为 A、B、C、D 等 4 级.

表 1 液化势分级

Tab. 1 Classification of liquefaction potential

液化势类别	特征	由液化引起的建筑物震害
A 未液化	无喷砂(含少量黏土),也未发现沉陷	一般建筑物完好,地表也不发生明显沉陷
B 轻微液化	液化与不液化的边缘,零星喷冒,没有沉陷	液化危害性较小,一般不致引起明显的震害
C 中等液化	中等程度喷水冒砂,地面沉陷小于液化土层厚度的 2%	危害比较大,使建筑物产生小于 20 cm 的不均匀沉降
D 严重液化	喷水冒砂严重,喷量大,范围广,地裂缝较多,地表形态变化很大	危害性很大,一般可使建筑物产生 20 ~ 30 cm 的不均匀沉降,高重心建筑物可严重倾斜

训练样本和测试样本数据取自唐山 7.8 级地震中天津某地区轻亚黏土液化实测数据^[13,14],其中标贯击数为修正后的值^[15]. 本文采用下列经验算式^[16]估算场地的循环剪应力比:

$$\frac{\tau}{\sigma'_0} = 0.1 \frac{a}{g} (M - 1) \frac{\sigma_0}{\sigma'_0} (1 - 0.0015z) \tag{10}$$

式中: τ/σ'_0 为循环剪应力比; σ'_0 为上覆有效应力; a/g 为地面水平加速度峰值; M 为震级; z 为土层埋深. 表 2 列出了该地区的 6 个指标.

2.2 网络设计

网络结构如图 1 所示. 输入选择 6 个液化影

响指标;评价等级选为 4 级. 因此选择评价的最少规则数为 4,即隐层神经元初始值为 4. 输入层把 6 个指标数据传递到隐层,在隐层中一方面完成输入变量指标的模糊化处理,产生各评价指标的初始隶属度函数,另一方面完成模糊逻辑操作和条件匹配. 隐层中第 i 个规则的启动强度采用式(1)中的乘法操作运算,此处 $i = 1, 2, 3, 4$;输出为一维,经式(3)进行正则化处理. 各液化势等级所对应的神经元输出值分别如下^[7]:A 类期望输出为 0.7,实际要求输出范围为 $0.6 < y \leq 0.8$;B 类期望输出为 0.5,实际要求输出范围为 $0.4 < y$

≤ 0.6 ;C 类期望输出为 0.3,实际要求输出范围为 $0.2 < y \leq 0.4$;D 类期望输出为 0.1,实际要求输出范围为 $0 < y \leq 0.2$.

针对天津地区轻亚黏土液化的实测数据,根据经验隶属度函数确定网络初始数据中心 c_{ji} 和

扩展值 σ_{ji} 的初值^[2,16,17]. 采用上述分析方法并参考文献[18] 编程、进行具体计算. 表 2 中列出了所采用的 28 个训练样本,经训练后隐节点数即模糊规则数由 4 增加至 30,学习过程中隐节点数 h 的变化如图 2 所示.

表 2 训练样本液化影响指标因素值及模式识别结果

Tab. 2 Training sample values of the selected indexes affecting light loam liquefaction and pattern recognition results

样本代号	震中距 /km	上覆有效 应力 /kPa	黏粒 含量 /%	标贯击数	地下 水位 /m	循环剪 应力比	现场液 化等级	网络识 别结果
1	105	65.6	6.3	4.8	1	0.214	D	D
2	50	122.0	16.0	5.0	0.21	0.439	B	B
3	105	71.4	6.1	3.6	0.8	0.221	D	D
4	105	99.4	7.4	1.7	1	0.214	D	D
5	105	66.4	7.5	1.4	1	0.215	D	D
6	44	113.8	16.0	6.5	0.43	0.439	B	B
7	50	129.0	16.0	7.5	0.40	0.429	A	A
8	50	69.2	10.0	6.0	0.40	0.465	B	B
9	50	120.0	16.0	9.5	0.77	0.425	A	A
10	106	54.6	13.0	3.0	1.02	0.211	C	C
11	106	88.0	7.5	4.4	1.64	0.201	C	C
12	106	82.4	6.0	3.6	1.64	0.200	C	C
13	106	98.3	4.0	2.0	1.43	0.206	D	D
14	106	79.2	6.0	4.0	1.43	0.205	C	C
15	116	41.0	4.52	10	0.50	0.229	C	C
16	116	36.0	4.52	9	1.06	0.192	D	D
17	116	67.0	4.52	8	1.06	0.213	C	C
18	116.5	39.5	8.65	9	0.54	0.226	B	B
19	116.5	41.5	8.65	8	0.68	0.219	B	B
20	116.5	45.5	8.65	9	0.68	0.221	B	B
21	105	111.2	2.0	3	1.40	0.098	C	C
22	105	30.48	2.0	3	0.86	0.080	C	C
23	105	34.5	6.0	3.2	1	0.079	A	A
24	105	36.0	5.3	4.2	1	0.081	A	A
25	46.6	45.5	15.0	8.0	1.37	0.174	B	B
26	46.6	43.4	7.0	4.0	1	0.189	B	B
27	106	32.6	10.0	2.6	1.19	0.180	C	C
28	106	32.0	4.5	4.0	1.20	0.181	C	C




图 2 学习过程中隐节点数的变化

Fig.2 Change of unit numbers in hidden-layer during learning

3 模型验证及预测

利用学习训练的网络进行回判,检验表 2 中的学习样本,识别结果列于表 2,网络误差如图 3 所示. 由此可见,输出结果都在正确分类的范围内. 同时,选择另外 8 个非学习样本检验模型的泛化能力,测试样本数据及网络识别结果和实际结果见表 3,网络误差结果如图 4 所示. 除了样本

7 之外,其他 7 个样本的网络评判结果和实际情况完全相同. 对于测试样本 7,虽然网络识别和实际情况均为液化,但是网络识别的液化等级和实际情况具有较小的差异. 实际上,这种误差可能是由于在输入中缺少土的不均匀系数等一些重要液化参数所导致的,然而,并不是参数越多模拟效果越好^[19],必须适当地选择输入参数.




图 3 训练样本误差
Fig.3 Errors of training samples

表 3 测试样本的指标值、网络预报结果及实际结果

Tab.3 Index values of testing samples, prediction result by AFSs-RBF neural network modeling and actual results

样本代号	震中距 /km	上覆有效 应力 /kPa	黏粒 含量 /%	标贯击数	地下 水位 /m	循环剪 应力比	现场液 化等级	网络输 出结果	网络识 别结果
1	105	40.0	7.5	6.2	1.0	0.085	A	0.748	A
2	105	90.2	4.6	6.3	0.80	0.219	C	0.202	C
3	105	100.4	10.0	2.1	0.80	0.217	D	0.124	D
4	116.5	35.5	8.65	8	0.54	0.224	B	0.514	B
5	50	63.6	10.0	6	0.21	0.479	B	0.493	B
6	105	110.48	2.0	3	0.86	0.104	C	0.283	C
7	116	64.0	4.52	10	1.06	0.212	D	0.335	C
8	116	36.0	4.52	6	0.50	0.227	C	0.357	C




图 4 测试样本误差
Fig.4 Errors of testing samples

4 结 论

AFSs-RBF 网络能够通过训练样本的有监督学习动态调节规则数,在理论上比自定义规则的模糊神经网络更合理,同时在调节数据中心和扩展数据时使用了样本的输出信息或误差信息以提高学习精度;并且网络结构清晰,每层均有明确的物理意义. 实践结果表明,基于模糊系统的径向基高斯函数网络模型具有极强的自适应能力,当条件变化或样本增多时,可在新条件下重新训练以进一步提高模型效率. 同时由于模型本身的在线学习优势也带来了问题,即学习结果可能受样

本输入顺序的影响,对此应在训练样本中选用同一场地的多个样本,在训练样本总体中随机重新排列,从而提高网络评价某地区液化势的泛化能力.

参考文献:

[1] 石兆吉, 郁寿松, 王余庆, 等. 饱和轻亚黏土地基液化可能性判别[J]. 地震工程与工程振动, 1984, 4(3):71-81

[2] 何广讷, 郭 莹. 粉土液化的模糊综合评判方法[J]. 地震工程与工程振动, 1988, 8(3): 48-56

[3] 陈国兴, 张克绪, 谢君斐. 液化判别的可靠性研究[J]. 地震工程与工程振动, 1991, 11(2): 85-95

[4] 蔡煜东, 宫家文, 姚林声. 砂土液化预测的人工神经网络模型[J]. 岩土工程学报, 1993(6): 53-58

[5] GOH A T C. Seismic liquefaction potential assessed by neural networks[J]. J Geotech Eng, ASCE, 1994, 120(9): 1467-1480

[6] GOH A T C. Neural-network modeling of CPT seismic liquefaction data [J]. J Geotech and Geoenviron Eng, ASCE, 1996, 122(1): 70-73

[7] 汪明武, 李 丽, 章杨松, 等. 混合遗传算法在砂土液化势评价中的应用[J]. 合肥工业大学学报, 2002.

- 25(4): 505-509
- [8] 薛新华, 张我华, 刘红军. 基于遗传神经网络的地震砂土液化判别研究[J]. 西北地震学报, 2006, 28(1): 42-45
- [9] 张晓晖, 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(2): 209-213
- [10] 陈国兴, 李方明. 基于径向基函数神经网络模型的砂土液化概率判别方法[J]. 岩土工程学报, 2006, 28(3): 301-305
- [11] CHEN S G, HU R F, CHANG Y J, *et al.* Fuzz-ART neural networks for predicting Chi-Chi earthquake induced liquefaction in Yuan-Lin area [J]. *J Marine Sci and Technol*, 2002, 10(1): 21-31
- [12] 闻 新, 周 露. MATLAB 神经网络应用设计[M]. 北京: 科学出版社, 2000
- [13] 刘恢先. 唐山大地震震害[M]. 北京: 地震出版社, 1986
- [14] 郭 莹. 轻亚黏土液化的能量分析方法[D]. 大连: 大连理工大学, 1987
- [15] TOKIMATSU K, YOSHIMI Y. Empirical correlation of soil liquefaction based on SPT N-value and fines content [J]. *Soils and Foundations*, 1983, 23(4): 56-74
- [16] 金 富, 祁 冰, 贺可强. 轻亚黏土液化机制的动三轴特性与模糊综合评价[J]. 水文地质工程地质, 1992, 19(5): 38-41
- [17] 潘品蒸, 闫俊爱. 天津滨海区轻亚黏土地震液化研究——模糊模式识别的应用[J]. 地质灾害与防治, 1990, 1(4): 29-37
- [18] 魏海坤. 神经网络结构设计的理论与方法[M]. 北京: 国防工业出版社, 2005
- [19] URAL D N, SAKA H. Liquefaction assessment by artificial neural networks [J/BL]. *Electronic Journal of Geotechnical Engineering*. [1998-03-01]. <http://www.ejge.com/1998/Ppr9803/Ppr9803.htm>

Application of AFSs-based RBF neural network model to evaluation of earthquake-induced liquefaction potential in light loam sites

CHEN Rong^{1,2}, HAO Dong-xue^{1,2}, LUAN Mao-tian^{*1,2}, LI Xue-hui³

(1. State Key Lab. of Coastal and Offshore Eng. , Dalian Univ. of Technol. , Dalian 116024, China;

2. Inst. of Geotech. Eng. , School of Civil and Hydraul. Eng. , Dalian Univ. of Technol. , Dalian 116024, China;

3. Huizhou City & Country Constr. Eng. Co. Ltd, Huizhou 516001, China)

Abstract: The adaptive fuzzy systems (AFSs) are incorporated with the radial basic function (RBF) to develop an integrated neural network model AFSs-RBF. In this model, the number of the hidden layers or units, i. e. fuzzy rule number, can be dynamically adjusted and widely used in engineering practice. This model is applied to evaluation of earthquake-induced liquefaction potential in light loam sites. The six parameters related to earthquake and site condition which are composed of epicentral distance of earthquake, effective overburden stress, clay percentage, SPT-blow counts, water table, cyclic stress ratio are chosen to develop the AFSs-RBF neural network model with six-index input. The proposed model is applied to the classification of liquefaction potential of sites located in Tianjin area occurring in the Tangshan earthquake with the magnitude of 7.8. It is shown that such an AFSs-RBF network model is capable to offer a more rational prediction of liquefaction potentials of light loam site compared with those by conventional artificial neural network methods.

Key words: light loam liquefaction potential; fuzzy neural network; classification evaluation; AFSs-RBF