DOI:10.3969/j.issn.1001-5485.2013.05.017 2013,30(05):76-81

RBF神经网络模型在砂土液化判别中的应用研究

勾丽杰[1],刘家顺[2]
(1.辽宁省交通高等专科学校 信息系,沈阳 110122;2.辽宁工程技术大学 土木与交通学院,辽宁 阜新 123000)

摘要:以时松孝次收集的砂土液化数据为研究对象,选取黏粒含量 ρ_c、相对密实度 D_r、临界深度 d_s、竖向有效应力 σ'、地下水位 d_w、地震震级 M、最大地面水平加速度 α_{max} 和标准贯入次数 SPT-N 等8个砂土液化的主要影响因素作为RBF神经网络的输入参数,利用MATLAB7.0中的神经网络工具箱,对部分样本数据进行训练和测试。并利用建立的RBF神经网络模型分析了各因素对砂土液化的影响规律。结果表明:砂土液化判别指标随 α_{max} 的增加而增大,随SPT-N 和 d_w 的增加而减小。研究成果表明,建立的RBF网络模型完全满足砂土液化判别的精度要求,能够精确模拟输入和输出之间复杂的非线性映射关系,具有较高的预测精度,具有重要的工程应用价值。

关 键 词:砂土液化;评价指标;RBF神经网络;液化等级
中图分类号:TU478 **文献标志码**:A **文章编号**:1001-5485(2013)05-0076-06

1 研究背景

自1964年美国Alaska地震、日本新泻地震以及2008年中国汶川地震造成大量地面沉陷、建筑物破坏以来,地震引起的地基土液化、地基失效、边坡失稳等问题引起了国内外学者和工程界的高度重视。目前对地基土液化产生的原因、影响因素和液化作用机理等方面的研究取得了大量具有应用价值的研究成果[1-2],特别是对地基土液化判别的研究已经具有多种分析方法。归纳起来主要有试验分析法和经验法2类[3]。室内试验存在仪器精度不足、试验条件简化和对土体地震反应分析结果的可信度有争议等问题,导致了室内试验分析方法还无法在土体液化判别中广泛应用。经验判别方法以地震场地液化调查资料为基础,利用数理统计法[4]、模糊综合评判法[5]、灰色聚类法[6],给出判别液化的条件和标准,具有广泛应用性。由于砂土液化的影响因素包括诸如地震震级、地震烈度、持续时间、土体颗粒组成、含水量、静偏应力和地下水位等,且各影响因素与砂土液化与否并非简单的线性关系,导致砂土液化的判定十分困难,其判别结果也并不准确[7]。

人工神经网络ANN(Artificial Neural Network)克服了模式、语音识别和非结构信息处理方面的缺陷,在模式识别、智能控制、组合优化和预测等领域取得了重要进展,在解决非线性问题上具有独特的优越性。ANN可以通过大量样本的学习来抽取隐含在样本中的因果关系,从数据中提取事物特征,在信息不准确、背景知识不清楚或推理规则不明确的情况下依然能进行推理判断。

为准确描述砂土液化与各影响因素之间复杂的映射关系、提高砂土液化势评价的可靠性和准确性,本文将ANN技术引入到砂土液化评判问题中,采用函数逼近能力、数据拟合能力和收敛速度都明显优于BP网络的RBF网络,用于砂土液化势评价,建立各主要影响因素与地基土液化之间的非线性关系。即实现神经网络模型对砂土液化势的自动预估,并利用该模型建立了各因素影响趋势线,通过对该神经网络模型的建立、运行和检验,得到了各因素对砂土液化的影响规律。

2 RBF神经网络模型的原理

目前,常用的前馈型神径网络模型包括误差反向传播BP网络模型和RBF网络模型2种[8]。二者不同之处在于BP模型用于函数逼近时,采用负梯度下降法调节权值,存在着收敛速度慢和结果局部极小等缺陷。而RBF网络的作用函数则是局部的,在逼近能力、分类能力和学习速度等方面均优于BP网络模型,训练样本越多,向量维数越高,其优势越明显[9]。

收稿日期:2012-09-19;**修回日期**:2012-12-15
作者简介:勾丽杰(1983-),女,辽宁黑山人,副教授,主要从事应用数学的教学与研究工作,(电话)15802451668(电子信箱)glj_5188@yahoo.com.cn。
通讯作者:刘家顺(1986-),男,辽宁铁岭人,博士,主要从事土力学与地基基础的研究工作,(电话)13941892585(电子信箱)liujiashun@163.com。

2.1　RBF 神经网络模型

RBF 神经网络模型是一种将输入矢量扩展或者预处理到高维空间中的神经网络模型,该模型由输入层、隐层和输出层 3 层构成,其模型结构如图 1 所示。

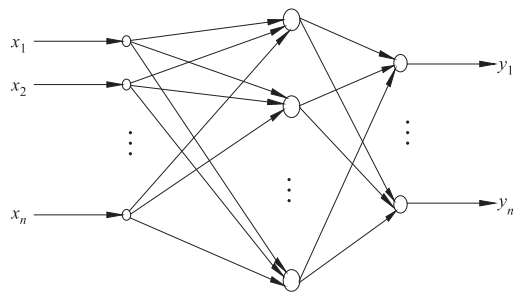


图 1　RBF 神经网络模型结构图

Fig. 1　Structure of the RBF neural network model

2.2　RBF 神经网络的核函数

输入层节点只是将输入样本信号传递到隐层,RBF 节点通常是由径向对称的辐射状核函数构成,核函数的形式主要有以下几种,如式(1)至式(3)所示:

$$f(x) = e^{(-x/\delta)^2}; \tag{1}$$

$$f(x) = \frac{1}{(\delta^2 + x^2)^{\alpha}}, \quad \alpha > 0; \tag{2}$$

$$f(x) = (\delta^2 + x^2)^{\beta}, \quad \alpha < \beta < 1。 \tag{3}$$

RBF 节点中的核函数对输入信号在局部产生响应,即当输入样本信号接近样本向量的中心范围值时,RBF 节点将产生较大的输出,这种网络具有局部逼近能力。RBF 节点作用核函数较为常用的是 Gauss 核函数,如式(4)所示:

$$\mu_j = \exp\left[-\frac{(\boldsymbol{X} - C_j)^{\mathrm{T}}(\boldsymbol{X} - C_j)}{2\sigma_j^2}\right], \quad j = 1,2,\cdots,N_h。 \tag{4}$$

式中:μ_j 为第 j 个隐层节点的输出;$\boldsymbol{X} = (x_1, x_2, \cdots, x_n)^{\mathrm{T}}$ 为输入样本信号;C_j 为 Gauss 核函数的中心值;σ_j 为标准化常数;N_h 为隐层节点数。

由式(4)可知,节点的输出范围在 0 ~ 1 之间,且输入信号越靠近节点的中心,输出的值越大。由式(4)还可以看出 Gauss 核函数具有形式简单、径向对称、光滑性好、解析性好、便于理论分析等优点。

为提高神经网路精度和减少隐层节点数,可将网络基函数改成多变量正态密度函数,见式(5)。

$$R_i(x) = \exp\left[-\frac{1}{2}(\boldsymbol{x} - \boldsymbol{c}_i)K(\boldsymbol{x} - \boldsymbol{c}_i)^{\mathrm{T}}\right]。 \tag{5}$$

式中:$K = E[(\boldsymbol{x} - \boldsymbol{c}_i)^{\mathrm{T}}(\boldsymbol{x} - \boldsymbol{c}_i)^{-1}]$ 是输入协方差阵的逆;$\boldsymbol{x}$ 为 n 维输入向量;$\boldsymbol{c}_i$ 为第 i 个基函数的中心,与 $\boldsymbol{x}$ 具有相同维数的向量。

2.3　RBF 学习过程

RBF 神经网络的输出为隐层节点(也称 RBF 节点)输出的线性组合,见式(6)所示。

$$y_i = \sum_{j=1}^{N_h} w_{ij}\mu_j - \theta = \boldsymbol{W}_i^{\mathrm{T}}\boldsymbol{U}, \quad i = 1,2,\cdots,m。 \tag{6}$$

式中:$\boldsymbol{W}_i = (w_{i1}, w_{i2}, \cdots, w_{iN_h}, -\theta)^{\mathrm{T}}$;$\boldsymbol{U} = (u_1, u_2, \cdots, u_{N_h}, 1)^{\mathrm{T}}$。

RBF 神经网络学习过程第 1 阶段为预处理阶段。采用无教师识别方法,根据输入样本的位置分布情况,决定隐层各节点的 C_j 和 σ_j,也可从样本向量中随机选取其值;第 2 阶段为学习权值阶段。预设好隐层参数后,根据最小二乘原则,求出输出层的权值 W_i。可根据样本信号,对隐层和输出层的参数进行调节,以提高网络的精度。

3　基于 RBF 神经网络模型的砂土液化预测方法

3.1　RBF 神经网络模型的建立

考虑到液化判别指标应具代表性以及现场测试的简便性,本文选取黏粒含量 ρ_c、相对密实度 D_r、临界深度 d_s、竖向有效应力 σ'、地下水位 d_w、地震震级 M、最大地面水平加速度 α_{max} 和标准贯入(简称标贯)次数 SPT-N 等 8 个砂土液化的主要影响因素作为 RBF 神经网络的输入参数。设输入层神经元数为 8,输出层神经元数为 2。利用 MATLAB 7.0 中的 NEWRB 函数自动确定所需隐层单元数并训练网络[10-11]。

3.2　RBF 网络训练目标

依据时松孝次等人的研究成果和参考行业规范[12],将砂土液化势的分类标准定为 4 级,如表 1 所示。

表 1　砂土液化分级标准

Table 1　Description of sand liquefaction levels

液化等级	产生的现象及对工程的危害	输出参数
未液化	无喷水、冒砂等现象,无危害	<0.25
临界液化	处于液化与否的临界状态	0.25 ~ 0.5
中等液化	喷水冒砂可能性较大,多数属中等程度;危害性较大,可造成不均匀沉陷和开裂	0.5 ~ 0.75
严重液化	喷水冒砂一般都很严重,地面变形明显;危害性大,一般可产生较大的不均匀沉陷,高耸结构物可能产生不允许的倾斜	0.75 ~ 1

对应训练样本,设定相应目标值,如表 2 所示。将 4 类样本的期望输出参数依次设定为:<0.25(未液化),0.25 ~ 0.5(临界液化),0.5 ~ 0.75(中等

液化),0.75 ~1(严重液化)。

3.3 RBF 神经网络模型评价

根据以上所建立的 RBF 神经网络模型,共选取 40 组时松孝次收集的砂土液化势数据[12],随机选取 25 组数据作为训练样本进行训练,选取 15 组数据作为测试样本,对所建立的 RBF 网络的正确性和智能性加以检验。RBF 网络训练结果、测试结果及判定标准见表 2 和表 3。

依据上述建立的 RBF 神经网络模型,对表 2 中数据进行训练时,迭代 213 次时,网络精度即达到 5×10^{-4},且训练结果与实际结果全部吻合,完全满足砂土液化势判别的精度要求。这说明所建立的 RBF 神经网络模型具有较好的模拟效果,能够精确模拟输入和输出之间复杂的非线性映射关系。在对另 15 组数据运用上述建立的 RBF 网络模型,进行测试时,样本点与实测结果亦完全相同。这说明 RBF 网络模型具有较强的容错性和自适应性,同时也有较高的预测精度。

表 2 时松孝次收集的砂土液化势数据及 RBF 网络训练结果

Table 2 Data of sand liquefaction potential collected by Tokimatsu Kohji and training results of RBF network

序号	M	ρ_c/%	D_r	d_w/m	d_s/m	σ'/MPa	SPT-N	α_{max}/g	液化等级	训练目标	RBF 训练结果
1	7.9	3.1	64	2.0	7.0	0.86	11.1	0.32	严重液化	(0.75,1.0)	(0.759 9,1.000 0)
2	7.9	4.0	62	1.9	6.0	0.73	20.2	0.28	严重液化	(0.75,1.0)	(0.750 0,1.000 0)
3	7.9	8.3	83	4.0	7.0	0.95	10.3	0.20	中等液化	(0.5,0.75)	(0.500 0,0.750 0)
4	7.9	12.1	83	3.0	5.0	0.75	6.7	0.20	临界液化	(0.25,0.5)	(0.249 8,0.500 0)
5	8.0	4.6	62	2.0	5.0	0.61	10.4	0.20	严重液化	(0.75,1.0)	(0.759 7,0.999 9)
6	8.0	2.9	63	2.5	3.0	0.46	2.9	0.20	严重液化	(0.75,1.0)	(0.759 9,0.999 7)
7	8.0	3.7	67	2.0	7.0	0.83	11.1	0.16	严重液化	(0.75,1.0)	(0.757 9,0.999 9)
8	7.3	13.6	83	0.8	8.0	0.72	34.7	0.35	未液化	(0,0.25)	(0.000 0,0.250 0)
9	7.3	3.4	69	1.2	4.0	0.48	11.5	0.40	严重液化	(0.75,1.0)	(0.750 0,1.000 0)
10	7.3	10.1	75	0.9	7.5	0.65	25.2	0.40	临界液化	(0.25,0.5)	(0.250 0,0.500 0)
11	7.3	5.6	61	1.0	7.0	0.73	9.8	0.16	严重液化	(0.75,1.0)	(0.751 8,0.998 7)
12	7.5	4.3	66	0.0	4.3	0.39	6.2	0.16	严重液化	(0.75,1.0)	(0.759 8,0.999 7)
13	7.5	12.8	86	1.3	6.0	0.67	33.5	0.16	未液化	(0,0.25)	(0.000 1,0.249 8)
14	7.5	5.1	64	0.6	4.5	0.47	8.7	0.16	严重液化	(0.75,1.0)	(0.750 9,0.999 9)
15	6.7	14.3	74	1.0	6.3	0.68	12.8	0.10	未液化	(0,0.25)	(0.000 2,0.248 9)
16	6.7	6.7	83	0.5	3.3	0.35	8.3	0.12	中等液化	(0.5,0.75)	(0.510 9,0.750 0)
17	6.7	11.9	87	1.3	3.3	0.42	19.7	0.12	未液化	(0,0.25)	(0.012 1,0.246 7)
18	6.7	12.3	86	0.3	4.3	0.42	15.7	0.12	未液化	(0,0.25)	(0.001 0,0.238 8)
19	7.4	5.1	63	1.0	6.3	0.68	12.8	0.20	严重液化	(0.75,1.0)	(0.752 1,0.989 9)
20	7.4	13.7	88	0.9	3.3	0.39	29.0	0.32	未液化	(0,0.25)	(0.000 2,0.247 7)
21	7.4	1.8	65	0.5	3.3	0.35	8.1	0.32	严重液化	(0.75,1.0)	(0.761 8,1.000 0)
22	7.4	5.6	74	1.3	3.3	0.42	10.0	0.32	中等液化	(0.5,0.75)	(0.520 9,0.747 8)
23	7.4	5.9	76	0.9	4.3	0.80	25.8	0.24	中等液化	(0.5,0.75)	(0.510 7,0.743 8)
24	7.4	11.9	89	2.2	5.3	0.68	24.0	0.24	未液化	(0,0.25)	(0.012 1,0.249 9)
25	7.4	12.3	79	2.5	4.5	0.65	12.6	0.24	临界液化	(0.25,0.5)	(0.255 1,0.499 3)

表 3 时松孝次收集的砂土液化势数据及 RBF 网络测试结果

Table 3 Data of sand liquefaction potential collected by Tokimatsu Kohji and testing results of RBF network

序号	M	ρ_c/%	D_r	d_w/m	d_s/m	σ'/MPa	SPT-N	α_{max}/g	液化等级	训练目标	RBF 测试结果
1	7.0	14.1	63	1.0	7.0	0.33	1.2	0.25	严重液化	(0.75,1.0)	(0.756 9,1.000 0)
2	6.1	3.7	84	1.0	14.0	1.68	3.8	0.10	未液化	(0,0.25)	(0.001 7,0.232 8)
3	8.3	4.2	62	0.0	6.0	0.54	4.9	0.15	严重液化	(0.75,1.0)	(0.756 9,0.998 1)
4	8.3	5.6	87	2.4	6.0	0.73	4.2	0.15	严重液化	(0.75,1.0)	(0.753 9,0.999 7)
5	6.6	2.1	81	3.0	6.0	0.88	6.9	0.45	严重液化	(0.75,1.0)	(0.750 0,1.000 0)
6	6.6	2.9	78	4.5	6.0	0.98	1.4	0.40	严重液化	(0.75,1.0)	(0.759 9,0.998 1)
7	7.5	3.4	79	1.5	4.6	0.29	9.9	0.14	严重液化	(0.75,1.0)	(0.758 7,0.962 5)
8	7.5	4.9	81	2.6	4.6	0.35	9.3	0.14	临界液化	(0.25,0.5)	(0.256 7,0.467 8)
9	7.5	3.8	88	3.3	7.0	0.64	12.7	0.14	未液化	(0,0.25)	(0.125 7,0.236 8)
10	7.8	9.7	84	0.5	11.0	1.30	7.0	0.20	中等液化	(0.5,0.75)	(0.567 8,0.743 3)
11	7.8	11.6	88	0.5	11.0	1.30	8.0	0.20	临界液化	(0.25,0.5)	(0.256 6,0.498 8)
12	6.6	13.8	66	1.8	4.0	0.52	43.2	0.60	未液化	(0,0.25)	(0.017 8,0.236 7)
13	6.6	1.4	65	1.8	4.0	0.52	5.6	0.60	严重液化	(0.75,1.0)	(0.756 1,1.000 0)
14	6.6	4.8	78	1.8	4.0	0.52	15.3	0.60	中等液化	(0.5,0.75)	(0.557 6,0.749 3)
15	9.6	7.3	91	0.2	5.0	0.47	10.1	0.20	中等液化	(0.5,0.75)	(0.532 7,0.721 8)

4　砂土液化的主要影响因素分析

4.1　各因素的相对贡献率分析

各因素对砂土液化的影响程度是不同的。为研究各影响因素对砂土液化判别指标的相对贡献，利用 MATLAB 7.0神经网络工具箱中的权重，计算出各因素对液化判别指标的相对贡献率[13]。

相对贡献率的计算公式为

$$C_8 = W_8/W \times 100\% \quad 。 \qquad (7)$$

式中：W_8 为各因素隐层节点与输入节点间的网络权重；W 为各因素权重之和。计算结果见表4。

表 4　各因素的相对贡献率

Table 4　Results of relative contribution of each factor

影响因素	M	ρ_c	D_r	d_w
相对贡献率/%	11.74	10.87	10.36	13.96
影响因素	d_s	σ'	SPT-N	α_{max}
相对贡献率/%	10.45	12.32	14.68	15.62

从表4 中可见，各因素对砂土液化的相对贡献率在10.36% ~15.62% 之间，说明所选取的因素对砂土液化影响显著，从而证明了 RBF 网络模型中各因素选择的正确性。进一步分析表 4 可知，α_{max} 对砂土液化的贡献率最大，SPT-N 和 d_w 对砂土液化的贡献次之。α_{max}对砂土液化贡献率大的主要原因是其越大，对土体所产生的循环剪应力越大，也就使得砂土发生液化的可能性增加。SPT-N 与 ρ_c，D_r，d_s 和 σ'等因素相互关联，而从表 4 中可以看出，这些因素与砂土液化关系密切。所以工程中很早就采用标贯击数法来判断砂土发生液化的可能性。地下水位以下的土颗粒处于悬浮状态，所以饱水砂土以上的覆盖层压力减小，从而使砂土发生液化。

4.2　各因素对砂土液化的影响规律分析

由表2 和表3 可知，采用 RBF 神经网络建立砂土液化预测模型是有效的，经过对学习样本的训练后，RBF 神经网络模型已建立了各输入参数（影响因素）与输出参数（液化判别指标）之间的非线性映射关系。为进一步研究各因素对砂土液化的影响规律，建立各参数与砂土液化判别指标之间的关系曲线。即令某一影响因素变化，其余因素取为定值，形成若干组输入向量，并将其输入已训练完的 RBF 神经网络模型，得到该影响因素与砂土液化判别指标之间的关系曲线，称之为因素影响趋势线[13]。

由上文分析可知，SPT-N 与 ρ_c，D_r，d_s 和 σ'等因素相互关联，为简化分析计算，本文利用所建立的 RBF 神经网络模型探讨了 α_{max}，SPT-N 和 d_w 对砂土液化判别指标的影响规律。用训练好的网络模型得到砂土液化判别指标和上述 3 因素之间的关系，见图 2 至图 4 所示。

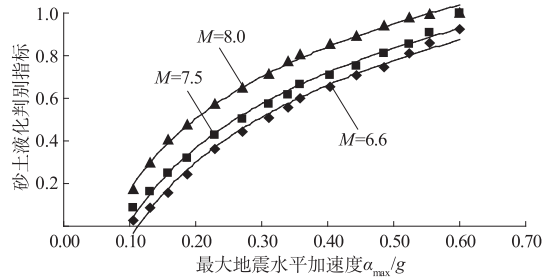


图 2　最大地面水平加速度 α_{max} 与砂土液化判别指标的关系

Fig. 2　Relation between maximum horizontal ground acceleration α_{max} and evaluation index of sand liquefaction

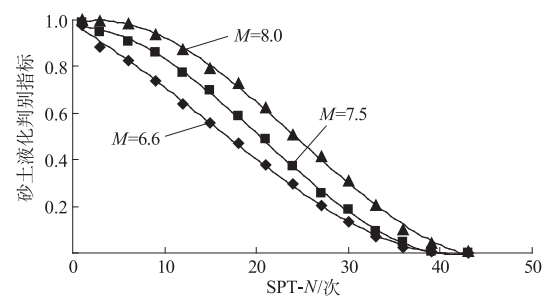


图 3　标贯击数 SPT-N 与砂土液化判别指标的关系

Fig. 3　Relation between standard penetration number SPT-N and evaluation index of sand liquefaction

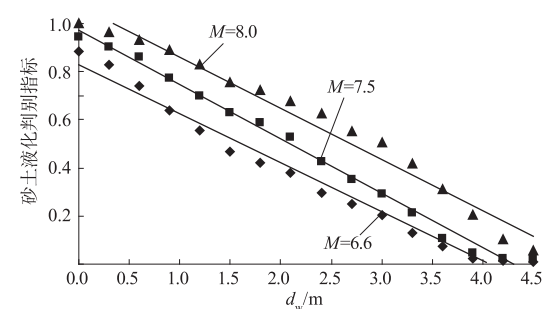


图 4　地下水位 d_w 与砂土液化判别指标的关系

Fig. 4　Relation between groundwater level d_w and evaluation index of sand liquefaction

从图 2 中可以看出，砂土液化判别指标随 α_{max} 的增加而增大，进一步分析图像可发现，最大地面水平加速度（α_{max}）与砂土液化判别指标近似呈对数函数关系增长，拟合参数见表 5。

图 3 为标贯击数 SPT-N 与砂土液化判别指标的关系曲线。标贯击数 SPT-N 越大说明土体越密实，也就越难液化，砂土液化判别指标就越小。通过数据拟合可知，二者近似呈 3 次多项式函数关系，拟合参数见表 5。

从图 4 可以看出，砂土液化判别指标随地下水位 d_w 的增加而减小，且二者呈简单的线性关系，拟合参数见表 5。

表 5 液化判别指标与 α_{max},SPT-N 和 d_w 的拟合系数

Table 5 Fitting coefficients between evaluation index and α_{max}, SPT-N, d_w respectively

指标	拟合函数	M	A	B	C	D	R^2
α_{max}	$y = A\ln(\alpha_{max}) + B$	6.6	0.522 3	1.140 1			0.991 9
		7.5	0.509 1	1.187 1			0.991 1
		8.0	0.485 8	1.285 7			0.997 1
SPT-N	$y = AN^3 + BN^2 + CN + D$	6.6	1×10^{-5}	−0.000 6	0.022 1	0.980 4	0.999 1
		7.5	3×10^{-5}	−0.001 8	0.001 0	0.970 7	0.999 2
		8.0	2×10^{-5}	0.001 8	0.009 6	0.984 9	0.997 7
d_w	$y = AN + B$	6.6	−0.068 0	0.912 9			0.987 7
		7.5	−0.074 2	1.057 6			0.995 8
		8.0	−0.065 6	1.132 1			0.968 9

上述结果符合最大地面水平加速度 α_{max},SPT-N 和 d_w 等因素对砂土液化判别指标影响的研究结果,能够反映各上述 3 因素对砂土液化的影响规律。

5 结 论

以时松孝次砂土液化势数据为研究对象,建立砂土液化预测的 RBF 神经网络模型,分析各因素对砂土液化的影响,主要结论如下:

(1) 根据时松孝次收集的砂土液化势数据,随机选取 25 组数据作为训练样本进行训练,选取 15 组数据作为测试样本,对所建立的 RBF 网络的正确性和智能性加以检验。样本训练结果表明:所建立的 RBF 网络模型训练结果与实际结果全部吻合,完全满足砂土液化势判别的精度要求,能够精确模拟输入和输出之间复杂的非线性映射关系。样本测试结果表明:RBF 网络模型具有较强的容错性和自适应性,同时也有较高的预测精度。

(2) 利用 MATLAB7.0 工具,研究了各影响因素对砂土液化判别指标的相对贡献,计算出各因素对液化判别指标的相对贡献率。计算结果表明:各影响因素对砂土液化的相对贡献率在10.36% ~ 15.62%之间,α_{max} 对砂土液化的贡献率最大,标贯击数 SPT-N 和地下水位 d_w 对砂土液化的贡献次之。

(3) 利用所建立的 RBF 网络模型探讨了地震水平最大加速度 α_{max}、标贯击数 SPT-N 和地下水位 d_w 对砂土液化判别指标的影响规律。结果表明:砂土液化判别指标与 α_{max} 呈对数关系增加,与标贯击数 SPT-N 呈 3 次多项式函数关系降低,随地下水位 d_w 的增加呈简单的负线性关系。

参考文献:

[1] RAHMAN M S, WANG Jun. Fuzzy Neural Network Models for Liquefaction Prediction[J]. Soil Dynamics and Earthquake Engineering, 2002, 22(8):685 – 694.

[2] BAZIAR M H, JAFARIAN Y. Assessment of Liquefaction Triggering Using Strain Energy Concept and ANN Model Capacity Energy[J]. Soil Dynamics and Earthquake Engineering, 2007, 27(12): 1056 – 1072.

[3] 李方明. 人工神经网络在砂土液化判别及震陷预估中的应用[D]. 南京:南京工业大学,2005. (LI Fang-ming. Application of Artificial Neural Network in the Estimation of Sand Liquefaction and the Prediction of Earthquake-Induced Ground Settlement[D]. Nanjing: Nanjing University of Technology, 2005. (in Chinese))

[4] CETIN K O, SEED R B, KIUREGHIAN A D, *et al*. Standard Penetration Test-Based Probabilistic and Deterministic Assessment of Seismic Soil Liquefaction Potential [J]. Journal of Geotechnical and Geoenvironmental Engineering, ASCE, 2004, (12): 1313 – 1340.

[5] 季倩倩. 砂土地震液化的优化判别[J]. 岩土工程技术, 2001, (3): 155 – 159. (JI Qian-qian. Fuzzy Evaluation for Seismic Liquefaction Discrimination of Sands [J] Geotechnical Engineering Technique, 2001, (3): 155 – 159. (in Chinese))

[6] 赵艳林,杨绿峰,吴敏哲. 砂土液化的灰色综合评判[J]. 自然灾害学报,2000, 9(1): 72 – 79. (ZHAO Yan-lin, YANG Lv-feng, WU Min-zhe. Grey Synthetical Evaluation of Liquefaction of Sands[J]. Journal of Natural Disasters, 2000, 9(1): 72 – 79. (in Chinese))

[7] HANNA A M, DERIN U, SAYGILI G. Neural Network Model for Liquefaction Potential in Soil Deposits Using Turkey and Taiwan Earthquake Data[J]. Soil Dynamics and Earthquake Engineering, 2007, 27(6): 521 – 540.

[8] 张德丰. MATLAB/Simulink 建模与仿真实例精讲[M]. 北京:机械工业出版社, 2010. (ZHANG De-feng. MATLAB/Simulink Modeling and Simulation Examples[M]. Beijing: China Machine Press, 2010. (in Chinese))

[9] 周瑞林,刘 燕,赵胜利. 基于 RBF 神经网络的砂土液化预测[J]. 河南大学学报 (自然科学版), 2005, 35(4):101 – 105. (ZHOU Rui-lin, LIU Yan, ZHAO Sheng-li. Application of RBF Neural Network to Prediction of Sands Liquefaction Potential[J]. Journal of Henan University (Natural Science), 2005, 35(4):101 – 105. (in Chinese))

[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 – 306. (CHEN Guo-xing, LI Fang-ming. Probabilistic Estimation of Sand Liquefaction Based on Neural Network Model of Radial Basis Function[J]. Chinese Journal of Geotechnical Engineering, 2006, 28(3):301 – 306. (in Chinese))

[11] 李菊凤, 宁立波,周建伟,等. 基于 RBF 神经网络的软基沉降预测研究[J]. 湖南科技大学学报(自然科学版), 2005, 20(3):49 – 53. (LI Ju-feng, NING Li-bo, ZHOU Jian-wei, *et al*. Research of Settlement Prediction of Soft Foundation Based on RBF Neural Networks[J]. Journal of Hunan University of Science & Technology (Natural Science Edition), 2005, 20(3): 49 – 53. (in Chinese))

[12] TOKIMATSU KOHJI. Empirical Correlation of Soil Liquefaction Based on SPT *N*-Value and Fines Content[J]. Soils and Foundation,1983, 23(4): 56 – 74.

[13] 陈国兴,李方明. 基于 RBF 神经网络模型的砂土液化震陷预估法[J]. 自然灾害学报, 2008,17(1):180 – 186. (CHEN Guo-xing, LI Fang-ming. Seismic Settlement Estimation of Sand Liquefaction Based on RBF Neural Network Model[J]. Journal of Natural Disasters, 2008, 17(1): 180 – 186. (in Chinese))

(编辑:姜小兰)

Application of RBF Neural Network Model to Evaluating Sand Liquefaction

GOU Li-jie[1], LIU Jia-shun[2]

(1. Department of Information, Liaoning Provincial College of Communications, Shenyang 110122, China;
2. School of Civil Engineering and Transportation, Liaoning Technical University, Fuxin 123000, China)

Abstract: The neural network toolbox of MATLAB7.0 was used to train and test some sample data of sand liquefaction collected by Tokimatsu Kohji. Eight eigenvectors: clay content (ρ_c), relative compaction(D_r), critical depth of soil layer(d_s), vertical effective stress(σ'), groundwater level(d_w), magnitude of earthquake(M), maximum horizontal ground acceleration(α_{max}) and standard penetration number(SPT-N) were selected as input parameters of the RBF neural network. Furthermore, the established RBF neural network model was used to analyze the effect of each factor on the sand liquefaction. Results of the relative contribution of each factor showed that α_{max} was the biggest influencing factor on the evaluation index of sand liquefaction, followed by SPT-N and d_w. The evaluation index increased with the rise of α_{max}, while reduced with the increase of SPT-N and d_w. The evaluation index shows a logarithmic relation with α_{max}, cubic polynomial relation with SPT-N, and a negative linear relation with d_w. It's revealed that the established RBF network model fully meets the requirement of evaluation accuracy for sand liquefaction. It can simulate the complex nonlinear mapping relation between the input and output data and also gives high prediction precision.

Key words: sand liquefaction; evaluation index; RBF neural network; liquefaction level

《长江科学院院报》荣获“第八届湖北省优秀期刊奖”及“第四届湖北省优秀期刊编辑奖”

2013 年 3 月 22 日,湖北省新闻出版局在武昌省政协委员之家主持召开了全省报刊管理工作会议暨优秀期刊、优秀期刊编辑表彰大会,《长江科学院院报》编辑部姜小兰主任参加了大会。

会上表彰了“第四届湖北十大名刊奖”、“第八届湖北省优秀期刊奖”和“第四届湖北省优秀期刊编辑奖”等奖项。《长江科学院院报》荣获“第八届湖北省优秀期刊奖”,同时《长江科学院院报》刘运飞同志荣获“第四届湖北省优秀期刊编辑奖”。

湖北省新闻出版局和湖北省期刊协会联合举办的本次评奖活动,是为了总结经验,表彰先进,扎实推进湖北省期刊业的繁荣与发展。此次各奖项的产生经过了省期刊协会专业委员会初评、专家组复评和省评选领导小组审定、无记名投票和《湖北日报》公示等阶段。

(摘自:长江水利科技网)