

文章编号: 1004- 4574(2009) 03- 0111- 06

基于混沌优化神经网络的砂土液化预测模型

谭钦文^{1,2}, 尹光志², 魏作安²

(1. 西南科技大学 环境及资源科学学院, 四川 绵阳 621010 2 重庆大学 资源及环境科学学院, 重庆 400044)

摘 要: 针对砂土液化预测的非线性难题, 在分析 BP神经网络和混沌优化的各自优缺点的基础上, 将混沌优化与梯度下降法相结合, 构成了神经网络权值和阈值的一种新的组合优化算法 (COBP), 并将该组合优化算法用于砂土液化的预测建模。工程实例应用表明, 该组合优化模型不仅搜索速度快, 全局稳定性好, 而且预测精度高, 结果可靠, 能达到工程应用的精度要求, 为砂土液化的非线性预测提供了一种有效方法。

关键词: 优化模型; 砂土液化预测; 混沌优化; BP神经网络

中图分类号: P694

文献标识码: A

Prediction model of sand liquefaction based on chaos optimization neural networks

TAN Qin-wen^{1,2}, YIN Guang-zhi², WEI Zuo-an²

(1. College of Resource and Environmental Southwest of Science & Technology University, Mianyang 621010 China

2. College of Resources and Environmental Sciences, Chongqing University, Chongqing 400044 China)

Abstract Based on the research of BP neural network and chaos optimization algorithm, a new hybrid optimization model is presented. This model integrates chaos optimization algorithm with BP algorithm, which not only has a BP algorithm's quick local search capability but also can converge strongly to the global optimal result by using the chaos optimization's global search character. The integrated optimization model is applied to predict sand liquefaction in practice. The results show that it is an effective and feasible method to predict sand liquefaction and can quickly converge to the global optimal result.

Key words optimization model; sand liquefaction prediction; chaos optimization; BP neural networks

场地砂土液化会引起地基承载力降低甚至丧失, 导致地面大面积变形、滑坡、侧移、冒水喷砂, 给人民生命财产带来巨大损失^[1]。因此, 砂土地震液化预测作为地震工程、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, 具有重要的现实意义。

由于影响砂土液化的众多因素呈高度的非线性, 工程中采用的经验公式法、Seed简化分析法、概率与统计方法等判别方法大多存在预测精度和可信度不高的问题^[1,2]。近年发展起来的 BP (Error Back-Propagation, 即误差反传) 神经网络在处理连续的非线性问题具有高度的智能学习、鲁棒性和系统建模能力, 可克服上述传统方法存在的问题, 在砂土液化预测中得到了广泛的应用^[1-3]。

但 BP神经网络用于砂土液化预测时, 其学习过程收敛速度慢且易陷入局部极小。而利用混沌运动“遍

收稿日期: 2008- 11- 23 修订日期: 2009- 04- 16

基金项目: 国家自然科学基金重点资助项目 (50374084), 西南科技大学博士基金项目 (08zx7119)

作者简介: 谭钦文 (1976-), 男, 讲师, 博士, 主要从事矿业灾害预测及控制研究。E-mail: tanqinwen@126.com

历性”形成的混沌优化 (chaos optimization, CO)搜索过程不受能量障碍的限制,可有效避免优化过程陷入局部极小解,已成为一种新颖的全局优化工具,受到广泛重视和大量研究^[4-6]。

因此,本研究在砂土地震液化预测的建模过程中,将利用 BP梯度下降算法与混沌优化的互补性,构造一种组合优化算法。该组合优化算法可克服 BP算法的不足,实现神经网络学习过程的快速全局优化,从而提高神经网络模型对砂土地震液化的预测精度和泛化能力。

1 BP神经网络算法

BP网络作为神经网络的精华,是工程中应用最广泛的神经网络。BP网络使用 BP梯度下降法,以极小化二次性能指标函数(如式(1))进行优化学习,学习过程由信号的正向传播和误差的逆向传播两个过程组成。图1为三层BP网络结构^[7,8]。

$$E = \frac{1}{2} \sum_{s=1}^L \sum_{j=1}^m (Y_{js} - Y_{js}^{\#})^2, \tag{1}$$

式中: L 为训练样本数, Y_{js} 为第 s 个样本第 j 输出节点的计算值, $Y_{js}^{\#}$ 为第 s 个样本第 j 个节点的期望值。

BP算法局部搜索能力很强,但全局稳定性差、收敛速度慢,且易陷入局部极小。

2 混沌优化算法

混沌优化是利用混沌运动的遍历性特点而建立的一种新型全局优化搜索算法^[5,6]。基本思想是将混沌状态引入到优化变量中,用类似载波的方法把混沌运动的遍历范围扩大到优化变量的取值范围,利用混沌变量进行搜索。

混沌优化属于非导数优化方法,可克服导数优化方法对梯度信息高度依赖性的缺点;它直接按混沌运动的“规律性”在一定范围内遍历求解,全局寻优能力很强。但研究表明,基本混沌优化算法按自身规律“遍历搜索”,其有些状态需要较长时间才能达到,局部搜索能力有限。

3 混沌优化与神经网络相结合的组合优化预测模型 (COBP)

3.1 COBP优化模型的基本思想

其基本思想是:以混沌优化与BP算法优缺点的互补性和局部极值有限性为前提,按照取长补短、相互提高的改进思路,将二者结合,利用混沌优化全局遍历性特点,引导搜索过程实现优化问题有限极值区间的遍历性自由跳转,而调用BP算法实现每一局部区间的快速极值寻优,并用最优保存策略使算法收敛到全局最优。组合优化模型算法流程如图2所示。

3.2 COBP模型的算法实现

3.2.1 COBP模型结构的确定

网络结构的设计对于整个神经网络性能具有很大影响^[7-8]。1989年 Robert Hecht-Nielsen证明了具有一个隐层的3层BP网络可以有效的逼近任意连续函数。故本研究以3层网络构造COBP预测模型。

输入层结点数则根据研究问题的影响因素和实际输入维数确定。结合第4.1节中的影响砂土液化影响因素和收集数据的构成情况可知,砂土液化主要影响因素为8个,即实际的输入维数为8,故输入层结点数最终确定为8,即输入结点数为8。

输出层结点数根据预测问题的分类情况确定,由于本研究将预测结果将用[0,1]之间的取值大小进行度量,越接近0液化程度越小,越接近1液化程度越大,所以输出结点为1。

隐层结点数则以经验公式(2)为基础,经试算得最优值为20。

$$H = m + n + a, \tag{2}$$

式中, H 为隐层结点数; m 为输出层结点数; n 为输入层结点数; a 为1~10之间常数。




图 1 3层 BP网络拓扑结构

Fig 1 Topologic structure of BP neural network

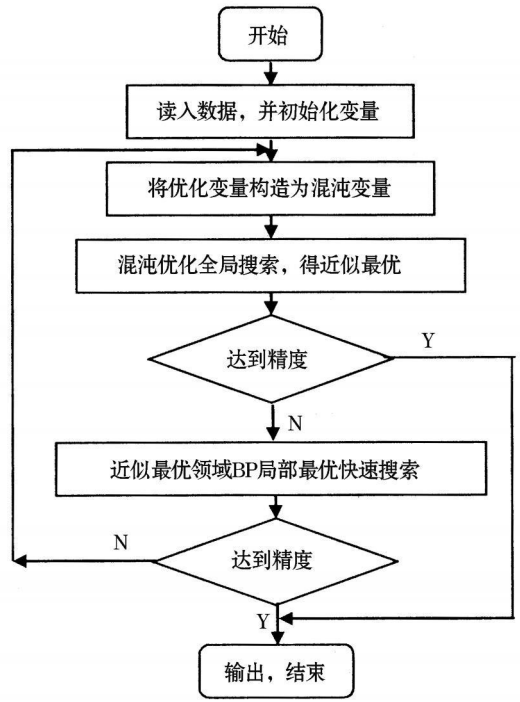


图 2 COBP算法的基本流程

Fig 2 Basic flow of COBP algorithm

建模时考虑到网络的实际输出取值在 [0 1]之间, 故输出层和隐层分别采用图 3(a)和图 3(b)所示 S型函数为激活函数。

3.2.2 BP算法的改进

为进一步提高 COBP模型中 BP算法局部搜索速度和稳定性: 一方面在训练中采用学习速度自适应调节机制, 增加稳定性, 提高速度和精度; 另一方面引入动量因子提高算法的收敛性。

3.2.3 混沌优化算法改造

(1)混沌优化系统的选择

研究表明^[4,5], 当控制参量 $\mu=4$ 时, Logistic映射为 [0 1]区间的满映射, 且系统处于完全的混沌状态。给定初始值 X_0 , 可以产生遍历 [0 1]区间的一系列混沌变量 $\{X_n\}$ 。将 $\{X_n\}$ 按载波方式赋予网络的权值和阈值可实现优化。故 COBP模型中采用式(3)所示 logistic映射进行网络模型权值和阈值混沌优化搜索。

$$X_{n+1} = 4 \cdot X_n(1 - X_n), \quad n = 0, 1, 2, \dots, 0 \leq X_n \leq 1 \quad (3)$$


(2)对基本混沌优化算法的改造

由于 COBP模型中, 混沌优化只是作为引导搜索过程实现局部极值区间自由跳转的运行机制, 故只进行第一阶段 N步混沌搜索, 无需进行二次载波。另, 混沌运动的“轨道”特性^[4]决定了它不能自动实现周期与非周期轨道自由跳转。而基本混沌优化中不能初始化为不动点的限制将使整个搜索过程都不能进入周期轨道中进行搜索, 当全局最优取值恰好落在周期轨道对应状态值时, 搜索过程将不能得到全局最优。

为克服上述缺陷, 本 COBP模型采用了互为起点的学习流程(图 2)。该流程不但可以利用 CO帮助 BP实现各局部极值区间的自由跳转, 而且可以利用 BP算法改变混沌优化的运动轨道实现周期与非周期轨道的自由跳转。既克服了单纯 BP算法易陷入局部最小的不足, 也克服了基本混沌优化局部搜索能力有限和有时不能搜索到全局最优的缺点。

3.2.4 COBP模型的计算公式

如设输入结点为: $X_i, i = 1, 2, \dots, 8$ 隐层结点为: $S_h, h = 1, 2, \dots, 20$ 输出层结点为: $Y_j, j = 1$, 希望输出为: $Y_j^d, j = 1$; 输入到隐层的权值为: W_{hi} ; 隐层到输出层权值为: V_{jh} ; 隐层结点阈值为: θ_h ; 输出层结点阈值为: θ_j ;



(a)阈值 0~1

(b)阈值 1~-1

图 3 BP神经网络的 S型激活函数

Fig 3 S-type activation functions of BP neural networks

输出层结点的误差为: E 。则 COBP 模型的计算公式见式 (4) ~ 式 (6)。

$$\text{隐层结点的输出式为} \quad S_h = f\left(\sum_{i=1}^n W_{hi} X_i - \theta_h\right) = f(N_h), \quad (4)$$

$$\text{输出层结点的输出式为} \quad Y_j = f\left(\sum_{h=1}^m V_{jh} S_h - \gamma_j\right) = N_j, \quad (5)$$

$$\text{输出层结点的误差为} \quad E = \frac{1}{2} \sum_{s=1}^L \sum_{j=1}^m (Y_{js} - Y_{js}^{\#})^2, \quad (6)$$

式中, $N_h = \sum_{i=1}^n W_{hi} X_i - \theta_h$; $N_j = \sum_{h=1}^m V_{jh} S_h - \gamma_j$; L 为样本数目, $f(x)$ 为 S 型传递函数。

3 2 5 COBP 模型的实现过程

再设权值和阈值相应载波矩阵为 \bar{W}_{hi} ; \bar{V}_{jh} ; $\bar{\theta}_h$ 和 $\bar{\gamma}_j$; 设变量 E^* , W_{hi}^* , V_{jh}^* , θ_h^* 和 γ_j^* 用于存贮当前最优。则 COBP 模型计算过程如下:

(1) 提供学习样本: 包括 L 个样本对 (X_p, Y_p) , 输入向量 $X_p = (x_{p1}, x_{p2}, \dots, x_{pn})$, 输出向量 $Y_p = (y_{p1}, y_{p2}, \dots, y_{pm})$, n, m 为输入、输出结点数 $p = 1, 2, \dots, L$ 。

(2) 算法初始化: 设置网络结构, 取 $[0, 1]$ 间微小差异的随机数初始化载波矩阵, 记为 $\bar{W}_{hi}^0, \bar{V}_{jh}^0, \bar{\theta}_h^0$ 和 $\bar{\gamma}_j^0$; 用式 (7) 将其变换初始化当前最优权值和阈值, 记为 $W_{hi}^*, V_{jh}^*, \theta_h^*$ 和 γ_j^* ; 根据学习样本用公式 (4) - (6) 计算 S_h, Y_j 和 E , 并用 E 初始化 E^* ; 令 $k = 1, k' = 1$, 并初始化误差准则 e 和最大混沌迭代次数 m_0 。

$$\begin{cases} W_{hi} = 200\bar{W}_{hi} - 100; & V_{jh} = 200\bar{V}_{jh} - 100 \\ \theta_h = 200\bar{\theta}_h - 100; & \gamma_j = 200\bar{\gamma}_j - 100 \end{cases} \quad (7)$$

其中: 系数为权值和阈值区间为 $[-100, 100]$ 所得。

(3) 进行混沌优化学习: 用 new 标记此次混沌搜索是否更新最优, 赋初值 $\text{new} = 0$ 。

步骤 1 将混沌变量 $\bar{W}_{hi}^i, \bar{V}_{jh}^i, \bar{\theta}_h^i$ 和 Z_j^i 用式 (3) 进行一次混沌变换得 $\bar{W}_{hi}^{i+1}, \bar{V}_{jh}^{i+1}, \bar{\theta}_h^{i+1}$ 和 $\bar{\gamma}_j^{i+1}$, 并用式 (7) 变换后作为新的权值和阈值, 记为 $W_{hi}^{i+1}, V_{jh}^{i+1}, \theta_h^{i+1}$ 和 γ_j^{i+1} 。

步骤 2 根据学习样本, 按照公式 (4) - (6) 分别计算 S_h, Y_j 和 E 。

步骤 3 $\text{if } E^* > E$ then 保存此次搜索结果为当前最优, 即 $E^* = E, W_{hi}^* = W_{hi}^{i+1}, V_{jh}^* = V_{jh}^{i+1}, \theta_h^* = \theta_h^{i+1}, \gamma_j^* = \gamma_j^{i+1}, \text{new} = 1$; else 放弃本次搜索结果, 转步骤 4。

步骤 4 $k = k + 1$, 并判断, $\text{if } E^* \leq e$ then 已得到全局最优, 转下面第 (6) 步结束学习过程。else $\text{if } k > m_0$ then 转下面第 (4) 步, 进行 BP 学习; else 转步骤 1, 继续混沌搜索。

(4) 根据混沌搜索结果, 进行 BP 学习:

$\text{if new} = 1$ then 以 $E^*, W_{hi}^*, V_{jh}^*, \theta_h^*$ 和 γ_j^* 为起点, 进行 BP 优化学习; else 以混沌搜索最后一步 $W_{hi}^{i+1}, V_{jh}^{i+1}, \theta_h^{i+1}$ 和 γ_j^{i+1} 为起点, 进行 BP 优化学习。

并将 BP 算法学习结果与当前最优 $W_{hi}^*, V_{jh}^*, \theta_h^*$ 和 γ_j^* 进行比较, $\text{if } E < E^*$, then 用学习结果对其更新, else 放弃。转下面第 (5) 步。

(5) $\text{if } E^* \leq e$, then 转下面第 (6) 步; else 将此次 BP 算法优化结果用式 (8) 进行反载波, 并赋值给混沌优化载波混沌变量 $\bar{W}_{hi}^i, \bar{V}_{jh}^i, \bar{\theta}_h^i$ 和 $\bar{\gamma}_j^i$, 返回上面第 (3) 步再次混沌优化。

$$\begin{cases} \bar{W}_{hi} = \frac{W_{hi} + 100}{200}; & \bar{V}_{jh} = \frac{V_{jh} + 100}{200}; \\ \bar{\theta}_h = \frac{\theta_h + 100}{200}; & \bar{\gamma}_j = \frac{\gamma_j + 100}{200}. \end{cases} \quad (8)$$

(6) 输出优化结果, 结束学习过程。

4 基于 COBP 算法的砂土液化预测模型的应用

如前所述, BP 神经网络在砂土液化预测中已经得到了广泛的应用, 针对其在运用过程中呈现的学习收敛速度慢和易陷入局部极小等问题, 文献 [3] 等通过引入学习自适应和动量因子等方法进行改进取得了较好效果。但该改进思路明显存在的局限性也很显然的。本模型的构造则在此基础上, 从相互结合, 取长补短的思路进行改进。为了检验 COBP 模型的有效性, 依据砂土地震液影响因素及发生条件, 以文献 [3] 收集到

的国内外砂土液化实例为基础,以 Matlab7.0 为平台进行仿真,并用文献 [3] 中的改进 BP 算法进行对比。

4.1 COBP神经网络优化模型结构的确定

从影响砂土液化的因素中选取具有代表性的烈度 I 、震中距 L 、平均粒径 d_{50} 、不均匀系数 C_u 、地下水 d_w 、砂层埋深 d_s 、标贯击数 $N_{63.5}$ 、剪应力比 τ_d/σ'_v 等 8 个实测指标对砂土液化进行预测^[2,3]。因此,网络层数为 3, 激发函数用 S 型函数, 输入层节点数为 8 代表 8 个实测变量, 输出层节点数为 1, 用 0 表示液化, 1 表示非液化; 经试算取隐层节点数为 20。

4.2 COBP模型仿真及精度评价

将收集整理的 25 组合理数据砂土液化实例作为样本总体 (见表 1)^[3], 并对其进行标准化和归一化处理, 使其限制在 [0, 1] 区间。然后, 用前 18 个训练网络模型; 用后 7 个检验模型的有效性。

表 1 砂土液化预测模型样本表^[3]

Table 1 samples of sand liquefaction prediction model

序号	烈度 $I/度$	震中距 L/km	地下水 d_w/m	埋深 d_s/m	标贯击数 $N_{63.5}$	平均粒径 d_{50}	不均匀系数 C_u	剪应力比 τ_d/σ'_v	实测值
1	7	76.8	0.5	1.70	3	0.166	1.65	0.10	0
2	7	82.2	1.10	6.30	9	0.14	2.80	0.11	0
3	7	91.0	0.70	2.30	1	0.07	4.00	0.10	0
4	7	68.6	1.09	4.15	5	0.41	2.90	0.10	0
5	7	92.0	0.60	1.80	2	0.22	2.20	0.10	0
6	7	71.0	0.85	1.80	2	0.145	8.50	0.089	0
7	7	78.6	0.76	3.90	5	0.09	3.77	0.11	0
8	7	80.2	1.40	2.30	2	0.19	1.90	0.80	0
9	7	71.0	1.60	2.10	8	0.19	2.16	0.07	0
10	8	116.6	1.12	9.22	12	0.105	2.00	0.225	0
11	8	117.4	3.20	7.20	8	0.134	2.23	0.172	0
12	8	44.2	3.10	4.30	15	0.25	2.38	0.147	1
13	8	25.0	3.10	9.30	51	0.32	2.46	0.184	1
14	8	116.8	3.00	5.10	9	0.20	2.38	0.159	0
15	8	47.0	2.00	3.46	8	0.31	2.42	0.163	1
16	9	14.0	4.90	9.38	61	0.16	2.25	0.318	1
17	9	11.0	4.50	4.50	22	0.16	2.76	0.248	1
18	9	14.0	5.00	13.52	64	0.13	2.00	0.34	1
19	7	81.2	1.25	1.80	4	0.11	2.00	0.08	0
20	7	81.8	1.25	4.30	7	0.17	2.00	0.10	0
21	7	80.8	1.10	3.30	7	0.17	1.70	0.10	0
22	7	81.0	1.20	2.30	6	0.16	1.89	0.09	0
23	8	70.9	2.30	12.3	13	0.30	2.43	0.203	1
24	8	38.7	1.10	1.30	15	0.18	2.76	0.14	1
25	9	9.60	3.50	8.35	31	0.21	3.15	0.347	1

(1) 模型仿真训练精度评价

利用预处理后的学习样本对 COBP 模型进行学习训练, 并同时与文献 [3] 的 BP 法预测结果比较, 结果见表 2。

表 2 COBP 模型与 BP 网络训练学习结果表

Table 2 Training results of COBP model and BP neural network

样号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
实测	0	0	0	0	0	0	0	0	0	0	0	1	1	0	1	1	1	1
BP 法	0.0356	0.0473	0.034	0.0313	0.0651	0.0034	0.0672	0.001	0.0264	0.0034	0.0177	0.9387	0.9954	0.0173	0.9459	0.9951	0.9712	0.9986
COBP	0	0	0	0.0021	0	0.0006	0	0.0009	0	0.0003	0.0003	0.9982	0.9997	0.0018	0.9978	0.9999	1	0.9997

从表 2 知, 本文 COBP 模型对样本的学习精度较改进 BP 算法普遍提高, 达到了较高的学习精度。

为检验本模型运行的稳定性, 对模型学习精度要求设置为 0.01, 经 100 次仿真模拟, 其各次学习误差曲线如图 4 所示, 其训练精度均很快达到 0.01 以上。且通常在 10~40 个混沌-BP 循环周次即能达到学习精度要求, 具有较高的学习效率, 最大误差为 0.009998, 最小误差值为 0.009235, 平均值为 0.00967202。

(2) COBP 模型仿真预测精度评价

以预处理的后 7 个样本作预测样本, 用学习后的 COBP 模型进行预测, 其预测结果和改进 BP 算法结果见表 3。

从表 3 可以看出, 本文提出的 COBP 模型和文献 3 的改进 BP 算法同样能够实现对砂土液化的预测评价, 且从总体上本模型的学习和预测精度也较 BP 算法有所提高。对于 23 号样本, 文献 3 的预测值也表现为离标准值 1 较大的偏离度, 经工程实际分析, 该样本代表的液化状态确系液化与非液化的中间状态, 故其预测值是符合实际情况的。




图 4 COBP 优化模型运行 100 次训练精度

Fig 4 Training errors of COBP model for 100 times operation

表 3 不同算法的预测结果与实际值

Table 3 Predicted results from different algorithms and measurements

样号	19	20	21	22	23	24	25
实测	0	0	0	0	1	1	1
BP 法	0.0501	0.0094	0.0082	0.0035	0.8124	0.8195	0.9907
COBP	0	0	0	0	0.6034	0.8472	1

5 结论

根据 BP 算法和混沌优化算法优缺点的互补性, 按照取长补短、相互提高的改进思路, 将二者结合构建了一种新的组合式优化预测模型 (COBP)。将该模型用于砂土地震液化预测对比研究, 可得出以下结论:

(1) 将混沌优化的全局寻优和 BP 算法快速局部寻优特性相结合, 用于砂土液化预测的 BP 神经网络优化建模, 可以有效地克服 BP 算法收敛性差、稳定性不强和易于陷入局部最小的缺点, 同时也克服了基本混沌优化初始化要求带来的不足;

(2) 两种模型都能达到一定的预测精度, COBP 模型对传统 BP 模型的学习和预测精度有较大提高;

(3) COBP 优化预测模型不仅搜索速度快、稳定性强, 而且预测精度和准确性也较高, 能达到工程应用精度需求, 为砂土液化非线性预测预防提供了一种有效方法。

参考文献:

[1] 李方明, 陈国兴. 基于神经网络的饱和砂土液化判别方法 [J]. 自然灾害学报, 2005 14(2): 108-114

[2] 任文杰. 人工神经网络在地基土液化判别中的应用 [D]. 天津: 河北工业大学, 2002

[3] 刘红军, 薛新华. 砂土地震液化预测的人工神经网络模型 [J]. 岩土力学, 2004 25(12): 1942-1947

[4] 王东升, 曹 磊. 混沌、分形及其应用 [M]. 合肥: 中国科学技术大学出版社, 1995.

[5] 李 兵, 蒋慰孙. 混沌优化方法及其应用 [J]. 控制理论与应用, 1997 (4): 613-615

[6] 刘勇健, 张伯友. 基于混沌优化-神经网络的水泥搅拌桩复合地基承载力预测方法 [J]. 路基工程, 2006 1 (124): 61-64

[7] William C Carpenter, M agency E Hoffman. Guidelines for the selection of network architecture [J]. Artificial Intelligence for Engineering Design Analysis and Manufacturing, 1997, 11(5): 395-408

[8] 董长虹. Matlab 神经网络及其应用 [J]. 北京: 国防工业出版社, 2005: 90-91