

# 位移反分析的进化神经网络方法研究\*

冯夏庭<sup>1, 2</sup> 张治强<sup>2</sup> 杨成祥<sup>2</sup> 林韵梅<sup>2</sup>

(<sup>1</sup>中国科学院武汉岩土力学研究所 武汉 430071) (<sup>2</sup>东北大学资源与土木工程学院 沈阳 110006)

**摘要** 将人工神经网络与遗传算法相结合, 提出了一种用于位移反分析的进化神经网络方法。这种方法基于正交试验获得的样本进行学习, 用遗传算法搜索最优的神经网络结构, 并用最佳推广预测学习算法训练此网络, 以此训练好的网络描述岩体(土)的力学参数与岩体位移之间的非线性关系, 再应用遗传算法从全局空间上搜索, 进行岩体力学参数的最优辨识。作为例子, 文中给出了弹性问题的反分析, 结果是令人满意的。

**关键词** 位移, 反分析, 遗传算法, 神经网络

**分类号** TP183

## 1 引言

在岩土工程领域内, 位移反分析法已引起人们的广泛关注。它以工程现场的量测位移作为基础信息反求实际岩体(土)的力学参数、地层初始地应力以及支护结构的边界荷载等, 为理论分析(特别是数值分析)在岩土工程中的成功应用提供了符合实际的基本参数。位移反分析法按照其采用的计算方法可分为解析法和数值法(有限元法、边界元法等)。由于解析法只适用于简单几何形状和边界条件的问题的反分析, 难于为复杂的岩土工程所采用, 而数值方法则具有更普遍的适应性。数值方法按实现反分析的过程不同又可以分为逆解法、图谱法和直接法三类。其中直接法又称为直接逼近法, 也称优化反分析法, 它把参数反分析问题转化为一个目标函数的寻优问题, 直接利用正分析的过程和格式, 通过迭代计算, 逐次修正未知参数的试算值, 直到获得“最优值”。最优化方法是进行位移反分析的有力工具, 目前已有多种优化方法用于位移反分析, 如鲍威尔法、单纯形法、Rosenbrok法和罚函数法等, 解决问题的范围也日渐广泛。从最早的弹性位移反分析到后来的粘弹性、弹塑性位移反分析等。这类方法的特点是可用于线性及各类非线性问题的反分析, 具有很宽的适用范围, 其主要缺点, 一是通常需要给出待定参数的试探值或分布区间等, 同时, 计算工作量大, 解的稳定

性差, 易陷入局部极小值, 特别是待定参数的数目较多时, 费时、费工、收敛速度缓慢, 不能保证搜索收敛到全局最优解; 二是由于岩土工程的复杂性, 它所涉及的工程地质条件及岩体特性参数是不完全定量的, 难以用确定的数学模型加以描述<sup>[1]</sup>。为了解决这两个问题, 本文探讨了进化神经网络方法在位移反分析中的应用, 并对实例进行了分析。

## 2 进化神经网络方法的建模思想

遗传算法(Genetic Algorithm, 简称GA)是一种全局最优化方法, 特别适用于多极值点的优化问题。它模拟了自然界生物进化过程中的“优胜劣汰, 适者生存”的法则, 将复制、杂交、变异等概念引入到算法中, 通过构造一组初始可行解群体并对其操作, 使其逐渐移向最优解。它克服了传统优化方法易于陷入局部最优解的缺点, 搜索具有隐含并行性, 可以较快地搜索到全局最优解, 并且对目标函数的形态没有具体的要求, 因而明显地优于传统的优化方法<sup>[2~4]</sup>。

人工神经网络(Neural Network, NN)具有模拟人类部分形象思维的能力, 它采用类似于“黑匣子”的方法, 通过学习和记忆, 找出输入(岩性参数)和输出(位移量)之间的特征关系(映射), 这样就减少了预先假定岩性参数和位移量服从某种数学关系而带来的误差。它特别适用于参数变量和目标函数之间

1998年12月7日收到初稿, 1999年3月30日收到修改稿。

\* 国家自然科学基金(59604001)和教育部博士点基金(96014513)资助项目。

作者 冯夏庭 简介: 男, 34岁, 博士, 1986年毕业于东北工学院采矿系, 现任教授、博士生导师, 主要从事智能岩石力学与工程力学方面的研究与教学工作。

无数学表达式的复杂工程问题中,在岩土工程中也得到了广泛的应用<sup>[5-10]</sup>。一个简单的神经网络模型可以反映一个非常复杂的映射关系。因此,用神经网络模型来表达岩土工程中岩体特性参数与岩体位移值之间的映射关系是非常适宜的。据此,本文将遗传算法和神经网络有机地结合起来,提出一种用于位移反分析的进化神经网络方法,以解决传统的各种优化方法易于陷入局部最优值和映射关系难以确定的问题。

### 2.1 岩体力学参数与岩体位移非线性映射关系的确定

由于岩土结构的复杂性,岩体力学参数与岩体位移之间的关系很难用显式数学表达式来描述,所以本文拟用广为流行的前馈网络模型来描述岩体力学参数与岩体位移之间的映射关系。鉴于不同的神经网络结构(主要是指网络的层数和每层的节点数)对模型的学习和推广预测能力有直接的影响,因此构造一个令人满意的神经网络模型是至关重要的。本文应用遗传算法搜索最佳的神经网络结构。由于网络的输入层节点数和输出节点数由问题的特征而定,故用遗传算法只需搜索网络的隐含层数和隐含层节点数。具体过程如下:首先,随机地产生一规模为  $N$  的初始网络结构群体,每个网络结构个体用一条二进制串的染色体表示。用给定的样本数据训练每一网络结构,用 BP 算法反复修正网络的连接权值。模型(权值)每修改一次,对新的样本数据进行一次检验预测,并计算出该模型对所有训练样本的累积预测误差平方和。以此作为适应值,评价该模型的预测能力。从中找出各个网络结构的最小预测误差(适应值)。对于每一网络结构,在最小预测误差下进行训练,可以避免网络学习的“过训练”问题。比较这些网络结构的最小预测误差平方和,如果未达到要求,则需对网络结构个体进行选择、杂交、变异等遗传操作,产生下一代可能的网络结构(子代群体)。具体做法是:选取两个适应值较好(最小预测误差较小)的网络结构个体的染色体,例如其二进制代码分别为 111111 和 000000。通过杂交产生一子代网络结构个体,假设杂交产生的子代个体的二进制代码为 111000,对其进行变异操作,如最后一位发生变异,由 0 变为 1,则最后生成的子代个体的二进制代码为 111001,它代表一种可能的网络结构。重复这个遗传操作过程,直至生成  $N$  个新网络结构个体。同时,将上代群体中适应值最好的网络结构个体随机地替换子代群体中的一个网络结构个体,以保证最好的网络个体总能保留下来而不会丢失。

对于这新一代的网络结构个体,重复上述的模型学习和性能评价过程。由于每一网络在最优学习

误差(对应的检验预测误差最小)下进行训练,通过对网络结构的反复进化操作,最终总能找到最理想的网络模型,以很好地反映出岩体力学参数与岩体位移之间的非线性映射关系。用此关系可以很好地进行位移反分析。

### 2.2 位移反分析目标函数的确定

用优化方法进行位移反分析的实质就是寻找一组待反演的参数使之与相应的位移值与实测位移值逼近的方法。对于实际工程的设计和施工来说,这种逼近追求的是总体上的最优效果,因此,目标函数可取为以下形式:

$$F(X) = \sum_{i=1}^n [f_i(X) - u_i]^2 \quad (1)$$

式中:  $(X)$  为一组待反演参数,如  $(X) = \{\alpha_x, \alpha_y, \tau_{xy}, E, \mu, c, \phi\}$ ;  $\alpha_x, \alpha_y, \tau_{xy}$  为初始地应力的 3 个分量;  $E, \mu, c, \phi$  分别为岩体的弹性模量、泊松比、内聚力和内摩擦角;  $f_i(X)$  为岩体上第  $i$  个量测点发生的位移量的计算值;  $u_i$  为相应的位移量的实测值;  $n$  为位移监测点总数。

### 2.3 位移反分析的进化神经网络算法

用神经网络建立起岩体力学参数与岩体位移之间的映射关系之后,对于任一组给定的岩体力学参数,均可以通过网络的推广预测能力求出其相应的位移值,如果某一位移值和实际位移值相比其误差为最小,则此位移值所对应的岩体力学参数即为所求。鉴于遗传算法具有搜索全局最优解和隐含并行性的优点,本文应用遗传算法结合神经网络对岩体力学参数进行搜索寻优,具体步骤如下:

- (1) 对进化神经网络模型进行初始化设置,确定待反分析的岩体力学参数的搜索范围;
- (2) 在待反演参数的取值范围内,随机地产生一组可能的取值。参数的每个取值是一个二进制代码表示的染色体;
- (3) 将参数的每一取值输入 2-1 节确定的神经网络模型,预测其位移值  $f_i(X)$ ,按式(1)计算位移值的预测误差(适应值);如果适应值不理想,则进行参数取值染色体的遗传进化操作。
- (4) 对每一参数取值的染色体进行复制、杂交、变异等遗传操作,产生一子代可能的参数取值群体。对其重复进行步骤(3)的操作,直至找到了最合理的参数值。

以上可以看出,进化神经网络方法既利用了神经网络的非线性映射、网络推理和预测功能,又利用了遗传算法全局优化特性,在处理变量与目标函数值之间无明显的数学表达式的复杂工程问题中,具有较高的应用意义。



### 3 应用实例

对于弹性位移反分析的例子, 可取图 1 所示的圆形截面巷道<sup>[1]</sup>, 巷道半径为 1.5m, 埋深为 50m,




图 1 弹性位移反分析例图

Fig 1 Displacement back analysis for elastic problems

围岩容重为  $28 \text{ kN/m}^3$ , 泊松比为 0.3, 量测位移取自相应点的理论值, 初始地应力为  $\sigma_0 = -1.4 \text{ MPa}$ ,  $\tau_{xy0} = 0 \text{ MPa}$ ,  $E_0 = 2255.2 \text{ MPa}$ , 取  $\tau_{xy0}$  为定值, 本文只反分析  $\sigma_0$  和  $E_0$  两个参数。

在样本“试验”阶段, 对每个参数, 取 5 个水平, 即  $\sigma_0$  取  $-1.0, -1.2, -1.4, -1.6, -1.8 \text{ MPa}$ ,  $E_0$  取  $2055.2, 2155.2, 2255.2, 2355.2, 2455.2 \text{ MPa}$ , 依据正交试验设计原理, 给出 25 组不同  $\sigma_0$  和  $E_0$  组合试验。对于每一组试验, 计算 6 个关键测点处的水平和垂直位移分量  $u_x$  和  $u_y$ , 测点的坐标分别为: 测点 1(0, 1.97)、测点 2(1.2, 1.75)、测点 3(1.75, 1.2)、测点 4(1.97, 0)、测点 5(1.5, 0)、测点 6(0, 1.5)。各试验用弹性有限元计算得出的水平与垂直方向的位移值如表 1 所示(由于测点 1 的  $u_x$ , 测点 4, 5 的  $u_y$  和测点 6 的  $u_x$  均为 0, 未计入该表)。

用表 1 中的前 20 个样本训练网络, 用后 5 个样本来测试网络。经过遗传算法搜索, 发现结构为 2-13-13-8 的神经网络在学习误差为 0.000577 时的推广预测效果最佳, 所以取网络结构为 2-13-13-8。网

表 1 各量测点对应于不同  $\sigma_0$  和  $E_0$  的绝对位移值(有限元计算求得)

Table 1 Displacement values corresponding to various  $\sigma_0$  and  $E_0$  for each measuring point

试验组数	$\sigma_0 / \text{MPa}$	$E_0 / \text{MPa}$	1		2		3		4	5	6
			$u_y$	$u_x$	$u_y$	$u_x$	$u_y$	$u_x$	$u_x$	$u_x$	$u_y$
1	-1.2	2355.2	-1.036	-0.7655	-0.408	-0.4958	-0.5573	-0.6873	-0.9045	-1.302	
2	-1.8	2455.2	-0.6825	-0.581	-0.6178	-0.4493	-0.9808	-1.352	-1.671	-0.9769	
3	-1.6	2055.2	-0.9398	-0.7555	-0.6477	-0.5474	-0.9936	-1.339	-1.69	-1.276	
4	-1	2255.2	-1.195	-0.8547	-0.3443	-0.527	-0.4205	-0.4668	-0.7037	-1.458	
5	-1.4	2155.5	-1.014	-0.7784	-0.5318	-0.5319	-0.7783	-1.014	-1.32	-1.32	
6	-1.4	2255.2	-0.9692	-0.7439	-0.5082	-0.5083	-0.7438	-0.969	-1.261	-1.261	
7	-1.2	2155.2	-1.132	-0.8363	-0.4461	-0.5416	-0.6092	-0.7513	-1.028	-1.423	
8	-1.8	2355.2	-0.7122	-0.6063	-0.6436	-0.4688	-1.022	-1.409	-1.741	-1.019	
9	-1.6	2455.2	-0.7866	-0.6323	0.5422	-0.4582	-0.8318	-1.121	-1.414	-1.068	
10	-1	2055.2	-1.311	-0.9379	-0.3778	-0.5783	-0.4614	-0.5122	-0.7722	-1.6	
11	-1	2455.2	-1.097	-0.7851	-0.3162	-0.4841	-0.3862	-0.4287	-0.6464	-1.339	
12	-1.4	2055.2	-1.064	-0.8165	-0.5575	-0.5579	-0.8158	-1.063	-1.383	-1.384	
13	-1.2	2255.2	-1.082	-0.7993	-0.4263	-0.5176	-0.5822	-0.718	-0.9825	-1.36	
14	-1.8	2155.2	-0.778	-0.6623	-0.7053	-0.5121	-1.117	-1.54	-1.903	-1.113	
15	-1.6	2355.2	-0.8202	-0.6594	-0.5651	-0.4778	-0.8669	-1.168	-1.474	-1.113	
16	-1.6	2155.2	-0.8961	-0.7204	-0.6177	-0.522	-0.9477	-1.277	-1.611	-1.216	
17	-1	2355.2	-1.144	-0.8184	-0.3297	-0.5046	-0.4027	-0.447	-0.6739	-1.396	
18	-1.4	2455.2	-0.8901	-0.6832	-0.4669	-0.4668	-0.6834	-0.8903	-1.159	-1.158	
19	-1.2	2055.2	-1.187	-0.8771	-0.4678	-0.568	-0.6388	-0.7878	-1.078	-1.492	
20	1.8	2055.2	-0.744	-0.6334	-0.672	-0.4879	-1.067	-1.471	-1.818	-1.064	
21	-1.8	2255.2	-0.8156	-0.6943	-0.7379	-0.5369	-1.171	-1.615	-1.996	-1.167	
22	-1.6	2255.2	-0.8562	-0.6884	-0.5903	-0.4988	-0.9057	-1.221	-1.54	-1.162	
23	-1	2155.2	-1.25	-0.8944	-0.3602	-0.5515	-0.44	-0.4883	-0.7363	-1.526	
24	-1.4	2355.2	-0.928	-0.7123	-0.4867	-0.4867	-0.7123	-0.928	-1.208	-1.208	
25	-1.2	2455.2	-0.9937	-0.7342	-0.3916	-0.4755	-0.5348	-0.6595	-0.9024	-1.249	

络在学习误差达到0.000577时结束学习,获得的模型作为映射 $f_i(X)$ 进行位移反分析。位移反分析的搜索区间为 $\alpha_0$ : -1.8~-1.0MPa,  $E_0$ : 2.055.2~2.455.2MPa, 用遗传算法搜索到反分析结果如表2所示。由表2中结果可见,线弹性位移反分析结果与理论值吻合较好。

用反分析得出的参数进行有限元应力计算所得的位移值和在位移反分析中神经网络模型预测的位移值如表3所示,它们与用参数理论值的有限元计

算结果吻合较好。

表2 弹性位移反分析结果与理论值比较

Table 2 Comparison of back-analysis results and theoretic solutions

反分析参数	反分析结果	理论值	相对误差/%
$\alpha_0 / \text{MPa}$	-1.400074	-1.4000	0.00053
$E_0 / \text{MPa}$	2.255261	2.2552	0.00027

表3 各测点位移反分析计算值、神经网络预测值和理论值比较

Table 3 Comparison of displacements from back-analysis, NN prediction, and finite element calculation

方法	1		2		3		4	5	6
	$u_y$	$u_x$	$u_y$	$u_x$	$u_y$	$u_x$	$u_x$	$u_x$	$u_y$
用参数理论值的有限元计算结果	-0.9692	-0.7439	-0.5082	-0.5083	-0.7438	-0.969	-1.261	-1.261	
用参数反分析值的神经网络预测结果	-0.9731	-0.7437	-0.5088	-0.5080	-0.7419	-0.9770	-1.2625	-1.2647	
用参数反分析值的有限元计算结果	-0.9691	-0.7438	-0.5083	-0.5083	-0.7439	-0.9692	-1.261	-1.260	

### 4 结 论

(1) 提出了一种新的位移反分析法——进化神经网络方法。它用遗传算法搜索神经网络结构,并用最佳推广预测学习算法训练网络结构,由此可以寻找到最理想的神经网络模型。由于参数的识别是个大空间的搜索问题,遗传算法再一次用来在全局空间上搜索待反演参数的取值,使得反分析结果是全局最优的。因而克服了传统优化方法易陷入局部最优和岩体力学参数与岩体位移之间的映射关系难以确定的缺点。

(2) 在各种问题的位移反分析中,线弹性位移反分析是一种最为有效的识别岩体力学参数的方法。故本例中,用获得的进化神经网络模型进行线弹性位移反分析,其平均相对误差为0.0004%,说明了这种方法是可行的。

(3) 为了建立这种映射关系,需要给出一组样本对神经网络模型进行训练,用来训练的样本可以通过数值计算和物理模型试验等方法获得。为了减少计算量和试验次数,用较少的样本高效率地训练神经网络,本文采用正交试验设计的思想来安排不同参数组合的有限元计算。正交设计法是研究和处理多因素试验的一种科学方法,它是利用预先设计好的“正交表”来安排试验的,具有“均衡分散性”和“整齐可比性”,这样可以使得试验点安排得比较均匀且具有代表性,从而能以较少的试验得出较好

的试验结果。

(4) 基于进化神经网络的位移反分析方法是一种通用的岩体力学参数和原岩应力反分析方法。只要根据具体问题更换模型训练样本数据集,就可以获得相应的岩体力学参数和原岩应力值。对于更为复杂的问题(如粘弹性、弹塑性、弹脆塑性)和一些重大岩土工程岩体的位移反分析,笔者将另文专述。

### 参 考 文 献

- 1 王芝银, 李云鹏 地下工程位移反分析及程序 西安: 陕西科学技术出版社, 1993, 40(4): 36~37
- 2 刘 勇, 康立山, 陈毓屏 非数值并行算法(第二册)——遗传算法 北京: 科学出版社, 1997
- 3 安美建, 李方全, 石耀霖 遗传算法在确定钻孔裂缝产状中的应用 岩石力学与工程学报, 1997, 16(5): 418~423
- 4 吴洪词, 张小彬, 包 太 边坡开挖步序的遗传算法排定 岩石力学与工程学报, 1998, 17(5): 565~570
- 5 曹焕光 人工神经元网络原理 北京: 气象出版社, 1992, 67~81
- 6 冯夏庭, 林韵梅 岩石力学与工程专家系统 沈阳: 辽宁科学技术出版社, 1993
- 7 冯夏庭, 王泳嘉 采矿工程智能系统 北京: 冶金工业出版社, 1994
- 8 冯夏庭 岩石力学智能化的研究思路 岩石力学与工程学报, 1994, 13(3): 205~208
- 9 Feng Xiating, Katsuyama K, Wang Yongjia, et al A new direction-intelligent rock mechanics and rock engineering Int J. Rock Mechanics and Mining Science, 1997, (1): 135~141
- 10 冯夏庭, 王泳嘉 关于智能岩石力学发展的几个问题的讨论 岩石力学与工程学报, 1998, 17(6): 705~710

## STUDY ON GENETIC-NEURAL NETWORK METHOD OF DISPLACEMENT BACK ANALYSIS

Feng Xiating<sup>1, 2</sup> Zhang Zhiqiang<sup>2</sup> Yang Chengxiang<sup>2</sup> Lin Yunmei<sup>2</sup>

(<sup>1</sup> Institute of Rock and Soil Mechanics, The Chinese Academy of Sciences, Wuhan 430071 China)

(<sup>2</sup> Northeastern University, Shenyang 110006 China)

**Abstract** An evolutionary neural network method for displacement back analysis is proposed by combining the neural network and genetic algorithm. The samples produced in orthogonal experiment are used to train the neural network whose architecture is determined in global optimum by genetic algorithm. Thus, the neural network with optimal architecture trained by optimal prediction algorithm is used to describe the relationship between the rock mechanical parameters and displacements produced due to excavation. Then genetic algorithm is adopted again to search the optimal rock mechanical parameters in their global ranges. As an example, a back analysis for elastic problem is introduced. The results are satisfactory.

**Key words** displacement, back analysis, genetic algorithm, neural network

## 钙质土土力学理论及其工程应用

刘崇权

(中国科学院武汉岩土力学研究所 武汉 430071)

**博士学位论文摘要** 在综述了钙质土的力学性质研究现状的基础上, 指出只有建立与颗粒破坏有关的应力应变理论和强度准则, 才能充分揭示其特殊的物理力学性能, 从而指导基础工程实践。认为钙质土在剪切过程中的剪胀和颗粒破碎的耦合作用是导致其独特的力学与工程性能的根本原因。基于这一思想, 论文从以下几个方面阐述了钙质土的力学特性:

(1) 钙质土基本静力学特性。详细讨论了在颗粒破碎和剪胀作用下, 钙质土在压缩、剪切及强度等方面的特征。指出在试验应力水平范围内, 钙质土是稳定材料。

(2) 钙质土基本动力学特性。以动三轴试验资料为基础, 叙述了其动三轴应力-应变的影响因素, 并详细研究了动三轴试验条件下孔隙水压力发展模式、变形规律及强度特征。

(3) 颗粒破碎对钙质土力学特性的影响。以相对破碎 $B_r$ 为刻画颗粒破碎强弱的指标, 理论推导和实验论证相结合, 导出 $B_r$ 与 $W^p$ ,  $(\sigma_1/\sigma_3)_{\max}$ ,  $(q/p)_{\max}$ ,  $\epsilon_s$ 等参数之间的显式表达式以及工程上常用的 $(\sigma_1/\sigma_3)_{\max}$ 与 $\varphi$ 之间的对数线性公式。

(4) 钙质土弹塑性本构模型。以沈珠江所建议椭圆屈服面和史-杨角隅式Mohr-Coulomb准则为基础, 引入颗粒破碎的影响, 建立了相适应流动条件下的弹塑性本构模型。

最后, 以论文提出的模型及相应参数, 编制了弹塑性二维有限元程序, 对一维压缩应力应变和单桩荷载-位移特性进行了计算, 结果表明模型计算结果较符合钙质土的力学特征。模型的进一步验证和优化有待将来更深入的研究。

**关键词** 钙质土土力学, 土力学, 试验, 颗粒破碎, 本构模型, 力学性质

## THE THEORY OF CALCAREOUS SOILS MECHANICS AND ITS APPLICATION IN ENGINEERING

Liu Chongquan

(Institute of Rock and Soil Mechanics, The Chinese Academy of Sciences, Wuhan 430071 China)

1999年8月2日收到来稿。

作者 刘崇权 简介: 男, 27岁, 1999年7月在中国科学院武汉岩土力学研究所获博士学位, 导师为白世伟研究员和汪稔研究员; 现在广州市城市规划勘测设计院从事岩土工程研究及勘察、设计与测试方面的工作。