

文章编号: 1000-7598-(2006)08-1263-04

神经网络在岩体力学参数和地应力场反演中的应用

金长宇¹, 马震岳¹, 张运良¹, 沙瑞华¹, 陈庆发²

(1. 大连理工大学 土木水利学院, 大连 116024; 2. 武汉理工大学, 武汉 430070)

摘 要: BP 神经网络已广泛地应用于岩体力学参数和初始应力场的反演分析, 但在实际应用中, BP 网络存在着网络训练易于过度、收敛速度慢、易陷入局部极小以及隐层节点数难于确定等缺点。采用 RBF 网络和改进的 BP 网络, 利用基于有限差分格式的快速拉格朗日算法进行正分析计算, 依据若干测点的正应力数据, 反演了计算区域的岩体力学参数以及初始应力场。算例表明, RBF 神经网络与快速拉格朗日算法相结合, 在样本容量相同的情况下, 反演分析的精度、网络的拓扑结构以及学习、收敛速度, 均优于采用 BP 网络的反演算法。

关 键 词: 有限差分法; BP 神经网络; RBF 神经网络; 反演; 力学参数; 初始应力场

中图分类号: TU 443

文献标识码: A

Application of neural network to back analysis of mechanical parameters and initial stress field of rock masses

JIN Chang-yu¹, MA Zhen-yue¹, ZHANG Yun-liang¹, SHA Rui-hua¹, CHEN Qing-fa²

(1. School of Civil and Hydraulic Engineering, Dalian University of Technology, Dalian 116024, China;

2. Wuhan University of Technology, Wuhan 430070, China)

Abstract: At present, BP neural network has been widely used in back analysis of material parameters and initial stress field of rock masses in geomechanics. However, BP neural network is prone to over-being-trained, slow in convergence, not global minimum but local ones obtained and number of neurons in hidden layer hard to be determined. Authors using RBF neural network and BP neural network respectively identified mechanical parameters and initial stresses according to measured normal stresses of some specific points. Direct computations based on fast Lagrangian analysis of continuum (FLAC) were performed to get enough training samples for RBF neural network and BP neural network. An example shows that combination of RBF neural network with FLAC is more effective and rapid than application of BP neural network.

Key words: finite difference method; BP neural network; RBF neural network; back analysis; mechanical parameters; initial stress field

1 引 言

岩体力学参数及初始应力场的反分析一直是岩石力学中的一个重要课题^[1~4]。根据反分析所利用的基础信息的不同, 反分析法可分为应力反分析法、位移反分析法和混合反分析法等, 其中位移反分析法最为常见; 根据所采用的计算方法, 反分析法又可分为解析法和数值法, 其中有限元法、边界元法以及各种耦合算法等应用较广。然而, 岩体具有极其复杂的结构和机理不明系统, 人们很难了解其内部结构的状态和方式, 只能通过它的外部联系(例如输入-输出关系)状态和方式来把握该事物的信息。

传统解析法和数值法考察的对象都是确定的信息, 要求具备严格的数学模型和简化条件。而事实上, 现场大量的离散数据和对系统的一些认识, 特别是经验认识都将参与分析过程。因此, 对于岩土工程这种极其复杂的问题, 采用现代智能方法如人工神经网络是一种有效的解决手段。目前, 已有不少学者应用 BP 网络分别对岩体力学参数和初始应力场进行了反演研究^[5~7]。同时, 在获取网络的训练样本时, 正分析大多采取基于有限元方法所建立的模型^[6~8]。

然而, 在实际应用中, BP 网络存在着网络训练易于过度、收敛速度慢、易陷入局部极小以及隐层

节点数难于确定等缺点。而 RBF (Radial basis function 径向基函数) 网络是一种局部逼近网络, 即输入空间的某一个局部区域只存在少数的神经元用于决定网络的输出。因此, RBF 网络有学习时间短、计算量小、网络性能优良等优点, 能够避免 BP 网络冗长的迭代计算和陷入局部极值的可能, 学习速度比通常 BP 学习算法快上千倍, 且有良好的推广能力。本文通过一简单地下工程算例, 比较了 RBF 网络和 BP 网络对岩体物理力学参数和初始应力场反演的效果, 以考察 RBF 网络应用于此领域的优越性。

为了更准确地获取网络训练的样本, 本文正分析采用比有限元法更适合模拟岩土介质的快速拉格朗日算法。该算法将问题的基本方程和边界条件以简单、直观的差分形式表达, 应用节点位移连续的条件, 可有效求解岩土力学非线性大变形问题, 能得到较满意的位移解, 在岩土工程中有很强的实用性。美国 ITASCA 公司基于差分法推出的 FLAC (Fast Lagrangian Analysis of Continuum) 程序, 在岩土工程界享有盛誉。本文采用 FLAC3D 进行模型的构建, 为正分析提供一个有效的计算平台。

本文基于有限差分法与 RBF 网络联合反演初始地应力场及岩体物理参数是一种新的尝试。

2 RBF 网络的理论与特性

径向基函数 RBF 网络由 3 层组成, 其拓扑结构如图 1 所示。输入层只用来输入, 没有传递函数; 隐层单元的传递函数为高斯型径向基函数; 输出层单元的传递函数为线性函数。




图 1 RBF 网络结构

Fig.1 RBF neural network architecture

RBF 网络的映射关系由两部分组成 (设输入维数为 n , 隐单元数为 p , 输出维数为 m):

第一部分: 从输入空间到隐含层空间的非线性变换层。第 j 个隐单元输出为

$$h_j(X) = \phi(\|X - C_j\|, \sigma_j) = \exp\left[-\frac{\|X - C_j\|^2}{2\sigma_j^2}\right] \quad (j=1, \dots, p) \quad (1)$$

式中 $\|\bullet\|$ 表示范数, 通常取欧几里德范数; X 为 n 维输入矢量, 即 $X=[x_1, x_2, \dots, x_n]^T$; C_j 为第 j 个非线性变换单元的中心向量, $C_j=[c_j^1, c_j^2, \dots, c_j^n]^T$, 与 X 具有相同维数的向量; c_j^k 为第 j 个中心对应第 k 个输入的分量; σ_j 为第 j 个非线性变换单元的宽度。

第二部分: 从隐含层空间到输出层空间的线性合并层。第 j 个输出为

$$y_j = \sum_{i=1}^p h_i w_{ij} \quad (1 \leq j \leq m) \quad (2)$$

式中 w_{ij} 为第 i 个隐单元与第 j 个输出之间的连接权; m 为输出维数; p 为隐单元数。

由上面对 RBF 网络的拓扑结构和映射关系的分析可知, RBF 的网络参数由三部分构成: 中心 C_j , 宽度 σ_j 和权值 w_{ij} , 这三部分参数在映射中所起的作用是不同的。隐含层的中心和宽度代表了样本空间模式及各中心的相对位置, 完成的是从输入空间到隐含层空间的非线性映射; 而输出层的权值是实现从隐含层空间到输出空间的线性映射。

RBF 网络学习过程包括隐层单元学习和输出层单元学习两个阶段。隐层单元学习时采用无监督学习的最近邻聚类算法, 确定隐层各节点的中心值 C_j 和宽度 σ_j ; 输出单元是一个线性求和器, 所以学习时采用有监督学习。例如: 采用最小二乘法完成学习, 网络学习和训练中止的条件是网络实际输出结果与期望输出之间的差值在最小二乘意义上小于给定的误差 ε , 以确定输出层的权值 w_{ij} 。

需要说明的是, 最近邻聚类学习算法是一种在线自适应聚类学习算法, 不需要事先确定隐含层单元的个数, 因而完成聚类所得到的 RBF 网络是最优的, 并且此算法可在线学习。同时, RBF 网络具有输出与初始权值无关、学习时间短、计算量小、网络性能优良等优点。

3 RBF 网络的应用

在应用 RBF 网络反演岩体力学参数和初始应力场时, 按照以下步骤:

(1) 针对具体的地下工程, 在基于有限差分法的 FLAC3D 软件平台上建立正分析模型, 包括几何模型、物理力学参数和初始应力场 (包括自重应力场和水平构造应力场)。改变初始应力场和物理力学参

数,进行正分析计算,目的是为了获得初始应力场作用下计算区域若干代表点的应力与初始应力场、物理力学参数之间的映射对应关系。以计算应力值作为输入向量,将对应的初始应力场及物理力学参数作为输出向量,构成RBF网络的若干组学习样本。

(2) 应用以上样本,经过RBF神经网络模型的学习,包括隐层单元的无监督学习和输出层单元的有监督学习,以获取影响输入-输出非线性映射关系的中心向量、权值和宽度。建立针对该工程反演计算所需的映射模式。

(3) 把若干点实测应力作为输入样本赋予训练好的RBF网络模型,可得到唯一的与之对应的初始应力场和相应的岩石物理力学参数。

(4) 将反演得到的初始应力场和岩石物理力学参数,代入正分析模型中进行正分析计算,即可得到计算模型中任意一点的应力值。

4 算例验证

4.1 正分析模型

拟建某地下厂房所在地域为 $500\text{ m} \times 300\text{ m} \times 500\text{ m}$ 的块体。借助FLAC3D建立正分析模型。为了模拟复杂的地质条件,在模型内考虑有3种岩体组成,其组成形式如图2所示(上层为Group1,下层左侧为Group2,下层右侧为Group3)。模型在 $Y=0\text{ m}$ 处为自由面;在 $Y=-300\text{ m}$ 处, X, Y, Z 方向全部为位移约束边界;在 $X=-250\text{ m}, X=250\text{ m}$ 处, X 方向为位移约束边界;在 $Z=0\text{ m}, Z=500\text{ m}$ 处, Y 方向为位移约束边界。




图2 计算模型
Fig.2 Computation model

4.2 反演参数

正分析模型在计算时采用了Mohr-Coulomb屈服准则,故要考虑的岩体物理力学参数有:密度、体积模量、剪切模量、内摩擦角、凝聚力、膨胀角和抗拉强度。一般而言,对初始地应力场影响较大的主要是体积模量 K 、剪切模量 G 、密度 ρ 。因此,本文将 K, G 及 ρ 作为待反演的参数。当然,也可反

演其他参数。

岩体中的初始地应力的分布规律极为复杂,影响因素甚多。一般地,竖向自重应力场和水平方向的构造应力场共同作用形成岩体初始应力场。不失工程精度,这里假设岩体中的任一点自重竖向应力为 ρgZ (g 为重力加速度, Z 为竖向深度),水平构造应力随深度 Z 而变化为 $\rho gZ k_0$ 。在此,借鉴了侧压力系数这一概念,将 $\rho gZ k_0$ 与 ρgZ 的比值记为 k_0 ,将 k_0 作为待反演的另一个参数,本文不妨称之为构造应力系数。因此,待反演量为 K, G, ρ 及 k_0 。为建立训练样本,所采用的 K, G, ρ 及 k_0 取值如表1所示。

4.3 反演过程与结果分析

在正分析模型中选取不同的4个点作为“现场的实测点”。将以上1~20组岩体物理力学参数及构造应力系数 k_0 代入模型进行正分析计算,将计算的4个节点 X, Y, Z 方向的20组正应力作为网络输入值,而将20组材料参数和构造应力系数 k_0 作为网络输出值,对RBF网络进行训练。由于RBF的学习速度很快,因此,在训练到第35次时,误差就已经达到给定误差 $\varepsilon=0.01$ 的要求。

网络训练结束后,将第21组的材料参数和构造应力系数 k_0 作为检验样本,代入模型进行正分析计算,将计算得到的4个测点的 X, Y, Z 方向的正应力值作为“现场的实测值”,再将此值代入建立好的RBF网络反演各岩体的物理参数以及 k_0 值。

将反演得到的各岩体物理参数和 k_0 值再代入正分析模型进行一次正分析计算,将反演得到的地应力值与“现场实测值”相比较,见表2。由表可知,反演结果的最大误差为16.3%、最小误差为1.2%。根据国内外统计的资料显示,初始地应力测量结果的误差可达到25%~30%^[6]。因此,本文应用RBF网络进行岩体力学参数和初始应力场的反演计算精度能够满足工程要求。

为了突出RBF网络的优越性,本文又采用改进的BP网络重新进行反演计算。由于传统BP算法存在局部极小问题和学习算法收敛速度慢等问题,为此,在这里采用了动量法和学习率自适应调整的方法对传统BP算法进行改进。在训练网络时,方法同RBF的网络训练,也是将计算出的4个节点 X, Y, Z 方向的20组正应力作为网络输入值,而将20组材料参数和构造应力系数 k_0 作为网络输出值,因此,输入节点数为12,输出节点数为11。隐含层的节点个数经试算后,节点数选取范围在25~40之间比较理想。因此,在该算例中隐含节点个数选取30个,经过训

练3 554 次数,误差就已经达到 $\varepsilon = 0.01$ 要求,反演结果见表2。由表可知,在训练样本较少的情况下,

RBF网络的精度和计算速度要高于BP网络,这就节省了很多的计算时间。

表 1 材料参数与构造应力系数 k_0
Table1 Material parameters and tectonic stress coefficient k_0

序号	Group 1			Group 2			Group 3			k_0	
	K/GPa	G/GPa	$\rho / \text{kg} \cdot \text{m}^{-3}$	K/GPa	G/GPa	$\rho / \text{kg} \cdot \text{m}^{-3}$	K/GPa	G/GPa	$\rho / \text{kg} \cdot \text{m}^{-3}$	X 方向	Y 方向
1	15	10	1.80	30	20	2.00	31	19	2.00	0.1	0.1
2	19	11	1.90	31	22	2.10	33	22	2.30	0.2	0.2
3	22	13	2.00	32	24	2.30	34	24	2.30	0.3	0.3
4	23	14	2.05	33	26	2.40	34	26	2.30	0.4	0.4
5	24	16	2.09	35	27	2.50	35	27	2.50	0.5	0.5
6	27	20	2.10	36	28	2.50	36	26	2.50	0.5	0.1
7	28	20	2.07	37	29	2.40	37	28	2.55	0.4	0.2
8	29	21	2.20	39	29	2.50	38	30	2.60	0.3	0.4
9	30	23	2.20	39	30	2.60	39	31	2.70	0.2	0.3
10	31	25	2.30	40	31	2.70	40	31	2.70	0.1	0.5
11	32	26	2.40	40	32	2.78	41	32	2.80	0.1	0.2
12	34	26	2.45	41	34	2.80	42	33	2.90	0.2	0.4
13	35	27	2.50	42	35	2.90	42	34	3.00	0.3	0.5
14	35	28	2.50	43	36	3.00	43	35	3.00	0.4	0.5
15	36	29	2.60	44	37	3.10	44	36	3.10	0.5	0.3
16	37	30	2.70	45	38	3.20	46	38	3.20	0.5	0.4
17	38	32	2.80	46	39	3.30	47	39	3.30	0.2	0.5
18	39	33	2.90	48	40	3.40	48	40	3.40	0.3	0.1
19	40	33	3.00	50	41	3.50	49	42	3.50	0.3	0.4
20	41	34	3.10	52	42	3.60	51	43	3.60	0.2	0.4
21	19	13	2.00	44	29	2.30	43	31	3.00	0.2	0.3

表 2 应力实测值与反演值的比较(单位: MPa)
Table 2 Comparison between observed stresses and those by back analysis (unit: MPa)

参数	1 号测点			2 号测点			3 号测点			4 号测点		
	σ_x	σ_y	σ_z	σ_x	σ_y	σ_z	σ_x	σ_y	σ_z	σ_x	σ_y	σ_z
实测值	-1.18	-1.53	-5.28	-1.21	-1.57	-5.42	-1.75	-2.58	-8.52	-1.81	-2.69	-8.85
RBF 网络	-1.29	-1.57	-5.16	-1.30	-1.55	-5.29	-1.59	-2.18	-8.22	-1.62	-2.25	-8.54
BP 网络	-1.57	-1.43	-5.55	-1.62	-1.47	-5.71	-2.72	-2.47	-9.18	-2.92	-2.57	-9.55

5 结 论

(1) RBF网络与BP网络相比,其突出优点是隐含层神经元的个数不需事先确定,能够自动确定隐含层各节点的中心值和宽度以及输出层的权值,是一种自适应网络;另外,在样本容量相同的情况下,RBF网络比BP网络学习速度要快很多。

(2) 正分析采用基于差分法的快速拉格朗日算法,更能够合理地模拟岩土工程问题,因而所提供的训练样本比较接近实际,可提高反演计算精度。

(3) 算例表明,RBF神经网络与基于差分法的快速拉格朗日算法相结合,是一种强强联合的反演分析工具。对于反演岩体物理力学参数和初始应力场,它快捷、有效,且精度较高。但对于实际工程问题,还需进一步检验和完善。

(4) 与BP网络类似,在采用RBF网络进行反演

分析时,要注意样本分布空间应足够大,应覆盖空间内的预测问题;同时,样本空间分布应比较均匀,不能集中在某个局部。

参 考 文 献

- [1] 杨林德. 岩土工程问题的反演理论与工程实践[M]. 北京: 科学出版社, 1996.
- [2] 冯夏庭. 智能岩体力学导论[M]. 北京: 科学出版社, 2000.
- [3] 葛宏伟, 梁艳春, 刘玮, 等. 人工神经网络与遗传算法在岩石力学中的应用[J]. 岩石力学与工程学报, 2004, 23(9): 1 542—1 550.
GE Hong-wei, LIANG Yan-chun, LIU Wei, et al. Applications of artificial neural networks and genetic algorithms to rock mechanics[J]. Chinese Journal of Rock Mechanics and Engineering, 2004, 23(9): 1 542—1 550.

- [4] 贾超, 刘宁, 肖树芳. 洞室岩体参数的位移正演反分析[J]. 岩土力学, 2003, 24(3): 450—454.
JIA Chao, LIU Ning, XIAO Shu-fang. Application of direct displacement inverse analysis to rockmass parameters of caverns[J]. **Rock and Soil Mechanics**, 2003, 24(3): 450—454.
- [5] 郝哲, 刘斌. 基于差分法及神经网络的洞室围岩力学参数反分析[J]. 岩土力学, 2003, 24(增刊): 77—80.
HAO Zhe, LIU Bin. Back analysis of mechanical parameters of rocks surrounding openings on the basis of calculus of difference method and neural network[J]. **Rock and Soil Mechanics**, 2003, 24(Supp.): 77—80.
- [6] 蒋中明, 徐卫亚, 邵建富. 基于人工神经网络的初始地应力场三维反分析[J]. 河海大学学报, 2002, 30(3): 52—56.
JIANG Zhong-ming, XU Wei-ya, SHAO Jian-fu. ANN based 3D back analysis of initial stress in rock masses[J]. **Journal of Hohai University**, 2002, 30(3): 52—56.
- [7] 易达, 徐明毅, 陈胜宏, 等. 人工神经网络在岩体初始应力场反演中的应用[J]. 岩土力学, 2004, 25(6): 943—946.
YI Da, XU Ming-yi, CHEN Sheng-hong, et al. Application of artificial neural network to back analysis of initial stress field of rock masses[J]. **Rock and Soil Mechanics**, 2004, 25(6): 943—946.
- [8] 易达, 陈胜宏, 葛修润. 岩体初始应力场的遗传算法与有限元联合反演法[J]. 岩土力学, 2004, 25(7): 1 077—1 080.
YI Da, CHEN Sheng-hong, GE Xiu-run. A methodology combining genetic algorithm and finite element method for back analysis of initial stress field of rock masses[J]. **Rock and Soil Mechanics**, 2004, 25(7): 1 077—1 080.