



利用神经网络预测岩石或 岩石工程的力学性态

张清 宋家葵

(北方交通大学土木系 北京 100044)

摘要 本文将人工智能中的神经网络引入岩石力学领域,用以预测岩石或岩石工程的力学性态。其用法类似经验公式,但其优点是影响岩体力学性态的各种描述性地质因素,均可做为变量输入,故可求得离散性较小的结果。文中附有两个实例,说明此方法的实用性。

关键词: 人工智能,神经网络,岩石工程力学性态预测。

1 前言

作为地质体的岩体具有非常复杂的力学特性,它与岩体的成岩过程、地质赋存环境和工程活动密切相关。在把岩体力学性态抽象成数学模型时,很难把上述诸因素都做为变量纳入加以分析,以致计算结果与实际情况相比具有很大的离散性。这是岩石力学发展过程中尚未明确解决的问题。

神经网络是80年代后期迅速发展起来的人工智能的一个分支。把神经网络用于岩石力学或岩石工程最大的特点是可以把岩体有关地质因素,即便是描述性的因素也可以做为变量输入。与经验公式相似,本方法是根据已有试验成果或实例,预测岩体或岩石工程的力学性态。

本文在简述神经网络原理后，以两个算例，一个取自岩石试块试验，一个取自岩石工程，说明其实用性。

2 神经网络基本原理

神经网络是由大量的处理单元广泛相互连接而成的网络，它是在现代神经科学研究成果基础上提出来的反映人类脑功能的一种模型。图1(a)说明一个真实的神经细胞，

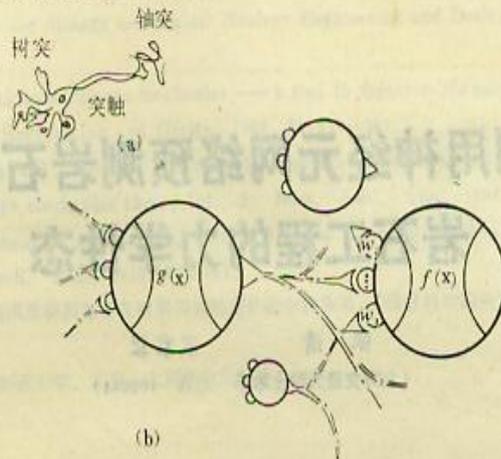


图1 (a) 神经细胞 (b) 神经网络模型

Fig. 1 (a) Real neural cell, (b) Neural network model

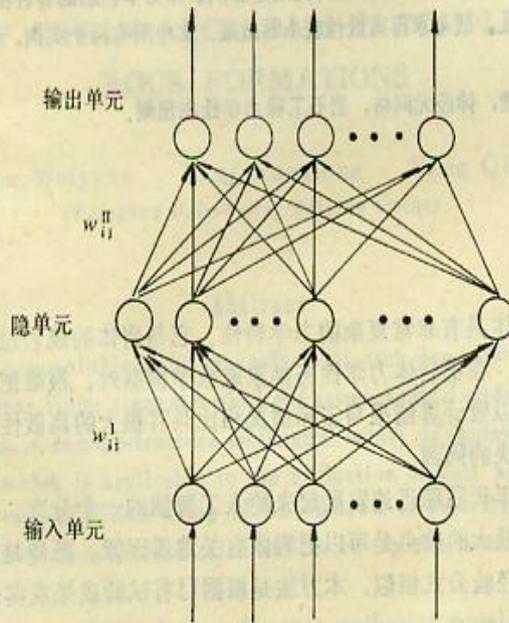


图2 多层神经网络模型

Fig. 2 A model of a multilayer neural network

它由树突、轴突和突触组成。树突接受信息; 轴突输出信息; 突触是二者之间的联结部分。图 1 (b) 是把真实神经系统抽象成模型, $g(x)$ 代表一个处理单元; $f(x)$ 代表另一个处理单元; 单元之间的联系由双线的联结部分表示, 其联结强度用 w_i 表示, 把各个处理单元联结成网络如图 2 所示。输入单元接受信息, 输出单元输出信息, 它是通过激发一个 SIGMOID 函数来输出结果。隐单元是在系统内部进行输入和输出。隐单元可以是一层, 也可以是多层。神经网络也有各种不同的模型, 在这里我们采用能广为人们接受的 PDP 模型^[1]。单元之间的联系通过权值 w_{ij} 表示其间相互的影响强度。权值的确定是通过机器学习 (Machine learning)^[2] 来进行的。机器学习有几种不同的定义, 通俗的解释是: 利用已有的实例 (称为样本), 计算机按一定的程序去预测同类性质的问题。具体用于神经网络其含意为: 如已知若干组输入数据, 亦已知其最终输出结果, 利用机器学习来调整各单元之间的权值 w_{ij}^1 和 w_{ij}^2 , 使之能最佳地适应已知诸实例的结论。

从数学角度来看, 神经网络是一组输入单元到输出单元的映射。这种映射是一个高度非线性的映射。如果有 n 个输入单元, 有 m 个输出单元, 则网络是:

$$F: R^n \rightarrow R^m \quad Y = F(x)$$

如果对于样本集合输入 x 和输出 y , 可以认为存在某一映射 G , 使 $y_i = G(x_i)$, $i = 1, \dots, k$ 。求解问题即要求求得一映射 F , 使得在某种意义上 F 是 G 的最佳逼近。根据 Kolmogorov 的神经网络映射定理已经证明: 只要采用有隐单元的网络, 这种映射就是存在的^[3]。

本文采用了包括隐单元的三层神经网络, 如图 2 所示。在机器学习过程中调整权值的算法, 采用了反向传播法^[1], 具体步骤如图 3 中框图所示。有关神经网络进一步的资料请参阅有关文献^[4-6]。

3 在岩石力学试验中的应用

L. Caruso 等人^[7]研究了砂岩中各种空隙及矿物成分等对岩石试件线弹性压缩系数 (Compressibility) 的影响, 但未能把这些因素做为变量包含在内。本文采用神经网络方法可以把上述因素均加以考虑做为变量, 输入系统。

根据现有资料, 本文把试件中影响其力学性状的诸因素定为:

(1) 岩石矿物含量 (%)

石英含量, 长石含量, 碎屑粘土含量, 其它成分含量。

(2) 平均结晶颗粒

形状: 分为 (a) 近似棱角 (SA);

(b) 近似棱角到近似圆形 (SS);

(c) 棱角到近似棱角 (AS);

(d) 近似圆形到圆形 (SR);

(e) 近似圆形 (R)。

尺寸 (μm)

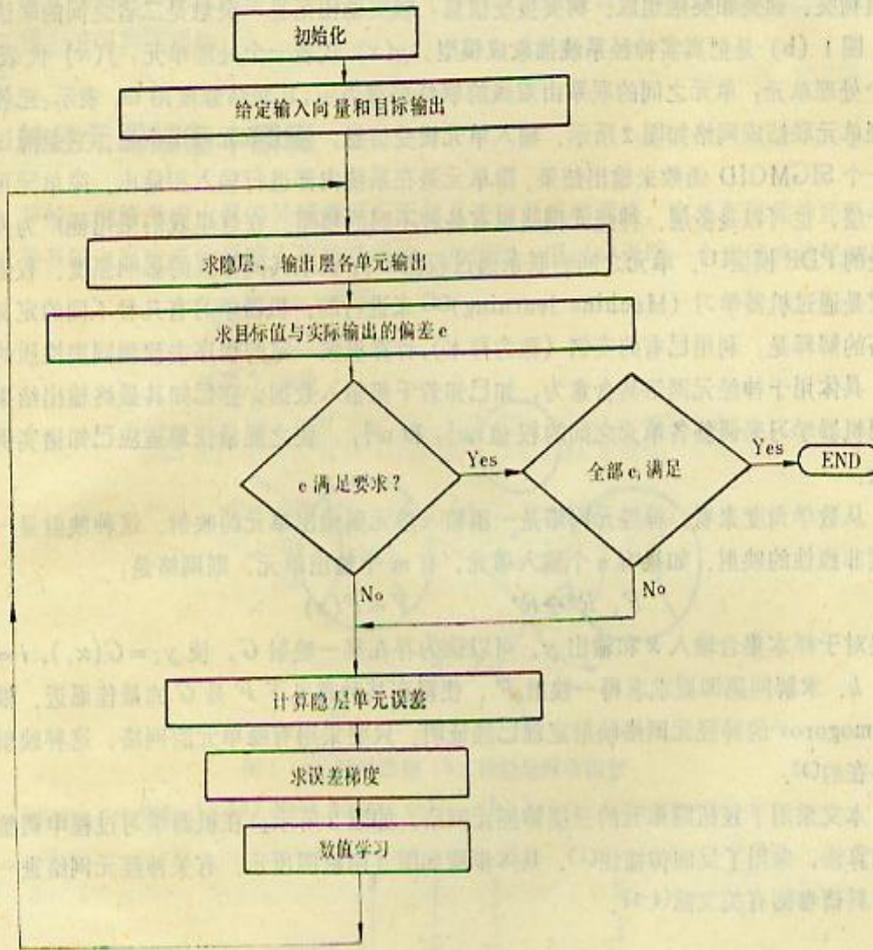


图3 反向传播法计算框图

Fig. 3 The flowchart of back-propagation method.

(3) 各种形状空隙的分布 (%)

颗粒之间的空隙, 联通的空隙, 微空隙.

(4) 平均空隙比

(5) 密度

此外, 对试件施加的压力 (MPa) 也是输入变量. 已知输出结果是三个正交方向 (A, B, C) 上的压缩系数. 我们把 30 个试验结果做为系统进行机器学习的学习样本, 以此来调整符合这 30 组输入和已经输出结果的最佳权值. 取另外 7 个试验结果做为考证本系统精确度的检定样品. 原始学习样本见表 1, 检定样品的结果见表 2.

从本算例可以看出利用神经网络进行岩石或岩石工程力学性态预测时具有以下的特点:

(1) 影响其力学性态的各种因素, 只要有相应的数据, 都能做为变量输入系统, 因素的数量多少不受限制.

表1 砂岩输入学习样本
Tab. 1 Input data of sandstones

样 本 编 号	矿物成分(%)				平均颗粒		密 度	平 均 空 隙 比 (%)	各种空隙的分布(%)			压 力 (MPa)	压缩系数		
	石 英	长 石	碎 屑 粘 土 质	其 它 成 分	尺 寸 (μm)	形 状			颗 粒 间 空 隙	联 通 空 隙	微 空 隙		A	B	C
1	80	0	18	2	65	SA	2.01	24.1	34	23	43	10	36.2	43.6	36.0
2	85	8	7	0	175	SS	1.98	23.8	67	11	22	100	32.7	24.0	29.3
3	70	15	12	3	90	SS	2.02	22.7	35	14	51	30	42.0	41.8	43.0
4	83	10	3	4	220	SA	1.78	30.5	72	4	24	50	43.1	40.8	35.0
5	65	5	28	2	95	AS	2.00	23.5	50	10	40	10	64.8	94.2	105.0
6	65	5	28	2	95	AS	2.00	23.5	50	10	40	50	44.1	55.2	54.9
7	65	5	28	2	95	AS	2.00	23.5	50	10	40	100	42.0	51.4	50.1
8	89	9	4	7	80	SA	2.21	15.6	57	26	17	30	25.5	31.8	45.4
9	80	9	4	7	80	SA	2.21	15.6	57	26	17	50	22.8	26.8	36.5
10	80	9	4	7	80	SA	2.21	15.6	57	26	17	100	20.2	32.9	30.9
11	94	0	1	5	120	SA	2.14	17.8	72	13	15	10	46.1	54.2	64.0
12	94	0	1	5	120	SA	2.14	17.8	72	13	15	30	28.9	28.8	32.5
13	94	0	1	5	120	SA	2.14	17.8	72	13	15	100	24.0	22.6	23.1
14	95	3	2	0	170	SS	2.13	18.1	76	14	10	10	40.1	50.5	34.0
15	95	3	2	0	170	SS	2.13	18.1	76	14	10	100	19.9	21.6	18.5
16	95	0	5	0	130	SS	2.03	21.7	76	10	14	30	32.8	29.0	30.2
17	98	0	2	0	350	SR	2.33	10.6	69	17	14	10	24.3	27.6	34.1
18	98	0	2	0	350	SR	2.33	10.6	69	17	14	50	14.1	15.6	15.8
19	98	1	2	1	115	R	1.94	24.1	70	14	16	30	33.2	35.9	35.4
20	98	1	2	1	115	R	1.94	24.1	70	14	16	100	25.0	28.8	26.0
21	90	2	1	7	100	R	2.18	16.8	60	19	21	10	34.3	26.2	36.8
22	90	2	1	7	100	R	2.18	16.8	60	19	21	50	21.8	24.0	23.2
23	92	0	8	0	120	SS	2.42	8.5	24	13	63	50	27.5	22.2	18.9
24	92	0	8	0	120	SS	2.42	8.5	24	13	65	30	36.5	28.5	22.7
25	90	4	6	0	145	SS	2.01	23.4	69	11	20	10	43.4	44.8	50.0
26	70	15	12	3	90	SS	2.02	22.7	35	14	51	10	86.0	67.2	86.4
27	83	5	8	4	65	SA	1.91	27.3	68	10	22	10	63.6	63.8	65.9
28	83	5	8	4	65	SA	1.91	27.3	68	10	22	30	46.5	47.2	53.6
29	85	8	7	0	175	SS	1.98	23.8	67	11	22	30	49.4	49.8	55.1
30	83	10	3	4	220	SA	1.78	30.5	72	4	24	10	46.8	46.4	38.4

表 2 计算结果及误差

Tab. 2 Results of calculation and their errors

样品 编号	矿物成分 (%)				平均颗粒 尺寸 (μm)	形状	密度	各种空隙的分布 (%)			压 力 (MPa)	压 缩 系 数			绝对误差 ($\text{MPa} \times 10^{-1}$)			相对误差 (%)						
	石 英	长 石	碎 屑 粘 土 质	其 它 成 分				平均 空 隙 比 (%)	颗 粒 空 隙	联 通 空 隙		微 空 隙	实 测 值			计 算 值			A	B	C	A	B	C
													A	B	C	A	B	C						
1	94	0	1	5	120	SA	2.41	17.8	72	13	15	50	26.0	24.9	27.0	25.0	25.2	24.3	1.0	0.3	2.7	3.8	1.1	10.0
2	95	0	5	0	130	SS	2.03	21.7	76	10	14	50	31.0	26.4	27.3	30.0	29.4	25.9	1.0	3.0	1.7	3.2	11.4	6.2
3	80	9	4	7	80	SA	2.21	15.6	57	26	17	10	34.4	48.6	82.9	59.9	65.1	87.0	25.5	16.5	4.1	74.0	34.0	4.9
4	96	1	2	1	115	R	1.94	24.1	70	14	16	10	47.8	50.5	50.4	41.9	39.7	49.9	5.9	10.8	6.5	12.3	24.4	12.9
5	90	4	6	0	145	SS	2.01	23.4	69	11	20	100	29.0	24.2	27.0	28.1	26.8	24.1	0.9	2.6	2.9	3.1	10.7	10.7
6	90	4	6	0	145	SS	2.01	23.4	69	11	20	50	30.5	27.4	30.9	34.8	33.0	32.3	4.3	5.6	1.4	14.1	20.4	4.5
7	75	9	15	1	85	SA	2.98	25.9	40	16	44	30	58.1	57.0	55.1	54.9	61.6	69.9	32.0	6.5	14.0	5.5	11.4	25.4

(2) 上述影响因素不论是数值的或描述性的因素, 如地质描述(本例中的颗粒形状), 甚至一些人为的因素(如岩石工程的施工方法, 管理水平等)均可做为变量输入, 此时需要设计一导入规则(afferent rule), 把描述性的信息变成系统可以辨认的信息。

(3) 预测结果有较小的离散性, 由本算例可以看出, 7个检定样品的结果, 相对误差小于10%的占全部21个答案的38%, 相对误差小于20%的占全部答案的76%, 相对误差小于30%的占90%, 只有10%的答案相对误差大于30%。

(4) 采用神经网络预测岩石或岩石工程的力学性状, 与经验公式方法一样, 需要有一定试验结果或实例做为学习样本之用, 学习样本数量愈大, 求得的结论精确度愈高。

表3 大同煤矿的输入实例

Tab. 3 Input cases of a coal mine

样本编号	煤层厚度 (m)	工作面长度 (m)	老顶厚度 (m)	岩石型类*	支撑条件**	来压步距 (m)
1	2.7	153	20.0	MFS	AF	88
2	3.3	83	18.0	MFS, I	AF	91
3	3.3	97	12.0	P	NFNS	56
4	2.9	140	20.1	FS, I	3FIS	84
5	2.8	142	24.0	P, I	AF	83
6	2.9	130	22.0	CMS	3FIS	92
7	2.9	135	9.4	MFS	3FIS	60
8	3.8	100	24.0	CS	3FIS	121
9	3.8	104	24.0	CS, I	AF	122
10	2.4	110	20.5	PS	AF	102
11	3.2	150	46.2	PS, I	3FIS	145
12	3.1	84	10.5	PS	3FIS	85
13	2.5	148	19.6	SS	3FIS	90
14	2.4	136	18.8	MFS, I	3FIS	82
15	2.4	144	28.7	FS	3FIS	134
16	4.1	90	11.0	CMS	AF	80
17	3.1	100	14.3	S	3FIS	100
18	4.1	152	18.0	CMS	3FIS	78
19	2.2	186	15.0	CMS	AF	70
20	3.0	100	12.0	SS	AF	68
21	3.0	80	6.0	FS	AFNS	40
22	2.4	120	22.9	S	AF	120
23	4.4	110	30.0	S, I	AF	117
24	2.5	125	14.5	S	3FIS	73

* MFS=中细粒砂岩, P=粉岩, FS=细砂岩, CMS=粗中粒砂岩, CS=粗砂岩, PS=砂页岩, SS=粉细砂岩, S=砂岩, I=注水。

** AP=四边固支, 3FIS=三固一简, NFNS=邻区邻简。

4 在岩石工程中的应用

为了说明本文所提供的方法在岩石工程中也是适用的,我们利用大同煤矿的资料,按神经网络的方法预测了老顶初次来压步距^[8],长壁采煤工作面的推进,导致了采场老顶的初次断裂和来压,初次来压阶段一般是工作面顶板伤亡事故的多发期,所以预测老顶初次来压步距,具有重大现实意义,根据现有资料把影响来压步距的因素定为:1.岩石种类;2.煤层厚度;3.工作面长度;4.抽象成的支撑条件;5.老顶厚度,在这里只考虑了上述五个因素,实际上还有些影响因素,由于没有收集相应的数据无法考虑,在实际工作中本法可以考虑更多的因素。

我们把24个实例做为系统学习的样本,取另外6个实例做为考核本系统的检定样品,输入的数据见表3,预测结果见表4。

表4 计算结果及误差

Tab. 4 Results of calculation and their errors

样品编号	煤层厚度 (m)	工作面长度 (m)	老顶厚度 (m)	岩石类型	支撑条件	实测来压步距 (m)	计算来压步距 (m)	绝对误差 (m)	相对误差 (%)
1	3.3	84	13.2	P	3FIS	86	104	18	21
2	3.2	150	46.2	PS	3FIS	160	150	10	6
3	2.9	114	18.0	S	3FIS	82	91	9	11
4	3.2	130	15.0	CMS	3FIS	73	71	2	3
5	2.2	160	13.8	MFS	AF	70	69	1	1
6	2.8	117	25.0	FS	AF	133	121	12	9

利用神经网络进行力学性态的预测,考虑的因素愈多,则预计的结果愈接近实际,即便本例只考虑了五个因素,便求得离散性较小的预测结果,由表4可见预计结果与实测值比较,相对误差在11%以下的占六个检定样品的83.3%,只有一个结果相对误差是21%,这样的相对误差可以认为是相当满意的结果。

5 结论

由于岩体力学性质错综复杂,传统的固体力学方法还难以圆满地处理岩体力学问题,于是损伤力学,随机有限元,模糊有限元等各种计算方法得以迅速发展,力求解决有关岩石力学与岩石工程问题,这是一条有效的途径,另一方面不妨借鉴其它学科的一些方法,用来解决我们学科的问题,本文把人工智能中的神经网络引入岩石力学与岩石工程领域就是一种尝试,通过本文的两个算例可以看出,凡是可以利用经验公式或回归分析的场所都可以利用本文所提出的方法,它输入变量的数量不受限制,又可以把描

述性的非数值的参量做为变量输入, 这是神经网络最突出的优点, 因此我们相信, 这一方法将会在岩石力学和岩石工程领域得到广泛的应用.

6 参考文献

- 1 Rumelhart DE, et al. Parallel distributed processing exploration in the microstructure of cognition, MIT Press, 1986.
- 2 Michalski RS, et al. Machine Learning, Morgan Kaufmann Publ.Inc., 1986.
- 3 Hecht-Nielsen R. Kolmogorov's mapping neural network existence theorem. Proc. IEEE 1st Int. Conf. on Neural Network, 1987, 3: 11-14.
- 4 Lippman RP. An introduction to computing with neural network. IEEE Transaction on Acoustics, Speech and Signal Processing Magazine, 1987, 4(22): 4-22.
- 5 Grossber S. Nonlinear neural network: principles, mechanisms and architectures. Neural Networks, 1988(1): 17-61.
- 6 Minsky M, Papert S. Perceptron, MIT Press, 1988.
- 7 Caruso L, et al. The physical peroperties of a set of sandstones. Part 1 & Part 2. Int. J. Rock Mech. Min. Sci. & Gemech. Abstr., 1985, 22(6): 381-392, 393-406.
- 8 何富连, 钱鸣高. 老顶初次来压步距的计算预测及其变化规律的研究. 岩石力学在工程中的应用 (第二次全国岩石力学与工程学术会议论文集). 知识工程出版社, 1989, 181-188.

PREDICTING MECHANICAL BEHAVIORS OF ROCK OR ROCK ENGINEERING BY NEURAL NETWORK

Zhang Qing Song Jiarong

(Northern Jiaotong University, Beijing 100044)

Abstract

In this paper the neural network, a method from artificial intelligence, was applied to rock mechanics and rock engineering to predict their mechanical behaviors. This method is similar to the method of empirical formula, but the distinguishing features of it are: the amount of effecting factors input to the system is unlimited and those descriptive ones such as geological factors etc. can be included as input variables in analysis. Two examples, one from rock specimens in lab and another from coal mine, were calculated for demonstration.

Key words: artificial intelligence, neural network, prediction of the mechanical behaviors of rock engineering.