

岩体微裂隙注浆量预测分析的遗传神经网络方法

The genetic algorithm-neural network method to forecast the miniature crack grouting in rock matrix

王述红, 郝哲

(东北大学资源与土木工程学院, 辽宁 沈阳 110004)

摘要: 提出一种用于岩体微裂隙注浆预测新方法——遗传神经网络方法, 即用遗传算法优化神经网络结构, 提高神经网络预测能力的新方法。实际工程实例表明, 该方法具有预测速度快、精度高、实用性强的特点, 是注浆量预测的有效方法。

关键词: 微裂隙注浆; 神经网络; 遗传神经网络模式; 预测; 岩体

中图分类号: TD 265

文献标识码: A

文章编号: 1000-4548(2001)05-0572-04

作者简介: 王述红, 男, 1969 年生, 东北大学资源与土木工程学院在读博士后, 主要从事岩土力学与工程方面的研究和教学工作。

WANG Shu-hong, HAO Zhe

(Northeastern University, School of Resource and Civil Engineering, Shenyang 110004, China)

Abstract: This paper provides a new forecasting method for miniature crack grouting in rock matrix—the genetic algorithm-neural network method, that is a new method to optimize the neural network structure, and to promote the forecasting ability of the neural network using genetic algorithm. A practical example shows that it is an effective method with rapid forecasting speed, high precision and strong practicability.

Key words: miniature crack grouting; neural network; the genetic algorithm-neural network mode; forecast; rock mass

1 引言^y

由于岩体的性质较土体复杂得多, 其裂隙的发育程度、大小和分布难以推断, 其赋存特征是影响岩体工程注浆量的主要因素, 而注浆量的预测在工程中具有重要的实际应用价值。采用传统的参照土体颗粒分布的相对均匀性, 岩体单一裂隙或均匀分布裂隙实验室模拟、工程类比等方法等进行模拟分析, 模型难以反映现场真实复杂的裂隙分布情况, 其注浆量的预测与实际用量相对偏差很大^[1]。

本文在文献[2, 3]的基础上提出了一种岩体微裂隙注浆量预测新方法——遗传神经网络方法, 该方法的特点是利用人工神经网络的高度非线性映射能力, 并用遗传算法优化神经网络结构, 提高神经网络预测的精确性。在位移反分析、钻孔裂缝产状确定等方面已有应用^[4~8], 本文主要针对岩体微裂隙注浆工程的特殊性, 用遗传算法优化神经网络结构, 工程实例中就山东莱芜铁矿谷家台注浆工程的实践进行预测。

2 遗传神经网络方法的提出

传统的用于注浆量的建模方法主要是时间序列分析方法^[1~3], 如 AR 法、ARMA 法和 ARIMA 法等。这些方法在本质上仍属于回归分析, 都是用确定的模型(函数)来表达变量间的关系。由于岩体结构的复杂性, 它所涉及的工程地质条件及岩体特性参数通常是不完全

定量的, 甚至是随机的、模糊的, 故难以用确定的数学模型加以描述。

人工神经网络是一门崭新的信息处理科学, 它具有模拟人类部分形象思维的能力, 是模拟人工智能的一条重要途径, 在地下工程注浆量预测方面发挥重要作用。目前广泛使用的为误差反向传播的前馈神经网络。它是一种有教师的学习算法, 它的任务是训练前馈神经网络将输入向量映射到期望的输出向量, 在训练阶段, 期望的输出与实际的输出之间的误差在层与层之间反向传播, 并适当地调节输入层与隐含层、隐含层与隐含层以及隐含层与输出层之间的连接权, 使得期望输出与实际输出之间的误差最小。

设有 L 对学习样本 $(\vec{x}_k, \vec{O}_k)$ ($k = 1, 2, \dots, L$)。设一个输入 $\vec{x}_k$ 经网络传播后得到的实际输出为 $\vec{y}_k$, 则它与要求的期望输出 $\vec{O}_k$ 之间的偏差为

$$E_k = \frac{1}{2} \sum_{i=1}^m (y_{k,i} - O_{k,i})^2 \quad (1)$$

式中 m 为输出层单元数; $y_{k,i}$, $O_{k,i}$ 分别为第 k 个样本第 i 分量的实际输出和期望输出。

这样整个样本集的总误差为

$$E = \sum_{k=1}^L E_k \quad (2)$$

^y 基金项目: 国家自然科学基金资助项目(59679019); 中国博士后科学基金资助项目

收稿日期: 2001-04-20

BP 网络学习算法的误差准则为通过学习不断调整权重系数 W_{ji} , 使得偏差 $E < \varepsilon$ 满足要求。权重系数 W_{ji} 的调整采用梯度下降法

$$\Delta W_{ji}^{(k)} = -\eta \left(\frac{\partial E_k}{\partial W_{ji}} \right) \quad (3)$$

式中 η 为学习速率, 用以控制学习速度。

所有学习样本对权 W_{ji} 的修正为

$$\Delta W_{ji} = \sum_k \Delta W_{ji}^{(k)} \quad (4)$$

由于神经网络的学习预测效果有时十分依赖于网络结构, 利用上述网络结构进行学习时, 容易陷入局部极小, 因此, 构造一个满意的网络结构非常重要。遗传算法的出现, 使其成为可能^[5, 6]。

遗传算法 (genetic algorithm, 简称 GA) 是一种模拟生物界自然进化过程的优化方法。群体在遗传算子作用下, 同时对空间中不同区域进行采样计算, 从而构成了一个不断进化的群体序列。对群体进行简单的复制、杂交和变异作用是遗传算法的精髓。为了寻找最优解, 传统方法是采用启发式策略, 在单个猜测解的邻域探寻, 即使算法中允许偶尔地跳跃到解空间中更远的部分, 这些启发式算法也往往趋于陷入局部最优, 通过保持在解空间不同区域中多个点的搜索, 遗传算法以很大的概率找到最优解。将遗传算法用于优化网络结构, 将减少人为选择网络结构的盲目性, 增强网络的学习效果和预测能力。与传统方法相比, 遗传算法具有更好的鲁棒性, 具有全局最优性、隐含并行性、算法的高度稳定性和广泛的可用性 (对目标函数不清的形态没有要求) 等优点。

3 遗传神经网络模型及其求解过程

推理是问题的求解过程, 就是使问题从初始状态转移到目标状态的方法和途径。神经网络推理是并行推理, 其求解过程分两个阶段: ①学习阶段, 利用建立的神经网络模型对输入样本进行学习 (训练), 建立各影响因素间复杂的非线性映射, 获得求解的知识领域 (存入人工神经网络知识库), 此阶段一般需要输入较多的工程实例, 覆盖面要尽可能广, 以保证知识的可靠性; ②预测求解阶段, 将待预测问题的输入指标经数据预处理送入训练好的网络, 网络自动将其与学得的知识进行匹配 (神经网络推理), 推理出合理的结果 (输出)。总之, BP 学习算法就是将信息从输入层向输出层以及从输出层向第一隐含层正反两方向传播, 通过不断调整各神经元的阈值, 使得误差信号达到最小, 完成神经网络学习 (训练); 学习后信息以并行分布方式贮存于网络中, 据此对未经学习的样本集进行推理和预测。

实际工程中, 注浆量和注浆率 (即注浆量占被注介质的体积百分数), 与注浆目的、注浆参数、注浆地层特性及注浆材料等因素密切相关, 这是一个难以确定但又十分重要的注浆参数指标。关于它的确定资料介绍较少, 一般注浆率在 1%~5%, 砂砾地层要大些, 如美国达 25%。岩体注浆较小些。本次研究的目的是依据现场注浆数据, 利用遗传算法优化神经网络结构, 建立遗传神经网络预测模型 (mode of genetic algorithm neural network), 并用来预测注浆量, 为现场注浆提供可靠的依据。

本文提出的用于注浆量预测的遗传神经网络方法, 首先是对前几步实测值进行搜索学习、优化, 具体步骤如下:

(1) 对神经网络遗传算法进行初始化设置, 包括进化代数、群体规模、每位参数中二进制数位数、变异率、随机种子数等;

(2) 随机产生一组可能的值作为父代, 其中每个染色体代表一个网络结构, 用一条染色体表示;

(3) 将参数的每一取值输入神经网络模型, 预测其注浆量值, 计算每条染色体的适应值 $f(x)$, 以反映这种模型预测注浆量序列分析的能力, 适应值 $f(x)$ 的计算式采用式 (1), 若适应值不理想, 则进行参数取值染色体的遗传进化操作;

(4) 对每一参数值的染色体进行复制、杂交、变异操作, 产生一子代群体重复进行 (3) 的操作, 直到找到最合理的参数值。

对神经网络结构及其相应学习参数进行优化的目的在于提高其训练精度。用遗传算法训练神经网络结构的流程图如图 1 所示。




图 1 GA 算法训练网络结构流程

Fig. 1 The training process of network with the genetic algorithms

山东莱芜铁矿矿区[#]22 勘探线从+ 30 m~ - 10 m 共 5 个水平, 加密孔注浆结束后, 每层注浆 6 个孔, 总共注浆孔数为 30 个。建构神经网络和基于遗传算法的遗传神经网络输入模型, 取如表 1 所示的 20 个注浆孔的实测原始数据为学习样本。

表 1 输入样本的原始数据
Table 1 The original input data

孔号	涌水量 /(m ³ ·h ⁻¹)	矿厚 /m	孔深 /m	注浆压力 /MPa	注浆量 /t
30- 1	10. 00	26. 19	49. 71	3. 4	5. 84
30- 2	8. 78	31. 69	63. 88	3. 4	3. 60
30- 3	108. 60	46. 30	66. 61	3. 4	2. 85
30- 4	126. 00	29. 36	64. 35	3. 4	22. 20
20- 1	1. 20	9. 96	50. 85	3. 5	6. 10
20- 2	3. 90	33. 25	63. 80	3. 5	2. 00
20- 3	4. 00	33. 60	58. 07	3. 5	2. 64
20- 4	5. 00	43. 97	63. 39	3. 5	2. 10
10- 1	1. 10	0	31. 43	3. 6	19. 65
10- 2	1. 46	1. 21	43. 73	3. 6	2. 10
10- 3	1. 20	16. 14	52. 19	3. 6	1. 50
10- 4	75. 60	29. 56	61. 92	3. 6	29. 50
01- 1	10. 50	3. 80	39. 01	3. 7	2. 10
01- 2	77. 76	13. 46	19. 98	3. 7	111. 60
01- 3	216. 00	11. 64	51. 74	3. 7	111. 90
01- 4	96. 25	3. 20	40. 86	3. 7	31. 25
- 10- 1	5. 69	14. 37	41. 60	3. 8	5. 06
- 10- 2	29. 32	19. 23	53. 35	3. 8	11. 70
- 10- 3	14. 48	13. 77	48. 08	3. 8	3. 15
- 10- 4	64. 19	15. 61	54. 78	3. 8	86. 35

计算中, 以涌水量、矿厚、孔深和注浆压力组成输入向量 **X**, 以注浆量为输出向量 **Y**。用一般神经网络计算比较简单, 只需将输入、输出原始数据均转化为 (0, 1) 的数据 {W/250, H/50, L/100, P/10, Q/150}, 代入程序迭代即可。表 2 为学习输入样本。

表 2 神经网络学习样本
Table 2 The data of neural network

孔号	输入向量 X	输出 Y
30- 1	{0. 040, 0. 524, 0. 497, 0. 34}	0. 038933
30- 2	{0. 0351, 0. 634, 0. 638, 0. 34}	0. 024
30- 3	{0. 434, 0. 926, 0. 666, 0. 34}	0. 019
30- 4	{0. 504, 0. 587, 0. 644, 0. 34}	0. 148
20- 1	{0. 005, 0. 199, 0. 508, 0. 35}	0. 040667
20- 2	{0. 016, 0. 665, 0. 638, 0. 35}	0. 013333
20- 3	{0. 016, 0. 672, 0. 581, 0. 35}	0. 0176
20- 4	{0. 020, 0. 879, 0. 634, 0. 35}	0. 013333
10- 1	{0. 004, 0. 0. 314, 0. 36}	0. 131
10- 2	{0. 006, 0. 024, 0. 437, 0. 36}	0. 014
10- 3	{0. 005, 0. 323, 0. 522, 0. 36}	0. 01
10- 4	{0. 302, 0. 591, 0. 619, 0. 36}	0. 196667
01- 1	{0. 042, 0. 076, 0. 390, 0. 37}	0. 014
01- 2	{0. 311, 0. 269, 0. 199, 0. 37}	0. 744
01- 3	{0. 864, 0. 233, 0. 517, 0. 37}	0. 746
01- 4	{0. 385, 0. 064, 0. 408, 0. 37}	0. 208333
- 10- 1	{0. 022, 0. 287, 0. 416, 0. 38}	0. 033733
- 10- 2	{0. 117, 0. 384, 0. 533, 0. 38}	0. 078
- 10- 3	{0. 058, 0. 275, 0. 481, 0. 38}	0. 021
- 10- 4	{0. 257, 0. 312, 0. 548, 0. 38}	0. 575667

样本训练误差 *E* 和循环次数 *t* 是程序运行的两个结束标准, 为计算精确, 迭代中程序结束标准为 *E*= 0, *t*= 10000。

选取学习率 η = 0. 9, 隐含层数 *c*= 1, 隐层节点数 *n*₁= 8, 用两种神经网络进行训练。

对于一般的网络, 输入节点数 *n*= 4, 输出节点数 *m*= 1; 对神经网络 *n*= 20, *m*= 1。

网络训练结果: 一般神经网络 $E= 6. 445 \times 10^{-5}$, 遗传神经网络 $E= 9. 016 \times 10^{-7}$, *E* 为网络总误差。

用 BP 算法训练多层前馈神经网络时, 网络权值在学习过程中不断得到修正, 直到达到稳定值。学习参数取值的合理性直接影响到网络的学习速度、收敛性能和推广应用, 这是因为网络在学习过程中, 常常会出现系统误差的局部振荡“原地踏步”及收敛速度缓慢等问题。出现这些问题的一个主要原因是由于学习参数的取值不合理。

优化后的 BP 网络结构结构参数为 *n*= 20, *m*= 1, *c*= 1, *n*₁= 8, *k*= 20, η = 0. 9, α = 0. 7, *E*= 0, *t*= 10000。用这些参数对网络进行训练, 表 3 为遗传神经网络学习(训练)结果与实测值的对比。

表 3 实测值与遗传神经网络学习结果对比

Table 3 Contrast of the measured values to result of genetic algorithmr neural network

孔号	实测值 (Q/150)	样本学习 结果	孔号	实测值 (Q/150)	样本学习 结果
30- 1	0. 038933	0. 038868	10- 3	0. 01	0. 013416
30- 2	0. 024	0. 025663	10- 4	0. 196667	0. 196615
30- 3	0. 019	0. 019517	01- 1	0. 014	0. 016636
30- 4	0. 148	0. 148042	01- 2	0. 744	0. 743968
20- 1	0. 040667	0. 039839	01- 3	0. 746	0. 746006
20- 2	0. 013333	0. 010573	01- 4	0. 208333	0. 208318
20- 3	0. 0176	0. 017192	10- 1	0. 033733	0. 033205
20- 4	0. 013333	0. 011672	10- 2	0. 078	0. 077914
10- 1	0. 131	0. 130948	10- 3	0. 021	0. 020968
10- 2	0. 014	0. 012363	10- 4	0. 575667	0. 575693

4 工程实例

莱芜铁矿谷家台矿区由于涌水量大, 采矿工作难以顺利进行, 经多方论证, 矿体为上盘中奥陶系灰岩, 岩溶含水层为矿区主要含水层, 其余含水性较弱, 相对堵水。为加快采矿速度, 决定对灰岩顶板进行注浆堵水, 而注浆量大小直接关系到用料多少, 对注浆量进行预测成为工程建设的关键。东北大学注浆课题组承担了注浆工作, 在对现场灰岩分布情况做了彻底清查, 摸清了微裂隙网络模拟的原始数据, 并在进行的注浆初步实践的基础上, 采用遗传神经网络对注浆量进行了预测。

下面用遗传神经网络方法对各水平的# 5, # 6 孔注浆量进行预测。首先建立网络所需输入的模型, 对# 30- 5 孔: $W = 0.46, H = 26.39, L = 58.60, P = 2.3$, 则

$$\begin{aligned}\mu(W_1) &= 1 - (0.46 - 0) / (50 - 0) = 0.9908; \\ \mu(W_2) &= 1 - (50 - 0.46) / (50 - 0) = 0.0092; \\ \mu(H_3) &= 1 - (26.39 - 25) / (35 - 25) = 0.861; \\ \mu(H_4) &= 1 - (35 - 26.39) / (35 - 25) = 0.139; \\ \mu(L_3) &= 1 - (58.60 - 50) / (60 - 50) = 0.14; \\ \mu(L_4) &= 1 - (60 - 58.60) / (60 - 50) = 0.86; \\ \mu(P_1) &= 1 - (3.4 - 3.2) / (3.4 - 3.2) = 0; \\ \mu(P_2) &= 1 - (3.4 - 3.4) / (3.4 - 3.2) = 1.\end{aligned}$$

从而输入向量为 $X = \{0.9908, 0.0092, 0, 0, 0, 0, 0.861, 0.139, 0, 0, 0.14, 0.86, 0, 0, 1, 0, 0, 0\}$ 。

再次将输入向量 X 代入已训练好的网络, 即可得预测输出值。

将此数据输入程序即可对注浆量 Q 进行预测, 表 4 与图 2 是遗传神经网络预测结果与实测结果的对照(结果已经还原), 图 2 中序号与表 4 中孔号是对应的。




图 2 注浆量实测值与预测值散点对照图

Fig. 2 The measured and forecast values

表 4 实测值与遗传神经网络预测值对照表

Table 4 Contrast of measured values to those forecast with genetic algorithm neural network method

序号	孔号	实测值 /t	一般神经网络预测值/t	遗传神经网络预测值/t
1	30- 5	3.30	5.7687	3.3574
2	30- 6	2.70	2.22	2.4351
3	20- 5	3.15	2.3832	3.0004
4	20- 6	9.30	3.90645	7.8681
5	10- 5	5.50	4.3645	5.2114
6	10- 6	6.15	6.5868	6.2334
7	01- 5	1.00	1.18245	1.1242
8	01- 6	1.00	1.3902	1.2684
9	- 10- 5	2.25	1.97795	2.0475
10	- 10- 6	3.50	3.76095	3.6102

从以上分析可以看出, 遗传神经网络由于发挥了人工智能的推理、理解、规划、决策、抽象、自学习和创造功能, 使施工方案优选工作大大地科学化、自动化, 避免了人为的遗漏及繁琐的手工劳动, 提高了工作效率, 使大型复杂的工程设计计算优化工作成为可能。

5 结 语

(1) 提出并建立了注浆量的遗传神经网络求解模型。用遗传算法优化神经网络结构, 既减少了人为选择网络结构的盲目性, 又提高了网络学习的效率和推广预测的能力, 通过对样本的训练和预测, 证明了遗传神经网络方法应用于注浆中的科学性、准确性和可行性。

(2) 现场数据一般都有较大离散性, 若用传统的回归分析必然要舍弃大量的漂移点, 而人工神经网络具有高度的非线性函数映射功能, 它忠实于样本交给它的知识, 只对样本提供的知识负责, 比其他方法有更高的精度。

(3) 基于 GA- NN 方法预测注浆量是一种新的预测方法, 应用遗传神经网络方法预报现场注浆量, 可提供重要的注浆材料需求信息, 以便进行注浆的优化设计, 只要根据具体问题更换模型训练样本数据集、优选适当遗传神经网络结构, 就可以获得相应的注浆量预测值, 遗传神经网络方法在地下工程注浆量预测预报中具有广泛的应用前景。

(4) 实例表明, 该方法具有预测速度快、精度高、实用性强的特点, 是注浆量预测的有效方法, 在工程中具有借鉴意义。

(5) 需要说明的是, 用于预测注浆量的 GA- NN 方法也是一种通用注浆分析方法, 由于 GA- NN 结果受到样本数据集影响, 对于一些复杂问题结果的深入讨论, 笔者将另文专述。

感谢东北大学刘 斌教授和冯夏庭教授对本文提供的无私帮助!

参考文献:

- [1] 郝 哲, 王介强, 何修仁. 岩体裂隙注浆的计算机模拟研究[J]. 岩土工程学报, 1999, 21(6): 727~ 730.
- [2] 王述红, 田 军, 刘 斌, 等. 遗传神经网络方法在大型地下结构位移演化预测预报中应用[J]. 东北大学学报(自然科学版), 2000, 22(5): 84~ 87.
- [3] 刘 勇, 康立山, 陈毓屏. 非数值并行算法(第2册): 遗传算法[M]. 北京: 科学出版社, 1997. 122~ 148.
- [4] 冯夏庭, 张治强, 杨呈祥, 等. 位移反分析的进化神经网络方法研究[J]. 岩石力学与工程学报, 1999, 18(5): 529~ 533.
- [5] 安美建, 李方全, 石耀霖. 遗传算法在确定钻孔裂隙产状中应用[J]. 岩石力学与工程学报, 1997, 16(5): 418~ 423.
- [6] 王述红, 刘 斌, 刘之洋. 南芬铁矿 1 号驱动站大洞室围岩自稳结构及其稳定性研究[J]. 中国矿业, 1998(5): 84~ 87.
- [7] 史忠植. 高级人工智能[M]. 北京: 科学出版社, 1998.
- [8] 冯夏庭. 智能岩石力学导论[M]. 北京: 科学出版社, 2000.