

煤层底板突水组合人工神经网络预测 Combined ANN forecast of water-inrush from coal floor

王连国¹, 宋 扬²

(1. 山东科技大学 土木建筑学院, 山东 泰安 271019; 2. 山东科技大学 资源与环境工程学院, 山东 泰安 271019)

摘要: 综合考虑水源、水压、隔水层、断层等因素对煤层底板突水的影响, 采用遗传算法训练人工神经网络, 建立了煤层底板突水组合人工神经网络预测模型。实例分析表明, 采用遗传算法训练 BP 网络明显提高了人工神经网络的预测精度, 使预测结果更加可靠。

关键词: 煤层底板; 突水; 人工神经网络; 遗传算法; 预测

中图分类号: TB 115

文献标识码: A

文章编号: 1000-4548(2001)04-0502-04

作者简介: 王连国, 男, 1963年生, 博士, 山东科技大学土木建筑学院副教授, 主要从事岩土工程与系统工程的教学与科研工作。

WANG Lian-guo, SONG Yang

(1. Institute of Civil and Architecture Engineering, Shandong University of Science and Technology, Tai'an 271019, China; 2. Institute of Resource and Environmental Engineering, Shandong University of Science and Technology, Tai'an 271019, China)

Abstract: This paper considers comprehensively water source, water pressure, water impedance strata, and fault etc to establish a combined ANN forecast model of water-inrush from coal floor by using genetic algorithms to train ANN. The analysis of actual examples indicates the forecast precision of ANN trained by genetic algorithms is obviously enhanced, so that it makes the predicted result more reliable.

Key words: coal floor; water-inrush; ANN; genetic algorithms; forecast

1 引言*

人工神经网络(Artificial Neural Networks, 简称 ANN)理论是 80 年代中后期在世界范围内迅速发展起来的一门非线性科学。网络的信息处理由人工神经元之间相互作用来实现, 知识与信息的存储表现为网络元件互连间分布式的物理关系; 网络的学习与识别决定于各神经元连接权系数的动态演化过程。

人工神经网络在生物学、医学、自动控制等^[1,2]方面都得到了较深入的研究和广泛的应用。近几年来, 人工神经网络的研究和应用也渗透到地学领域^[3~7]。

BP 神经网络在人工神经网络中应用最为广泛, 取得了许多成果, 但这种网络却有两个重要的缺陷: 一是存在较多局部极小的情况下很容易陷入局部极小点; 二是学习精度与学习速度之间的矛盾不可避免。为此, 我们采用了遗传算法训练 BP 网络, 利用遗传算法全局最优搜索的特性可完全弥补 BP 网络上述的缺陷, 在此基础上建立了煤层底板突水组合人工神经网络预测模型。

2 煤层底板突水组合人工神经网络预测模型

2.1 BP 网络算法

设有任意大小的多层前向神经网络, 各神经元的激励函数选取为 Sigmoid 函数:

$$f(x) = 1/(1 + e^{-x}) \quad (1)$$

如图 1 所示, 设有 m 个学习样本 $(X_k, Y_k) (k = 1,$

$2, \dots, m)$, X_k, Y_k 分别为第 k 个样本的输入、期望输出矢量, 其中, $X_k = (x_{k1}, x_{k2}, \dots, x_{kn})$, $Y_k = (y_{k1}, y_{k2}, \dots, y_{kp})$ 。对于某一个输入 X_k , 网络的实际输出为 Y'_k , 节点 i 的输出为 O_{ki} , 节点 j 的输入为

$$\text{net}_{kj} = \sum_i W_{ji} O_{ki} \quad (2)$$

节点 j 的输出为 $I_{kj} = f(\text{net}_{kj})$ (3)

对应网络的期望输出 Y_k , 有输出误差:

$$E_k = \frac{1}{2} \sum_j (y_{kj} - y'_{kj})^2 \quad (4)$$




图 1 BP 网络结构

Fig. 1 Framework of BP network

训练集中每个样本输入至网络时, 网络的权重 W_{ji} 都作相应的调整, 其改变是为满足

$$\Delta_k W_{ji} = \mu \delta_{kj} \cdot O_{ki} \quad (5)$$

若 j 是输出层, 则有

$$\begin{aligned} \delta_{kj} &= (y_{kj} - y'_{kj}) \frac{\partial I_{kj}}{\partial \text{net}_{kj}} = (y_{kj} - y'_{kj}) I_{kj} (1 - I_{kj}) \\ &= (y_{kj} - y'_{kj}) y'_{kj} (1 - y'_{kj}) \end{aligned} \quad (6)$$

若 j 是隐含层, 则有

$$\delta_j = I_{kj}(1 - I_{kj}) \sum_l \delta_{kl} \cdot W_{lj} \quad (7)$$

式中 δ_{kl} 为节点 j 上一节点 l 的误差信号; W_{lj} 为节点 j 到其上一节点 l 的连接权重。

为加速权重收敛, 在网络学习过程中引入动量因子项 α , 对式(5)修正如下:

$$\Delta_k W_{ji}(t+1) = \mu \cdot \delta_j \cdot O_{ki} + \alpha \Delta W_{ji}(t) \quad (8)$$

式中 t 为训练样本模式 K 出现的次数; α 为动量系数, 一般取 $0 < \alpha < 1$, 它决定过去权重对目前权重变化的影响程度; μ 为学习步长, 一般取 $0 < \mu < 1$ 。

从本质上讲, BP 网络算法是把一组样本的输入输出问题变为一个非线性优化问题, 可将其视为从 n 维空间到 p 维空间的映射。

如前所述, BP 网络目前虽然已应用到众多领域, 取得许多可喜的成果, 但它仍然存在以下两方面的缺陷, 如果处理不当, 就会影响运算的精确度。

(1) 由于 BP 网络算法采用误差导数指导学习过程, 从本质上来说属于局部寻优算法, 在存在较多局部极小的情况下, 很容易陷入局部极小点。

(2) 学习精度与学习速度之间的矛盾不可避免: 当学习速度较快时, 学习过程容易产生振荡, 难以得到精确的结果; 而学习速度较慢时虽然结果可以得到较高的精度, 但学习周期太长, 也不实用。

为了克服 BP 网上述缺陷, 我们充分利用遗传算法^[8]全局最优搜索的特性来训练 BP 网络, 建立了底板突水组合人工神经网络预测模型。

2.2 煤层底板突水组合人工神经网络预测模型

遗传算法全局寻优的特性为我们使用 BP 网络进行煤层底板突水预测开辟了一条新途径。BP 网络对煤层底板突水预测的优选模型结构最终表示为一组优化权值, 用以表征输入与输出间复杂的映射关系。而 BP 网络自身的局限性有时不能保证所优选权值为全局最优, 结合遗传算法, 我们所构造的煤层底板突水组合人工神经网络预测模型, 可完全弥补 BP 网络这方面的不足。

(1) 确定组合模型中的 BP 网络结构

通过对大量底板突水案例的统计分析, 选取了 5 个影响因素: 水压、含水层、隔水层厚度(底板岩层厚度)、底板采动导水裂隙带深度、断层落差(对底板破坏型突水而言断层落差取零)作为预测底板突水的控制参数, 即网络的输入, 网络的输出即为底板突水量等级, 按煤炭科学研究总院西安分院王梦玉等人的划分方案, 将底板突水量分为 4 个等级(见表 1)。参数取值的原则是能完全定量地尽量用定量数据表示, 不能量化的用二值模式表示。定性因素取值原则如表 1 所示。

表 1 变量定义

Table 1 Definition of variables

变量名称	变量类型	变量取值
含水层	薄层灰岩	1
	厚层灰岩	0
最大突水量	$Q < 600$ (小型突水)	1000
	$600 \leq Q < 1200$ (中型突水)	0100
	$1200 \leq Q < 3000$ (大型突水)	0010
	$Q \geq 3000$ (特大型突水)	0001

由以上分析可知, 输入节点数为 $Q_i = 5$, 输出节点数 $Q_j = 4$ 。隐含节点数 Q_k 可通过训练样本试算确定。

(2) 编码策略

一般每一个网络用一个二进制串的染色体来表示。网络中的每一个参数用 P 个二进制表示。每个网络的染色体为所有参数基因串接而成。本模型 P 取 10, 第一位为符号位, 1 取正值, 0 取负值。则编码形式为

11000101110110011010...0111010111

W_{m1}

W_{m2}

W_{mQ}

(m 为群体数, Q 为网络具有的参数个数)

(3) 适应度函数

遗传算法优化人工神经网络权值的一个重要问题, 是如何定义合理的适应度函数。一般可用误差函数 E 来衡量。

定义训练网络权值的误差函数为 $E_k = \sum_j (y_{kj} - y'_{kj})$ ($k = 1, 2, \dots, n; j = 1, 2, \dots, Q_j$), 其中 y_{kj} , y'_{kj} 分别为前向训练中的期望输出和实际输出值。在 n 个训练集内, 总误差为 $E = \frac{1}{n} \sum_k E_k = \frac{1}{n} \sum_k \sum_j (y_{kj} - y'_{kj})$ 。因习惯中取大的适应度进行优选, 可取适应度函数 $f = 1 - E$ 。对误差水平, 根据经验, BP 网络的误差水平取 0.0001, 则组合模型的误差水平取 $e = 1 - 0.0001$ 。

(4) 选择

保存上一代最优个体($\max f_i$), 直接进入下一代群体。

(5) 交叉

以概率 $f_i / \sum f_i$ 选择个体 i , 以概率 $f_j / \sum f_j$ 选择个体 j , 从群体中选出两个串 Z_i , Z_j , 在随机选定交换位置基础上, 以交换概率 P_j 进行交换操作, 得到新的串 Z'_i , Z'_j 。

(6) 变异

变异操作分两种情况, 由于基因的第一位表示正负号, 该位的变异概率要小于其他位的变异概率 (P_b)。在本模型中取前者为后者的 0.1 倍。对新串 Z'_i , Z'_j 的各位进行变异操作, 变异结果进入下一群体。

煤层底板突水组合人工神经网络预测模型运算过程如图 2 所示。

表 2 训练样本

Table 2 Training samples

序号	工作面名称	水压 /MPa	含水层	隔水层厚度 /m	底板采动导水 裂隙带深度/m	断层落差 /m	最大 突水量
1	淮南谢一矿 33 采区底板	2.00	1	30.0	12.9	1.5	0100
2	焦作九里山矿 12031 工作面	1.80	1	23.0	12.3	0.0	0010
3	新汶潘西矿潘东井 106 工作面	1.70	0	10.0	10.7	5.0	0001
4	肥城陶阳矿 9901 工作面	0.60	1	17.0	8.6	8.0	0100
5	肥城大封矿 9204 工作面	1.08	1	16.5	16.5	3.2	0010
6	肥城陶阳矿 9906 工作面	1.42	1	25.7	15.2	0.0	1000
7	淄博夏庄矿二井 1007 工作面	5.19	0	55.9	17.0	7.0	0001
8	焦作王封矿 1441 工作面	1.10	1	20.0	8.5	15.0	0001
9	峰峰二矿 2682 工作面	2.90	1	40.0	20.9	0.0	0100
10	新汶协庄矿 31104 东工作面	1.30	1	30.0	18.3	4.9	0010
11	淄博龙泉矿 149 工作面	4.06	0	65.9	16.0	10.0	0010
12	肥城陶阳矿 9903 工作面	0.85	1	23.1	13.9	0.4	1000
13	淮北杨庄矿 II617 工作面	3.11	1	44.3	14.4	3.5	0001
14	峰峰一矿 1532 工作面	2.30	0	7.3	7.3	0.0	0001
15	肥城查庄矿 7505 工作面	1.01	1	18.0	11.7	0.0	1000




图 2 组合网络运算过程

Fig. 2 Calculating process of combined BP network

3 实例分析

从大量的煤层底板突水案例中选取 15 个典型采煤工作面底板突水资料作为训练样本, 如表 2 所示, 其中含水层及最大突水量按表 1 的定义取值。

根据表 2, 建立 BP 网络, 其中输入层节点 5 个, 各节点取值与表 2 对应, 输出层节点为 4 个, 分别对应最大突水量的 4 个等级隐含层取 15 个节点。用遗传算法训练该 BP 网络, 运算 400 代达到要求精度, 表 3 为用训练好的网络对训练样本进行学习的结果。由表 3 可知, 网络采用遗传算法训练后, 已充分掌握了数据间复杂的非线性关系, 可用作学习好的网络进行预测。

表 4 为 4 个采煤工作面底板突水资料, 表 5 为利用上述训练好的网络对这 4 个采煤工作面煤层底板突水情况预测的结果。另外, 我们仅采用 BP 算法同样用表 2 中的训练样本对网络进行训练, 并用训练好的网络对表 4 中的 4 个采煤工作面煤层底板突水情况进行了预测, 其预测结果如表 6 所示。

从表 5、6 可以看出, 如果以 4 个输出节点值最大者作为突水判断依据, 采用遗传算法训练的网络, 4 个全部判对, 判对率达到 100%, 预测效果比较理想, 而仅采用 BP 算法训练的网络, 在 4 个突水工作面中, 仅判对了 3 个, 判对率为 75%。可见采用 BP 神经网络和遗传算法的组合模型进行底板突水预测比单一的 BP 网络具有较大的优越性, 很好地弥补了 BP 网络的缺陷。

以上基于 BP 人工神经网络的非线性动力学机制, 并考虑到 BP 网络存在的缺陷, 采用遗传算法训练 BP 网络, 建立了煤层底板突水量预测的组合神经网络预测模型。实例分析表明, 采用遗传算法训练 BP 网络明显提高了人工神经网络的预测精度, 证实了用组合人工

表 3 训练样本的学习结果
Table 3 Study results of training samples

序号	实际突水量	预测突水量	误差	序号	实际突水量	预测突水量	误差	序号	实际突水量	预测突水量	误差
1	0	0.00012	0.00012	6	1	0.98958	- 0.01042	11	0	0.00556	0.00556
	1	0.99465	- 0.00535		0	0.00028	0.00028		0	0.00024	0.00024
	0	0.00121	0.00121		0	0.00139	0.00139		1	0.99231	- 0.00769
	0	0.00517	0.00517		0	0.00875	0.00875		0	0.00102	0.00102
2	0	0.00200	0.00200	7	0	0.00244	0.00244	12	1	0.99535	- 0.00465
	0	0.00029	0.00029		0	0.00006	0.00006		0	0.00014	0.00014
	1	0.99683	- 0.00317		0	0.00095	0.00095		0	0.00085	0.00085
	0	0.00008	0.00008		1	0.99760	- 0.00240		0	0.00386	0.00386
3	0	0.00039	0.00039	8	0	0.00073	0.00073	13	0	0.00033	0.00033
	0	0.00276	0.00276		0	0.00011	0.00011		0	0.00008	0.00008
	0	0.00728	0.00728		0	0.00274	0.00274		0	0.00093	0.00093
	1	0.99167	- 0.00833		1	0.99638	- 0.00362		1	0.99843	- 0.00157
4	0	0.00331	0.00331	9	0	0.00068	0.00068	14	0	0.00195	0.00195
	1	0.99682	- 0.00318		1	0.99370	- 0.00630		0	0.00056	0.00056
	0	0.00004	0.00004		0	0.00008	0.00008		0	0.00005	0.00005
	0	0.00208	0.00208		0	0.00413	0.00413		1	0.99787	- 0.00213
5	0	0.00325	0.00325	10	0	0.00016	0.00016	15	1	0.99343	- 0.00657
	0	0.00154	0.00154		0	0.00186	0.00186		0	0.00031	0.00031
	1	0.99571	- 0.00429		1	0.99763	- 0.00237		0	0.00213	0.00213
	0	0.00035	0.00035		0	0.00049	0.00049		0	0.00436	0.00436

表 4 预测样本
Table 4 Training samples

序号	工作面名称	水压 /MPa	含水层	隔水层厚度 /m	底板采动导水 裂隙带深度/m	断层落差 /m	最大 突水量
1	峰峰二矿 2671 工作面	2.80	1	40.0	15.0	6	1310
2	焦作韩王矿 2131 工作面	1.10	1	16.0	8.0	0	900
3	大封 9206 工作面	1.26	1	23.5	8.5	0	436
4	焦作冯营矿 1301 工作面	1.90	1	15.0	13.0	65	5082

表 5 文中方法预测结果
Table 5 Forecast result of method in this paper

序号	实际突水量	预测突水量	误差	序号	实际突水量	预测突水量	误差
1	0	0.00054	0.00054	3	1	0.99830	- 0.00170
	0	0.00126	0.00126		0	0.00021	0.00021
	1	0.98933	- 0.01067		0	0.00085	0.00085
	0	0.00879	0.00879		0	0.00113	0.00113
2	0	0.01671	0.01671	4	0	0.00089	0.00089
	1	0.73625	- 0.26375		0	0.00021	0.00021
	0	0.27450	0.27450		0	0.00007	0.00007
	0	0.00052	0.00052		1	0.99852	- 0.00148

表 6 BP 法预测结果
Table 6 Forecast result of BP method

序号	实际突水量	预测突水量	误差	序号	实际突水量	预测突水量	误差
1	0	0.00016	0.00016	3	1	0.95331	- 0.04699
	0	0.00273	0.00273		0	0.00046	0.00046
	1	0.93460	- 0.06064		0	0.00571	0.00571
	0	0.00761	0.00761		0	0.00418	0.00418
2	0	0.51906	0.51906	4	0	0.02362	0.02362
	1	0.31874	- 0.68126		0	0.00161	0.00161
	0	0.00132	0.00132		0	0.00683	0.00683
	0	0.00025	0.00025		1	0.95638	- 0.04362

神经网络预测模型对煤层底板突水进行预测具有较高的准确性, 用其进行煤层底板突水预测结果更加可靠。

参考文献:

[1] 胡守仁. 神经网络应用技术[M]. 长沙: 国防科技大学出版社, 1998. 33~ 41.

[2] 王永骥, 涂健. 神经元网络控制[M]. 北京: 机械工业出版社, 1998. 7~ 21.

[3] 李东升, 王炜, 黄冰树. 人工神经网络及其在地震预报中的应用[J]. 地震, 1995, (4): 379~ 383.

[4] 夏宏泉, 廖明光. 基于人工神经网络的测井评价油气污染研究[J]. 西南石油学院学报, 1998, 20(2): 12~ 15.

[5] 周保生, 朱维申. 巷道围岩参数的人工神经网络预测[J]. 岩土力学, 1999, 20(1): 22~ 26.

[6] 黄润秋, 许强. 工程地质广义系统科学分析原理及应用[M]. 北京: 地质出版社, 1997. 139~ 143.

[7] 蔡煜东, 宫家文, 姚林声. 砂土液化的人工神经网络模型[J]. 岩土工程学报, 1993, 15(6): 53~ 58.

[8] 周明, 孙树栋. 遗传算法原理及应用[M]. 北京: 国防工业出版社, 1999. 18~ 32.