



移动扫码阅读

张承斌.基于BP神经网络的煤层底板突水量等级预测[J].能源环境保护,2022,36(6):101-109.
ZHANG Chengbin. Prediction of the level of water inrush from coal seam floor based on BP neural network [J]. Energy Environmental Protection, 2022, 36(6):101-109.

基于BP神经网络的煤层底板突水量等级预测

张承斌

(山东省煤田地质局第三勘探队,山东 泰安 271000)

摘要:为了减少水灾损失并提高煤矿底板突水量预测精度,基于肥城矿区相关矿井水文地质资料,选取水压、底板裂隙发育程度、断层落差、岩溶发育程度、含水层厚度、隔水层厚度等6项指标,建立了肥城矿区底板突水量等级预测模型,采用平均影响值(MIV)方法评价了神经网络模型中各自变量对突水量等级预测的影响程度。结果表明:该模型具有较高的预测精度;肥城矿区内的小型突水主要由含水层及隔水层的属性决定;大型及特大型突水的发生与断裂构造、岩溶和底板裂隙发育程度等因素密切相关。

关键词:底板突水;BP神经网络;预测模型;平均影响值(MIV);肥城矿区

中图分类号:X45;X523 **文献标识码:**A **文章编号:**1006-8759(2022)06-0101-09

Prediction of the level of water inrush from coal seam floor based on BP neural network

ZHANG Chengbin

(The Third Exploration Team of Shandong Coalfield Geologic Bureau, Taian 271000, China)

Abstract:In order to reduce flood loss and improve the prediction accuracy of water inrush from coal seam floor, a prediction model of water inrush grade in Feicheng mining area was established based on the mine hydrogeological data of this area, selecting six indexes including water pressure, development degree of floor fissure, fault gap, karst development degree, aquifer thickness and aquiclude thickness. The method of mean impact value (MIV) was used to evaluate the influence of each variable in the neural network model on the prediction of water inrush grade. The results show that this model has high prediction accuracy. Small water inrush in Feicheng mining area is mainly determined by the attributes of the aquifer and aquiclude. The occurrence of large and extra-large water inrush is closely related to the factors such fault structure, karst and development degree of floor fissure.

Key Words:Water inrush from coal seam floor; BP neural network; Prediction model; Mean impact value (MIV); Feicheng mining area

0 引言

肥城矿区受煤层底板突水水害威胁严重,矿区内69%的可采储量受水害威胁。自开采以来,共发生突水300余次,其中60%以上属于底板突水。最大的一次为1993年1月5日,国庄矿-210

水平北大巷施工过程中,遇到隐伏的陷落柱,发生底板奥灰突水,突水量达 $32\ 970\ m^3/h$,是继开滦范各庄突水事故之后的中国采矿史上又一次罕见的特大型突水,使国庄矿及相邻南高余、隆庄矿被淹,造成了高达11 017.9万元的巨大经济损失^[1-2]。因此,深入研究肥城煤田的底板突水机

理,正确地评价及预测该井田深部开采时底板突水的可能性及突水量等级,有利于提出科学的风险预防决策,进一步提升煤矿生产安全性^[3-4]。

在国内外针对突水机理及预测的研究中,大量专家学者提出了顶板的压力拱假说、悬臂梁假说、铰接岩块假说、“上三带”理论和底板的突水系数法、“下三带”理论^[6-7]、关键层理论^[8]、原位张裂和零位破坏理论^[9]、板模型理论等诸多理论方法^[10-11]。但矿井水害发生的影响因素众多,各因素共同构成一个复杂的地学系统,相互间具有强烈的非线性动力学关系^[12]。因此,运用传统的线性理论和方法来预测煤层底板突水量难以取得令人满意的预测精度。

BP 神经网络模型具有极强的非线性逼近、大规模并行处理、自训练学习等特点,对解决煤层底板突水的预测及评价问题具有较强的适用性和优越性^[13]。本文通过分析肥城矿区煤层充水条件和底板突水机理,研究建立基于 BP 神经网络的肥城矿区底板突水量等级预测模型并进行评价。

1 肥城矿区底板突水因素分析

1.1 水压

水压是底板突水的动力,足够的水头压力是引起突水的一个重要条件。在其它条件相同时,水压力越大,发生底板突水的可能性也就越大。

肥城矿区水文地质条件极为复杂,下组煤层开采面临隔水层薄、水压大的情况。随着开采标高的降低,水压增大,矿压对底板破坏深度加大,更易发生底板突水,直接威胁着本矿区煤层的安全开采。

1.2 断裂构造

地质构造,尤其是断层,是造成煤层底板突水的主要因素之一。断层的存在不但破坏底板隔水层的完整性、缩小有效隔水层厚度,而且使断层两盘附近裂隙比较发育、降低岩层的强度。此外,褶曲轴部断层的尖灭拐弯处,由于应力的作用构造裂隙发育,也容易发生突水。

通过对峰峰、焦作、淄博以及肥城 4 个矿 163 个底板突水工作面的统计可知,由地质构造引起的突水事故约占总数的 70%。井陉矿区的统计结果表明,直接沿断层发生的突水占 74%,沿断层裂隙带发生的突水占 23%,合计 97%。

1.3 隔水层

隔水岩层阻止矿井充水的作用主要取决于以

下 3 个因素:(1)隔水岩层的阻水能力;(2)隔水岩层的厚度和稳定性;(3)隔水岩层的岩性组合关系。隔水岩层常常是由不同岩性的岩层组成的岩组。一般认为刚性较强的岩层,如灰岩、砂岩等具有较高的强度,对抵抗矿压的破坏起较大作用;柔性岩石,如泥岩、页岩等,具有强度较低,抵抗矿压破坏的能力差,但其隔水阻水能力较强。由刚柔相间的岩层组成的隔水岩层则更有利与抵抗矿压与水压的综合作用,在厚度相同的情况下更有利与抑制底板突水。

1.4 隔水底板的破裂程度

肥城矿区处于构造的转折部位,底板裂隙十分发育,导致有效隔水厚度减小,许多小型突水就是由此类原因导致。

隔水底板的岩性组合不仅影响底板的阻隔水能力,而且极大地影响到矿压对底板的破裂程度。当底板存在如砂岩、灰岩之类的含粘土质少的坚硬岩石时,其阻水能力较强,因其抗水压能力强,不易引起底鼓膨胀,但是因其硬度大,粘土质少,裂隙一旦形成,往往就是导水通道。

1.5 含水层

本溪群五层灰岩含水层(简称五灰含水层)是矿井直接充水水源,直接威胁着矿区 8、9、10₂ 层煤的安全开采。区内五灰厚 4.82~12.68 m,平均厚 9~10 m,质纯、致密坚硬,为灰色质纯致密厚层状细粒结晶灰岩,岩溶裂隙发育。

1.6 岩溶发育程度

肥城矿区底板突水水源主要为五灰和奥灰,补给量受岩溶发育程度控制。灰岩含水层中,易形成岩溶裂隙、溶洞或陷落柱,为岩溶水提供了良好的赋存空间。采掘时,当掘到裂隙、断裂等通道,连通岩溶水水源时,就会发生突水。岩溶越发育的地区,突水的危险性及突水量就越大。

2 BP 神经网络突水量预测模型

2.1 BP 神经网络的概念及原理

BP(Back Propagation)神经网络模型采用了 Rumelhart 和 McClelland 于 1985 年提出的误差反向后传 BP 学习算法,是目前最为广泛使用的一种人工神经网络模型之一^[14-16]。

图 1 给出了两个全连接、前向反馈人工神经网络的实例。这些网络包含一个输入层、一个输出层以及一个或多个隐含层。各层包含若干个神经元,神经元个数根据实际需要而定。

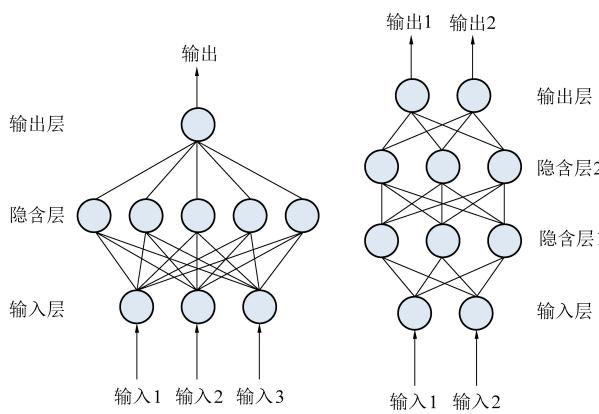


图 1 全连接前馈人工神经网络实例
Fig.1 Example of full connection feedforward artificial neural network

2.2 BP 神经网络突水量预测模型设计

2.2.1 输入层和输出层节点数的确定

选取了 6 个影响因素:断层落差(对底板破坏型突水而言断层落差取零)、底板裂隙发育程度、底板含水层岩溶发育程度、水压、底板含水层厚度、隔水层的厚度作为预测底板突水的控制因素,即网络的输入。

模型输入矩阵详见式(1),模型输出详见式(2)。

$$P = \begin{bmatrix} WP \\ KT \\ M \\ L \\ DF \\ H \end{bmatrix} \quad (1)$$

$$T = [Q] \quad (2)$$

式中: WP 表示水压, MPa; KT 表示含水层岩溶发育程度; M 表示含水层厚度, m; L 表示隔水层厚度, m; DF 表示底板裂隙发育程度; H 表示导水断层落差, m; Q 表示与输入数据相对应应该次突水的突水量, m^3/h 。

由此确定输入层节点数为 6, 输出层节点数为 1。输出层神经元的传递函数为 S 型对数传递函数 Log-Sigmoid。

按照国家煤矿安全监察局出台的《煤矿防治水细则》将突水量分为 4 个等级(见表 1)。通过分级,省去了对输出数据归一化的步骤,大大减小了计算的复杂程度。分级的实质是把 BP 建模从一个回归问题转换成为一个分类问题。

表 1 突水量变量取值表
Table 1 Water inrush variable value

变量名称	变量类型	变量取值
最大突水量	$0 < 60 m^3/h$ (小型突水)	1 0 0 0
	$60 m^3/h \leq Q < 600 m^3/h$ (中型突水)	0 1 0 0
	$600 m^3/h \leq Q < 1800 m^3/h$ (大型突水)	0 0 1 0
	$Q > 1800 m^3/h$ (特大型突水)	0 0 0 1

如果节点数过多,不仅增加了网络学习时间,而且可能出现“过拟合”现象,即训练样本拟合精确,但是其他样本的预测误差较大。本次设定隐含层的神经元个数为 13, 隐含层神经元的传递函数为 S 型对数传递函数 logsig。

2.2.2 隐层的设计

在 BP 神经网络模型中,对于任何在闭合区间内的一个连续函数都可以用单隐层的 BP 网络逼近,因而一个三层 BP 网络就可以完成任意的 n 维到 m 维的映射^[17-18]。实践表明,隐含层数目的增加可以提高 BP 网络的非线性映射的能力,但是隐含层数目超过一定值,网络性能反而会下降。单隐层的 BP 可以逼近一个任意的连续非线性函数。因此,本次突水量预测模型采用单隐层的 BP 神经网络。

BP 神经网络构建时还应注意隐含层节点数的选择,如果隐含层含节点数太少,BP 神经网络不能建立复杂的映射关系,网络误差较大。然而

最终,确定模型输出矩阵为 $T = [Q] = \begin{bmatrix} t_1 \\ t_2 \\ t_3 \\ t_4 \end{bmatrix}$,

上式中 t_i 表示输出节点变量取值。

2.2.3 网络模型结构

最终确定本模型的结构如图 2 所示:由 3 层网络组成,6 个输入神经元信息分别为水压、底板裂隙发育程度、断层落差、含水层岩溶发育程度、含水层厚度、隔水层厚度;隐含层设定 13 个神经元;1 个输出神经元信息为突水量等级。

2.2.4 样本的选择及数据处理

选取肥城矿区曹庄矿、查庄矿、陶阳矿、杨庄矿、白庄矿等矿井突水资料较为完整的 33 次突水样本,将其中 27 次突水样本进行训练,其余 6 次突水预留作为预测样本。

通常获取的数据样本不是都能直接用于网络

的训练,而需要对原始数据进行一定预处理。本次已对输出数据(即突水量等级)进行了归一化处理,对水压、含水层厚度、隔水层厚度、断层落差等输入数据不作处理,而针对含水层岩溶发育程度和底板裂隙发育程度这 2 项输入数据,则根据矿山实际揭露资料通过专家评判将其分别概化为中等、较发育、发育等 3 个等级,对应量化为 3、4、5 来作为输入数据。经过预处理的训练样本见表 2。

2.3 网络的创建、训练及测试

2.3.1 网络创建

网络结构确定后,需要根据样本数据通过一定的学习规则进行训练,提高网络的学习能力^[19]。学习速率是训练过程的重要因子,它决定每一次

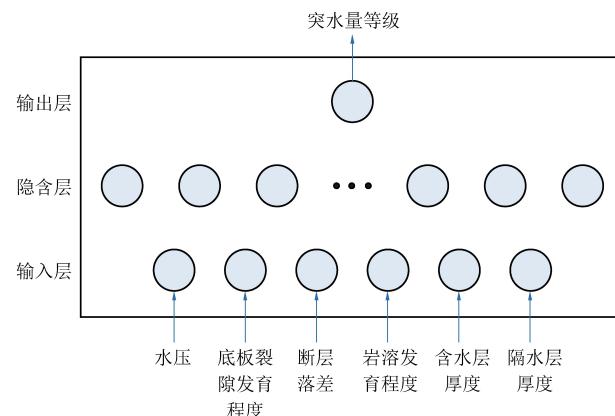


图 2 BP 神经网络突水量预测模型结构示意图

Fig.2 Structure of the BP neural network water inrush prediction model

表 2 BP 神经网络突水量预测模型训练样本表

Table 2 Training samples of the BP neural network water inrush prediction model

序号	突水工作面名称	水压/ MPa	含水层岩溶 发育程度	含水层 厚度/m	隔水层 厚度/m	底板裂隙 发育程度	断层落差 /m	最大突水量/ ($m^3 \cdot h^{-1}$)	变量取值
1	杨庄 103051 号贯眼	0.56	4	13.00	21.4	3	8.0	28	1 0 0 0
2	杨庄 9309 回风巷	0.60	3	13.00	25.4	2	8.0	5	1 0 0 0
3	杨庄 10307 运中巷	0.58	3	13.00	21.4	3	8.0	10	1 0 0 0
4	杨庄 9101 运中巷	0.81	4	13.50	6.0	3	17.0	721	0 0 1 0
5	杨庄 9101 回风巷	0.88	5	13.50	4.0	4	26.0	4 409	0 0 0 1
6	杨庄 9510 轨中巷	1.09	3	12.17	21.0	5	0	22	1 0 0 0
7	杨庄 10510 工作面	0.77	3	9.10	20.0	5	0	18.9	1 0 0 0
8	杨庄 9507 工作面	0.92	3	12.00	26.0	4	0	5	1 0 0 0
9	杨庄 9706 工作面	1.50	3	11.00	26.5	5	0.5	48	1 0 0 0
10	杨庄 10601 运中巷	1.30	3	12.30	22.0	4	0	7	1 0 0 0
11	杨庄 97061 号贯眼	1.59	3	12.00	26.5	4	0	10	1 0 0 0
12	杨庄 10706 工作面	0.56	3	13.00	20.0	4	1.2	80	0 1 0 0
13	杨庄 9605 工作面	2.12	4	13.00	32.0	4	1.0	140	0 1 0 0
14	杨庄 8717 工作面	2.14	3	13.00	37.8	4	2.7	105	0 1 0 0
15	查庄 7505 工作面	1.10	3	7.00	20.0	4	1.6	130	0 1 0 0
16	查庄 7507 工作面	1.10	4	7.00	18.0	5	0.8	516	0 1 0 0
17	查庄 8105 工作面	2.60	3	9.00	32.0	4	2.0	320	0 1 0 0
18	查庄 8503 工作面	2.98	3	9.00	33.0	5	0	395	0 1 0 0
19	查庄 7802 工作面	0.81	3	7.00	19.9	4	0.9	135	0 1 0 0
20	查庄 8505 工作面	2.63	3	10.00	34.0	5	0	403	0 1 0 0
21	查庄 91001 工作面	0.88	3	10.00	25.4	4	1.4	100	0 1 0 0
22	查庄 7905 工作面	2.90	4	10.00	58.7	5	3.6	700	0 0 1 0
23	曹庄 9403 工作面	2.95	5	11.00	23.0	5	3.0	869	0 0 1 0
24	大封 9204 工作面	1.08	5	10.00	16.5	5	3.2	1 628	0 0 1 0
25	陶阳 9901 工作面	0.60	5	10.00	19.0	5	8.0	1 083	0 0 1 0
26	陶阳 9906 工作面	1.42	4	8.50	26.0	4	0	420	0 1 0 0
27	陶阳 9903 工作面	0.85	4	8.50	24.0	4	0.4	310	0 1 0 0

循环中的权值变化量^[20]。本次模型取学习速率
为 0.05。

网络的训练函数选择 trainlm, 经试算, 选用函
数拟合效果较好。学习函数取默认值, 性能函数
取默认值 mse, 其中函数 minmax 设定了输入向量
元素的阀值范围, 简化了计算复杂程度。

2.3.2 网络训练

网络创建好后, 并不能直接使用, 必须经过训
练且达到要求后, 才可以作为设备状态分类器使
用。BP 神经网络的训练调用函数为 train。函数
形式为: [net, tr] = train(net, p, t)。

训练结果为: 经过 131 次训练之后, 网络误差
达到最小, 计算结果如图 3 所示。

2.3.3 网络测试

通过仿真来检验网络的输出是否满足要求,

代码为: sim(net, p); 运行结果见表 3。

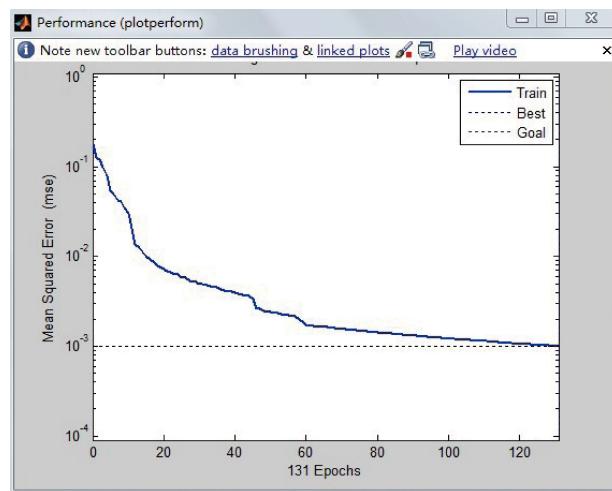


图 3 BP 神经网络训练误差图

Fig.3 Training error of BP neural network

表 3 训练样本的学习结果

Table 3 Learning results of training samples

序号	突水量 等级	预测	误差	序号	突水量 等级	预测	误差	序号	突水量 等级	预测	误差
1	1	0.953 1	-0.046 9	10	1	0.946 5	-0.053 5	19	0	0.013 3	0.013 3
	0	0.016 0	0.016 0		0	0.048 3	0.048 3		1	0.967 3	-0.032 7
	0	0.013 4	0.013 4		0	0.010 3	0.010 3		0	0.013 0	0.013 0
	0	0.013 9	0.013 9		0	0.000 0	0.000 0		0	0.000 0	0.000 0
2	1	0.960 1	-0.039 9	11	1	0.968 7	-0.031 3	20	0	0.023 3	0.023 3
	0	0.029 7	0.029 7		0	0.039 2	0.039 2		1	0.981 5	-0.018 5
	0	0.004 6	0.004 6		0	0.014 4	0.014 4		0	0.006 6	0.006 6
	0	0.018 2	0.018 2		0	0.000 0	0.000 0		0	0.000 1	0.000 1
3	1	0.954 6	-0.045 4	12	0	0.112 1	0.112 1	21	0	0.040 7	0.040 7
	0	0.019 4	0.019 4		1	0.891 1	-0.108 9		1	0.957 2	-0.042 8
	0	0.008 5	0.008 5		0	0.002 4	0.002 4		0	0.005 1	0.005 1
	0	0.010 2	0.010 2		0	0.000 0	0.000 0		0	0.000 0	0.000 0
4	0	0.037 0	0.037 0	13	0	0.029 0	0.029 0	22	0	0.034 4	0.034 4
	0	0.000 2	0.000 2		1	0.968 3	-0.031 7		0	0.027 4	0.027 4
	1	0.939 0	-0.061 0		0	0.006 6	0.006 6		1	0.917 2	-0.082 8
	0	0.006 8	0.006 8		0	0.000 1	0.000 1		0	0.034 1	0.034 1
5	0	0.012 9	0.012 9	14	0	0.002 9	0.002 9	23	0	0.000 1	0.000 1
	0	0.000 1	0.000 01		1	0.985 6	-0.014 4		0	0.005 0	0.005 0
	0	0.069 3	0.069 3		0	0.006 6	0.006 6		1	0.993 8	-0.006 2
	1	0.944 6	-0.055 4		0	0.000 3	0.000 3		0	0.000 4	0.000 4
6	1	0.954 6	-0.045 4	15	0	0.002 1	0.002 1	24	0	0.000 0	0.000 0
	0	0.055 3	0.055 3		1	0.978 2	-0.021 8		0	0.043 5	0.043 5
	0	0.010 5	0.010 5		0	0.014 0	0.014 0		1	0.954 2	-0.045 8
	0	0.000 0	0.000 0		0	0.000 0	0.000 0		0	0.001 1	0.001 1

续表

序号	突水量 等级	预测	误差	序号	突水量 等级	预测	误差	序号	突水量 等级	预测	误差
7	1	0.967 8	-0.032 2	16	0	0.000 3	0.000 3	25	0	0.000 1	0.000 1
	0	0.035 5	0.035 5		1	0.969 0	-0.031 0		0	0.004 1	0.004 1
	0	0.011 9	0.011 9		0	0.049 1	0.049 1		1	0.971 3	-0.028 7
	0	0.000 0	0.000 0		0	0.000 0	0.000 0		0	0.042 5	0.042 5
8	1	0.970 9	-0.029 1	17	0	0.001 2	0.001 2	26	0	0.009 9	0.009 9
	0	0.035 0	0.035 0		1	0.990 7	-0.009 3		1	0.972 5	-0.027 5
	0	0.012 7	0.012 7		0	0.004 1	0.004 1		0	0.017 5	0.017 5
	0	0.000 0	0.000 0		0	0.000 2	0.000 2		0	0.000 1	0.000 1
9	1	0.932 4	-0.067 6	18	0	0.022 8	0.022 8	27	0	0.003 5	0.003 5
	0	0.065 0	0.065 0		1	0.982 1	-0.017 9		1	0.957 2	-0.042 8
	0	0.014 0	0.014 0		0	0.007 1	0.007 1		0	0.047 6	0.047 6
	0	0.000 0	0.000 0		0	0.000 1	0.000 1		0	0.000 0	0.000 0

根据表 3, 对比矿井突水量级别和预测结果, 得出 BP 神经网络模拟误差(图 4), 实际值与预测值最大误差为 11%, 平均误差为 2%。由此表明, 网络训练后, 拟合情况较好, 该模型可以准确有效的预测底板突水量级别。

3 BP 神经网络预测突水量等级

利用已经训练好的 BP 神经网络对事先预留的 6 个底板突水样本(详见表 4)进行预测。

预测结果见表 5, 根据预测结果做出 BP 神经网络突水量预测模型误差柱状图(图 5)。

由表 5 和图 5 可以看出, 预测结果与实际值之间的最大误差为 40%, 最小误差为 0, 平均误差为 4.28%。如果以 4 个输出节点值最大者作为突水量判断依据的话, 对 6 个突水工作面的预测结

果均正确, 判对率为 100%。由此说明, 采用 BP 神经网络方法进行煤层底板突水量预测是可行的。

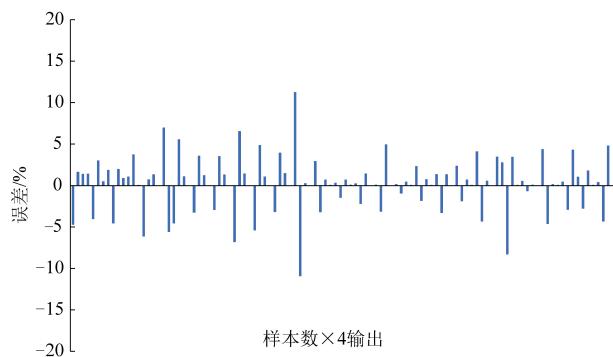


图 4 BP 神经网络预测模型误差柱状图

Fig.4 Error histogram of the BP neural network prediction model

表 4 预测样本参数表

Table 4 Prediction sample parameter

序号	突水工作面名称	水压 /MPa	含水层岩溶 发育程度	含水层 厚度/m	隔水层 厚度/m	底板裂隙 发育程度	断层 落差/m	最大突水量 /(m³·h⁻¹)	变量取值
1	杨庄 103051 贯眼	0.60	3	13.5	27.50	3	5	8.0	1 0 0 0
2	杨庄 9309 回风巷	0.58	3	13.0	27.64	3	5	18.0	1 0 0 0
3	杨庄 10307 运中巷	0.60	3	13.0	27.64	4	5	20.0	1 0 0 0
4	杨庄 9101 运中巷	0.90	3	12.0	26.00	3	5	10.6	1 0 0 0
5	杨庄 9101 回风巷	1.90	4	10.3	37.90	5	0	495.0	0 1 0 0
6	杨庄 9510 轨中巷	1.26	5	10.0	23.50	5	0	436.0	0 1 0 0

但是预测模型的预测结果还存在着一定的误差, 主要原因有 3 个: 第一, 影响矿井底板突水的

因素众多, 本次模型中只是选取了对突水有直接和重要影响的 6 个因素, 而未考虑其他次要影响

表 5 BP 神经网络模型预测结果

Table 5 Prediction results of the BP neural network model

序号	突水量 等级	预测	误差	序号	突水量 等级	预测	误差	序号	突水量 等级	预测	误差
1	1	0.943 3	-0.056 7	2	1	0.977 5	-0.022 5	3	1	0.979 5	-0.020 5
	0	0.032 6	0.032 6		0	0.007 5	0.007 5		0	0.005 5	0.005 5
	0	0.002 6	0.002 6		0	0.003 8	0.003 8		0	0.005 1	0.005 1
	0	0.002 2	0.002 2		0	0.002 6	0.002 6		0	0.002 3	0.002 3
4	1	0.955 3	-0.044 7	5	0	0.026 6	0.026 6	6	0	0.029 3	0.029 3
	0	0.015 8	0.015 8		1	0.980 6	-0.019 4		1	0.548 8	-0.451 2
	0	0.005 1	0.005 1		0	0.013 0	0.013 0		0	0.347 2	0.347 2
	0	0.002 3	0.002 3		0	0.000 2	0.000 2		0	0.000 0	0.000 0

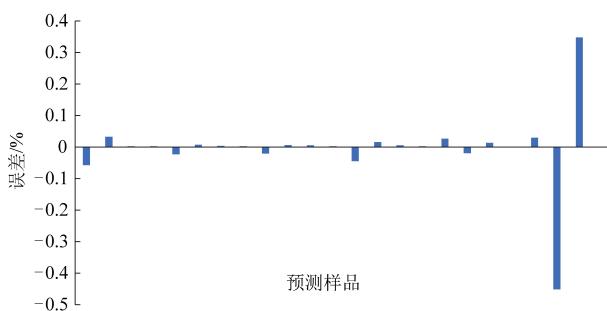


图 5 BP 网络模型突水预测误差柱状图

Fig.5 Error histogram of the BP network water inrush prediction model

因素;第二,输入节点中岩溶发育程度以及底板破裂程度均是采用概化后的量化值,其赋值不够精确,存在较大的误差;第三,由于资料所限,可供训练的样本数不够丰富,训练不够充分。

4 MIV 方法对模型的变量评价

4.1 MIV 方法的基本原理

采用平均影响值(MIV)作为评价神经网络中各个自变量对于因变量影响的重要性指标^[21],其符号一般代表相关的方向,绝对值代表影响的相对重要性。

具体计算过程为:在网络训练终止后,将训练样本 P 中每一自变量特征在其原值的基础上分别加/减 10%构成新的训练样本 P₁ 和 P₂,将 P₁ 和 P₂ 分别作为仿真样本利用已建成的网络进行仿真,得到两个仿真结果 A₁ 和 A₂,求出 A₁ 和 A₂ 的差值,即为变动该自变量后对输出产生的影响变化值(IV),最后将 IV 按观测例数平均得出该自变量对于应变量网络输出的 MIV,一个输入因素的 MIV 为所有训练样本输出量变化的平均值。按照上面步骤依次算出各个自变量的 MIV 值,最后根据

MIV 绝对值的大小为各自变量排序,得出各自变量对网络输出影响相对重要性的位次表,从而判断出输入特征对于网络结果的影响程度。

4.2 模型实现

本次建立的 BP 神经网络预测模型含 6 个输入因素(自变量)和 4 个输出(因变量),通过指标 MIV 评价 6 个自变量(岩溶发育程度、含水层厚度、隔水层厚度、底板裂隙程度、断层落差、水压)分别对 4 个输出神经元的影响重要性,筛选对输出结果有重要影响的变量,从而探究肥城矿区的突水机理。在 MATLAB 中运行程序,得出 MIV_n 结果如下:

$$\begin{aligned}
 MIV_1 &= (\text{水压}) \\
 &-0.0019 \quad -0.0019 \quad -0.0028 \quad 0.0026 \\
 MIV_2 &= (\text{含水层岩溶发育程度}) \\
 &-0.0134 \quad 0.0050 \quad 0.0224 \quad -0.0112 \\
 MIV_3 &= (\text{突水含水层厚度}) \\
 &0.0352 \quad -0.1652 \quad 0.0099 \quad -0.0018 \\
 MIV_4 &= (\text{隔水层厚度}) \\
 &0.0152 \quad 0.1212 \quad -0.0713 \quad 0.0016 \\
 MIV_5 &= (\text{底板裂隙发育程度}) \\
 &-0.0041 \quad -0.0256 \quad 0.0117 \quad 0.0055 \\
 MIV_6 &= (\text{断层落差}) \\
 &-0.0032 \quad -0.0016 \quad -0.0217 \quad 0.0238
 \end{aligned}$$

4.3 结果及分析

由以上 MIV 结果分析可知:

对第一和第二个因变量,即对小型及中型突水等级有控制作用的因变量而言,MIV₃、MIV₄ 的值明显大于其他自变量的 MIV 值,即突水因素中含水层厚度和隔水层厚度对小型及中型突水的发生有着较大的相关性,这与肥城矿区小、中型突水主要由矿区含水层及隔水层的属性决定,而与

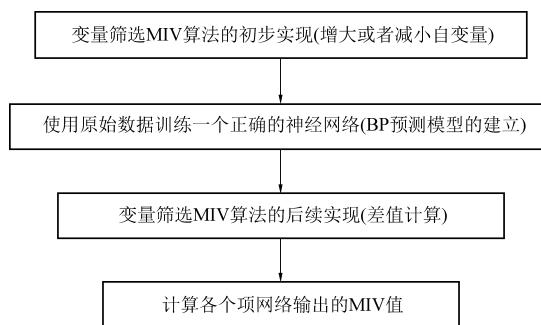


图 6 基于 MIV 方法的 BP 神经网络变量评价筛选流程图

Fig.6 Evaluation and screening process of BP neural network variables based on the MIV method

断层等构造因素的相关性不大的特点相符。

对第三和四个因变量,即对大型及特大型突水而言,MIV_2、MIV_5 和 MIV_6 值显著大于其他自变量的 MIV 值,即突水因素中断层构造、岩溶发育程度以及底板裂隙发育程度对大型及特大型突水的发生有较大的相关性,这说明肥城矿区大型及特大型突水的发生与断层、裂隙、岩溶发育等多种地质作用共同作用有关。

5 结 论

(1)建立了 BP 神经网络模型进行突水量等级预测,选用水压、底板裂隙发育程度、断层落差、含水层岩溶发育程度、含水层厚度、隔水层厚度等 6 项指标作为输入变量,预测结果能很好地反映实际情况,证明了该方法的可行性。

(2)基于 MIV 方法对所建立的 BP 神经网络突水量预测模型进行了变量评价,结果显示:肥城矿区小、中型突水主要由矿区含水层及隔水层本身决定,而与断层等构造因素的相关性不大;断层构造、岩溶发育程度以及底板裂隙发育程度对大型及特大型突水的发生有较大的影响,说明肥城矿区大型及特大型突水的发生与断层、裂隙、岩溶发育等多种地质作用共同作用有关。

(3)由于煤层底板突水的复杂性和不确定性,突水量等级受多种突水影响因素共同作用并相互耦合。不同煤矿的底板突水因素不尽相同,需对具体矿井进行深入分析和充分资料收集,才能建立具有良好适用性的 BP 神经网络突水量预测模型。今后应在矿井底板突水机理、评价指标优化、指标量化合理性以及神经网络算法优化等方面作进一步的研究。

参 考 文 献

[1] 王则才, 张兆强, 房孝春. 肥城矿区高承压岩溶水防治技

术研究 [J]. 华北科技学院学报, 2009, 6 (4): 87-89.
WANG Zecai, ZHANG Zhaoqiang, FANG Xiaochun. The study of control techniques on karst water in high - pressure in Feicheng Mining [J]. Journal of North China Institute of Science and Technology, 2009, 6 (4): 87-89.

- [2] 曹斌, 位来. 注浆改造含水层技术在煤矿中的应用 [J]. 煤, 2016 (197): 19-21.
CAO Bin, WEI Lai. The grouting reconstruction aquifer technology application of coal mine [J]. Coal, 2016 (197): 19-21.
- [3] 王皓, 董书宁, 乔伟, 等. 矿井水害防控远程服务云平台构建与应用 [J]. 煤田地质与勘探, 2021, 49 (1): 208-216.
WANG Hao, DONG Shuning, QIAO Wei, et al. Construction and application of remote service cloud platform for mine water hazard prevention and control [J]. Coal Geology & Exploration, 2021, 49 (1): 208-216.
- [4] 虎维岳, 田干. 我国煤矿水害类型及其防治对策 [J]. 煤炭科学技术, 2010, 38 (1): 92-96.
HU Weiyue, TIAN Gan. Mine water disaster type and prevention and control counter measures in China [J]. Coal Science and Technology, 2010, 38 (1): 92-96.
- [5] 煤科院北京开采研究所. 煤矿地表移动与覆岩破坏规律及其应用 [M]. 北京: 煤炭工业出版社, 1981: 294-312.
- [6] 沈光寒, 李白英, 吴戈. 矿井特殊开采的理论与实践 [M]. 北京: 煤炭工业出版社, 1992: 15-45.
- [7] 李白英. 预防矿井底板突水的“下三带”理论及其发展与应用 [J]. 山东矿业学院学报 (自然科学版), 1999, 18 (4): 11-18.
LI Baiying. "Down Three Zones" in the prediction of the water inrush from coalbed floor aquifer theory, development and application [J]. Journal of Shandong University of Science and Technology (Natural Science), 1999, 18 (4): 11-18.
- [8] 钱鸣高, 缪协兴, 许家林. 岩层控制中的关键层理论研究 [J]. 煤炭学报, 1996, 21 (3): 225-230.
QIAN Minggao, LIAO Xiexing, XU Jialin. Theoretical study of key stratum in ground control [J]. Journal of China Coal Society, 1996, 21 (3): 225-230.
- [9] 王作宇, 刘鸿泉. 煤层底板突水机制的研究 [J]. 煤田地质与勘探, 1989 (1): 36-39.
WANG Zuoyu, LIU Hongquan. Investigation in floor - water burst mechanism [J]. Coal Geology & Exploration, 1989 (1): 36-39.
- [10] 王延蒙. 承压水作用下底板突水机理及防治技术研究 [D]. 徐州: 中国矿业大学, 2015: 1-6.
- [11] 代长青. 承压水体上开采底板突水规律的研究 [D]. 淮南: 安徽理工大学, 2005: 3-6.
- [12] 王延福, 靳德斌, 曾艳京. 矿井煤层底板突水预测新方法研究 [J]. 水文地质工程地质, 1999 (4): 33-37.
- [13] 廖巍, 周荣义, 李树清. 基于小波神经网络的煤层底板突水非线性预测方法研究 [J]. 中国安全科学学报, 2006, 16 (11): 24-28.
LIAO Wei, ZHOU Rongyi, LI Shuqing. Study on the non-linear forecast methods for water inrush from coal floor based on

- wavelet neural network [J]. China Safety Science Journal, 2006, 16 (11): 24–28.
- [14] 卢文龙. 煤矿底板突水预测研究——以山西省某煤矿为例 [D]. 太原: 太原理工大学, 2015: 45–54.
- [15] 郝春燕, 邱国庆, 张海荣. 底板突水预测模型的影响因素分析 [J]. 武汉大学学报(信息科学版), 2013, 38 (2): 153–156.
- QI Chunyan, QIU Guoqing, ZHANG Hairong. Influencing factors analysis of floor water invasion prediction model [J]. Geomatics and Information Science of Wuhan University, 2013, 38 (2): 153–156.
- [16] 邱秀梅, 王连国. 煤层底板突水人工神经网络预测 [J]. 山东农业大学学报(自然科学版), 2002 (1): 62–65.
- QIU Xiumei, WANG Lianguo. ANN forecast for water-inrush from coal floor [J]. Journal of Shandong Agricultural University (Natural Science Edition), 2002 (1): 62–65.
- [17] 王鹏, 朱希安, 王占刚, 等. 基于 IPSO-SVR 模型的煤层底板突水量预测 [J]. 北京信息科技大学学报(自然科学版), 2021, 36 (1): 40–44.
- WANG Peng, ZHU Xi'an, WANG Zhangang, et al. Prediction of water inrush quantity from coal floor based on IPSO-SVR model [J]. Journal of Beijing Information Science & Technology University, 2021, 36 (1): 40–44.
- [18] 朱宗奎, 黄鑫磊. 基于 Visual MODFLOW 的煤层底板突水量预测研究 [J]. 煤炭科学技术, 2020, 48 (8): 157 –163.
- ZHU Zongkui, HUANG Xinlei. Study on water inrush quantity prediction from coal seam floor based on Visual MODFLOW [J]. Coal Science and Technology, 2020, 48 (8): 157–163.
- [19] 刘梦杰, 朱希安, 王占刚. 基于 FOA-SVR 模型的矿井底板突水量预测应用研究 [J]. 中国矿业, 2019, 28 (5): 87–91+130.
- LIU Mengjie, ZHU Xi'an, WANG Zhangang. Application of the prediction for mine floor water inrush quantity based on FOA-SVR model [J]. China Mining Magazine, 2019, 28 (5): 87–91+130.
- [20] 施龙青, 曲兴玥, 韩进, 等. 多模型融合评价煤层底板灰岩岩溶突水危险性 [J]. 煤炭学报, 2019, 44 (8): 2484–2493.
- SHI Longqing, QU Xingyue, HAN Jin, et al. Multi-model fusion for assessing the risk of inrush of limestone karst water through mine floor [J]. Journal of China Coal Society, 2019, 44 (8): 2484–2493.
- [21] 尹会永, 周鑫龙, 郎宁, 等. 基于 SSA 优化的 GA-BP 神经网络煤层底板突水预测模型与应用 [J]. 煤田地质与勘探, 2021, 49 (6): 175–185.
- YIN Huiyong, ZHOU Xinlong, LANG Ning, et al. Prediction model of water inrush from coal floor based on GA-BP neural network optimized by SSA and its application [J]. Coal Geology & Exploration, 2021, 49 (6): 175–185.