

Applied Research on the Prediction Model of Coalmine Gas Disaster Based on the LM Neural Network^{*}

Honglei Dai, Maoyi Tian, Lin Liu, Litao Han

College of Geomatics, Shandong University of Science and Technology, Qingdao
Email: Honglei_Dai@yahoo.cn

Received: Feb. 28th, 2012; revised: Mar. 19th, 2012; accepted: Mar. 24th, 2012

Abstract: Currently the forecasting of gas outburst and explosion is one of the issues to be solved in China's coal mine safety production. Based on the LM optimization algorithm of BP neural network, this paper discussed the mathematical model, network architecture and programming design of establishing the neural network prediction model on gas disaster with keeping the relationship among the spatial entities and their distributions, and tested an instance of Jining No. 2 coal mine. The result shows that this model is stable, fast and high prediction accurate and it can simulate the mine gas disaster to get higher accurate predictions.

Keywords: Gas Disaster; Spatial Correlation; Spatial Distribution; Neural Network; LM Algorithm

基于 LM 神经网络瓦斯灾害预测模型的应用研究^{*}

戴洪磊, 田茂义, 柳林, 韩李涛

山东科技大学测绘学院, 青岛
Email: Honglei_Dai@yahoo.cn

收稿日期: 2012 年 2 月 28 日; 修回日期: 2012 年 3 月 19 日; 录用日期: 2012 年 3 月 24 日

摘要: 矿山瓦斯突出与爆炸事故的预测预报是当前我国煤矿安全生产中急待解决的问题之一。本文引入 BP 神经网络的 LM 优化算法, 在保留空间实体相关和多种分布并存的前提下, 讨论了建立 LMBP 神经网络瓦斯灾害预测预报模型的数学模型设计、网络结构设计和程序设计三个部分, 并以兖矿集团济宁二号井为实例进行了测试。实验结果表明: 该模型稳定、快速、预测精度高, 能够较好地模拟矿山瓦斯突出与爆炸事故特征, 对瓦斯灾害作出较准确的预测。

关键词: 瓦斯灾害; 空间相关; 空间分布; BP 神经网络; LM 优化算法

1. 引言

矿井瓦斯突出与爆炸是煤矿灾害中最常见的突发性强、规模大, 后果严重、经济损失最大的矿山灾害之一^[1], 其后果是直接威胁到矿工的生命安全、家庭幸福和矿山本身的生产效益^[2,3]。随着近年来瓦斯灾害事故的频繁发生, 国内许多学者展开了矿山瓦斯灾害预测预报的研究。比如煤炭科学院的吴自立于 2005

年采用 AE 信号参数对瓦斯突出危险性进行了研究^[4]; 中国矿业大学的李成武在 2005 年展开了瓦斯突出危险程度的预测研究^[5], 2010 年王海锋等研究了开采工作面瓦斯涌出及瓦斯抽采参数优化工作^[6], 2007 年中南大学的傅鹤林探讨了隧道施工中的瓦斯预测预报技术^[7]。这些研究均从不同的方面对矿井瓦斯灾害预测预报进行了深入的分析和研究, 并在相应的矿井取得了实际的应用效果。

近 30 多年来, 随着矿山瓦斯监测技术的发展和普

*资助信息: 山东省“泰山学者”建设工程专项经费资助。

及, 我国许多瓦斯矿区收集了大量的矿山井下巷道和开采工作面的瓦斯分布实时监测数据。如何利用现代的空间数据挖掘技术从这些瓦斯监测数据中自动、快速、准确地提取与瓦斯灾害事故发生相关的空间信息, 揭示瓦斯灾害的演化规律, 建立瓦斯灾害预测预报模型是当前我国煤矿安全生产中急待解决的问题之一。

煤炭科学研究院的赵旭生在 2002 年探讨了利用 BP 算法对瓦斯突出强度进行预测, 验证了人工神经网络用于瓦斯突出强度预测的可行性^[8]; 2004 年, 焦作工学院的郝吉生提出了采用改进的 BP 算法对煤与瓦斯的突出区域进行预测^[9]; 中国矿业大学的吴财芳也利用自适应 BP 算法进行对瓦斯预测研究进行了实验研究^[10]; 安徽理工大学的齐刘宇于 2008 年分析了利用 BP 算法来扩展光谱从而改进瓦斯系统测量的应用^[11]。以上研究均对煤与瓦斯突出预测进行了详细的分析和测试, 取得了较高的预测精度。本文将利用 BP 神经网络中的 LM 优化算法, 在不需要任何假设的前提下, 突破传统空间数据挖掘技术中忽略多种分布并存(即假设空间数据变量服从同种分布)和变量相关性(即假设变量相互独立)的局限性, 在包含完整矿山瓦斯灾害空间数据源信息的基础上, 研究如何从矿山 GIS 空间数据库中挖掘瓦斯灾害事故信息, 建立合理通用的矿山瓦斯预测预报模型, 对矿山瓦斯突出和爆炸灾害事故进行预测预报工作。

2. LM 算法 BP 神经网络预测模型建立

BP 神经网络瓦斯预测预报模型的建立是一个综合性的问题, 一般包括数学模型的设计、网络结构的设计和模型的程序设计三个部分。

2.1. 数学模型设计

LM(Leverberg Marquart Algorithm)算法是在 1944 年和 1963 年分别由 Levenberg^[12] 和 Marquardt^[13] 提出并研究的具有梯度法和牛顿法优点的优化算法, 是一种利用标准数值优化技术的快速算法, 用以最小化其他非线性函数平方和的函数, 非常适用于性能指数是均方误差的神经网络训练。

矿山井下空间数据有不同于地表数据的特点: 首先矿山井下空间实体多种多样, 既有不同地质条件下的自然空间实体(如煤层、岩层、土沙层、水体、岩体、断层、陷落柱等), 也有井下人工空间实体(如巷道、

采区、路轨、支护体、采区间预留煤柱、顶底板、管线、泵房和车场等)。由于所处地理位置和产生环境的不同, 导致众多的空间目标可能来自众多不同的空间分布模式。其次是单一矿井内部常根据煤层赋存条件的不同进行多水平煤层同步开采, 因此使各水平的空间实体如立井、斜井、采区上下山和各种巷道等, 在三维立体环境中相互交叉, 加强了空间目标之间的相关性。

所以依附于矿山井下空间实体量测的导致瓦斯灾害事故的表征各影响因素的线形信息也不再是独立的, 它们之间存在一定程度的相关性, 相关性大小由这些因素所依附的空间实体空间相关矩阵^[14,15]表示。

假设影响瓦斯突出爆炸的主要因素有 n 个, 用集合 $X = \{X_1, X_2, \dots, X_n\}$ 表示, 预测点的瓦斯突出爆炸与否的输出值有 m 种, 用集合 $Y = \{Y_1, Y_2, \dots, Y_m\}$ 表示, 其间关系是一个在各影响因素相互作用下的非线性动态系统。其格式为:

$$Y = f(\mathbf{W}_0 \mathbf{X}) \quad (1)$$

其中 \mathbf{W}_0 为主要影响因素所依附的空间实体空间相关矩阵, \mathbf{X} 为主要影响因素输入向量矩阵, 代入 LM 算法中, 即得到瓦斯灾害事故的神经网络 LMBP 预测数学模型。

设 $\mathbf{w}^{(k)}$ 表示第 k 次迭代的权值和阈值所组成的向量, 新的权值和阈值组成的向量 $\mathbf{w}^{(k+1)}$ 可由下面的规则求得:

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + \Delta \mathbf{w} \quad (2)$$

对于牛顿法则是:

$$\Delta \mathbf{w} = -[\nabla^2 \mathbf{E}(\mathbf{w})]^{-1} \nabla \mathbf{E}(\mathbf{w}) \quad (3)$$

式中 $\nabla^2 \mathbf{E}(\mathbf{w})$ 表示输出误差 $\mathbf{E}(\mathbf{w})$ 的 Hessian 矩阵; $\nabla \mathbf{E}(\mathbf{w})$ 表示梯度。

$$\mathbf{E}(\mathbf{w}) = \frac{1}{2} \sum_{k=1}^l (d_k - y_k)^2 = \frac{1}{2} \sum_{k=1}^l e_k^2(\mathbf{w}) \quad (4)$$

式中 $e_k^2(\mathbf{w})$ 为误差, d_k 为期望输出, y_k 为实际输出, 有

$$\nabla \mathbf{E}(\mathbf{w}) = J^T(\mathbf{w}) e(\mathbf{w}) \quad (5)$$

$$\nabla^2 \mathbf{E}(\mathbf{w}) = J^T(\mathbf{w}) e(\mathbf{w}) + S(\mathbf{w}) \quad (6)$$

式中, $S(\mathbf{w}) = \sum_{k=1}^l e_k(\mathbf{w}) \nabla^2 e_k(\mathbf{w})$, $\mathbf{J}(\mathbf{w})$ 为 Jacobian 矩阵, 即

$$\mathbf{J}(\mathbf{w}) = \begin{vmatrix} \frac{\partial e_1(\mathbf{w})}{\partial \mathbf{w}_1} & \frac{\partial e_1(\mathbf{w})}{\partial \mathbf{w}_2} & \dots & \frac{\partial e_1(\mathbf{w})}{\partial \mathbf{w}_n} \\ \frac{\partial e_2(\mathbf{w})}{\partial \mathbf{w}_1} & \frac{\partial e_2(\mathbf{w})}{\partial \mathbf{w}_2} & \dots & \frac{\partial e_2(\mathbf{w})}{\partial \mathbf{w}_n} \\ \vdots & \vdots & & \vdots \\ \frac{\partial e_l(\mathbf{w})}{\partial \mathbf{w}_1} & \frac{\partial e_l(\mathbf{w})}{\partial \mathbf{w}_2} & \dots & \frac{\partial e_l(\mathbf{w})}{\partial \mathbf{w}_n} \end{vmatrix} \quad (7)$$

对于高斯 - 牛顿法的法则有:

$$\Delta \mathbf{w} = -[\mathbf{J}^T(\mathbf{w})\mathbf{J}(\mathbf{w})]^{-1}\mathbf{J}(\mathbf{w})e(\mathbf{w}) \quad (8)$$

LM 算法是一种改进的高斯-牛顿法, 其形式为:

$$\Delta \mathbf{w} = -[\mathbf{J}^T(\mathbf{w})\mathbf{J}(\mathbf{w}) + \mu \mathbf{I}]^{-1}\mathbf{J}(\mathbf{w})e(\mathbf{w}) \quad (9)$$

式中比例系数 $\mu > 0$ 为常数, \mathbf{I} 是单位矩阵。

从式(9)中可见, 如果比例系数 $\mu = 0$, 则为高斯 - 牛顿法; 如果 μ 取值很大, 则 LM 算法接近梯度下降法。由于 LM 算法利用了近似的二阶导数信息, 其训练速度比梯度下降法提高几十甚至上百倍。另外由于 $[\mathbf{J}^T(\mathbf{w})\mathbf{J}(\mathbf{w}) + \mu \mathbf{I}]$ 是正定的, (9)总存在解, 所以 LM 算法优于高斯—牛顿法。LM 算法的计算步骤为:

- 1) 给出训练误差允许值 ε , 系数 β , μ_0 , 计算输入变量所依附的空间实体空间相关邻接矩阵 \mathbf{W}_0 ^[14,15], 以及神经元网络初始化权值和阈值向量 $\mathbf{W}^{(0)}$, 令 $k = 0$, $\mu = \mu_0$;
- 2) 计算网络输出 d_k ;
- 3) 按式(7)计算 Jacobian 矩阵 $\mathbf{J}(\mathbf{w})$;
- 4) 分别按式(9)、式(4)计算 $\Delta \mathbf{w}$ 和 $E(\mathbf{w}^{(k)})$;
- 5) 若 $E(\mathbf{w}^{(k)}) < \varepsilon$, 转到(8), 否则以 $\mathbf{w}^{(k+1)}$ 为权值和阈值计算误差函数 $E(\mathbf{w}^{(k+1)})$;
- 6) 若 $E(\mathbf{w}^{(k+1)}) < E(\mathbf{w}^{(k)})$, 则令 $k = k + 1$, $\mu = \mu/\beta$, 回到 3); 否则这次不更新权值和阈值, 令 $\mathbf{W}^{(k+1)} = \mathbf{W}^{(k)}$, $\mu = \mu\beta$, 并回到(5);
- 7) 结束。

2.2. 网络结构设计

在进行网络结构设计时, 需要考虑网络的层数(除输入和输出层外, 是否需要中间隐含层和需要几层隐含层)、每层神经元的个数、网络输入初始值的选择、

学习速率和期望误差等主要因素。

本文采用单隐含层的三层 BP 网络来模拟瓦斯突出的变化情况。

输入层神经元的个数由影响瓦斯突出与爆炸的因素个数决定。当影响因素越多时, 网络就会越复杂, 训练时间加长, 因此正确选择影响瓦斯突出与爆炸的因素非常重要。根据实际情况, 选取井巷温度、瓦斯浓度、通风风速、煤层压力、氧气浓度、采场地质情况(即地质构造, 顶底板岩层岩性及其组合特征)和采矿因素(即开采深度、开采厚度、巷道尺寸、工作面推进速度、重复采动及采煤方法和顶板管理方法)等 7 个主要影响瓦斯突出与爆炸的因素作为网络输入项, 即选取输入神经元的个数为 7 个。为了动态的模拟瓦斯突出与爆炸灾害事故, 本文选择瓦斯突出与爆炸与否作为输出层变量, 所以输出层上的神经元对应着瓦斯突出与爆炸的可能性, 故选输出层神经元的个数为 1。

隐含层神经元的作用是从样本中提取并存储其内在规律, 每个隐含层神经元存在若干个权值, 而每个权值都是增强网络映射能力的一个参数。本文采用试凑法从最小隐含节点数 9 开始检验, 最终确定隐含层神经元个数为 15。

初始权值和阈值的选择对于网络学习是否达到局部最小、是否能够收敛以及训练时间的长短都有较大影响, 本文选取初始权值和阈值的区间为 [-1, 1]。

学习速率决定每一次循环训练中所产生的权值的变化量。大的学习速率会导致网络的不稳定, 但小的学习速率又会导致训练时间延长, 收敛速度很慢, 本文选择 0.02 是比较合适的既能保证收敛速度又能保证网络稳定的学习速率。

期望误差值是通过网络对不同误差值分别进行训练比较后确定的最佳值。本文在模型预测时发现, 当选取 20,000 个样本数据时, 设置期望误差为 0.005 可满足样本的误差需求, 并使网络具有较好的推广能力。

2.3. 模型的程序设计

2.3.1. 程序设计流程

本文预测模型的实现, 在.NET 中对样本数据进行预处理后, 然后在 MATLAB7.1 中编程完成, 具体流程见图 1, 主要包括训练样本的准备和归一化处理,

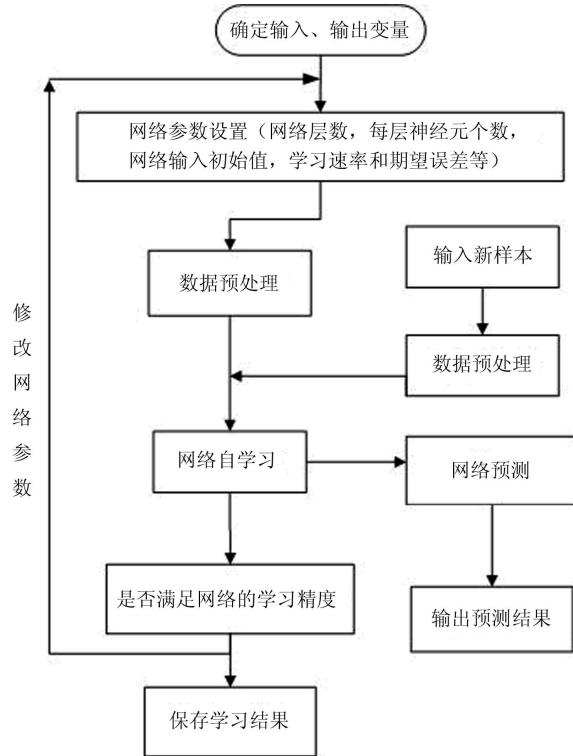


Figure 1. Flow chart of the prediction model
图 1. 预测模型流程图

神经网络的训练学习和利用训练后的神经网络对瓦斯灾害进行预测三大步骤。具体包括：

- 1) 确定影响瓦斯灾害的输入变量个数为 7, 输出变量个数为 1;
- 2) 设置神经网络参数：网络层数为 3；隐含层神经元个数为 15；初始权值和阈值的区间均为 $[-1,1]$ ；学习速率为 0.02；期望误差为 0.005；
- 3) 对原始输入和输出数据进行归一化处理，提出原始输入和输出数据的最大最小值；
- 4) 给出网络学习函数，进行网络学习训练；
- 5) 收敛检查，如果收敛，保存学习结果进行预测；如果不收敛，调整网络参数，重新进行网络训练学习；
- 6) 对网络输入新数据进行归一化处理和预测。

2.3.2. 网络输入、输出数据的预处理

在进行网络训练前，为了保证所有数据得到网络的同等对待，并且加快网络的训练速度，本文首先利用 MATLAB 中提供的归一化方法对神经网络的输入和输出数据进行预处理，使得所有样本的输入信号其均值接近于 0 或与其均方差相比很小，使归一化后的数据分布在 $[-1,1]$ 区间内。首先函数 premnmn 对输入

矩阵 P 和输出矩阵 T 进行归一化处理，然后在网络训练学习时用归一化之后的数据，即 $\text{train}(\text{net}, \text{PN}, \text{TN})$ 。

在训练网络时如果所用的是经过归一化的样本数据，那么当用训练好的网络对新数据 PNEW 进行预测时，也需要用函数 tramnmx 对新数据进行归一化处理。同时对预测结果 $Y_n = \text{sim}(\text{net}, \text{PNEWN})$ 利用 postmnmx 函数作反归一化处理(见表 1)。

3. 实例

3.1. 网络训练模式的选择

神经网络在训练学习时受样本输入顺序的影响，严重时会影响用户要求的训练精度。本文采用批处理学习方式输入数据，使用一批学习样本产生的总误差来调整权值，既可解决因样本输入顺序引起的精度问题和训练抖动问题，又可方便的为整个网络指定一个训练函数。

3.2. 瓦斯监测源数据

根据在矿山井下巷瓦斯传感器收集到的真实环境中的瓦斯监测数据集，包含每分钟瓦斯浓度的监测最小 min 值，最大 max 值和平均 avg 值和 3 列，如图 2 所示。

在瓦斯矿井采煤工作面瓦斯监测系统中，传感器设定的报警断电值为 1.5%，当瓦斯浓度降到 1% 以下才能恢复生产。在本文中将网络输出值作二值化处理，即当瓦斯传感器发出警报时，其值为 1，否则其值为 0。

Table 1. Functions in Matlab 7.1
表 1. 本文所用 Matlab7.1 中的函数

函数功能	函数	语句
对原始数据进行归一化处理	premnmm	[PN, MINP, MAXP, TN, MINT, MAXT] = premnm(P, T) 其中 P, T 分别为原始输入和输出数据，MINP 和 MAXP 分别为 P 中的最小值和最大值，MINT 和 MAXT 分别为 T 的最小值和最大值
网络训练	train	net = train (net, PN, TN)
反归一化	postmnmx	a = postmnmx (Y, MINT, MAXT)
对新数据进行归一化	tramnmx	PNEWN = tramnmx (PNEW, MINP, MAXP)
LM 算法模拟	trainlm	trainFcn = "trainlm"
模拟网络输出	sim	Yn = sim (net, PNEWN)

ID	min00	avg00	max00	min02	avg02	max02	min04	avg04	max04	min06	avg06	max06	min08	avg08	max08
1	0.015	0.015	0.015	0.015	0.015	0.015	0.015625	0.02	0.015	0.015	0.015	0.015	0.015	0.015	0.015
2	0.015	0.015	0.015	0.015	0.015	0.015	0.015714	0.02	0.015	0.015	0.015	0.015	0.016429	0.02	0.015
3	0.0175	0.02	0.015	0.015714	0.02	0.015	0.01625	0.02	0.015	0.015	0.015	0.015	0.015	0.015	0.015
4	0.016429	0.02	0.015	0.015625	0.02	0.015	0.01625	0.02	0.015	0.015	0.015	0.015	0.015625	0.02	0.015
5	0.015	0.015	0.015	0.015625	0.02	0.015	0.015625	0.02	0.015	0.015	0.015	0.015	0.015714	0.02	0.015
6	0.03	0.03	0.025	0.0275	0.03	0.025	0.025714	0.03	0.015	0.0225	0.025	0.015	0.019375	0.025	0.015
7	0.027857	0.03	0.015	0.025	0.03	0.015	0.023125	0.025	0.025	0.027143	0.03	0.025	0.025	0.025	0.015
8	0.015	0.015	0.015	0.01625	0.02	0.015	0.015	0.015	0.015	0.015625	0.02	0.015	0.015625	0.02	0.015
9	0.015	0.015	0.015	0.015	0.015	0.015	0.015	0.015	0.015	0.015	0.015	0.015	0.015	0.015	0.015
10	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
11	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.005	0.009286	0.01	0.01
12	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01

Figure 2. Gas monitoring data of coal mine

图 2. 矿山瓦斯监测数据

3.3. 训练样本的选取及分类

采用自适应 LMBP 神经网络方法建模的首要条件是有大量具有典型性和高精度的样本。为了避免网络训练的过适应(当样本数目趋于无穷时, 经验风险一致收敛于真实风险。一般情况下训练样本的数目往往是有限的, 由此导致经验风险与期望风险不一致, 尽管训练的网络具有最小的经验风险最小化(Empirical Risk Minimization—ERM)值, 但却不具有较强的推广能力, 即称为“过适应”问题^[14,15]), 提高网络的泛化能力, 本文使用 19,878 个抽样点, 并采用随机抽样法将数据等分成训练样本(用于训练网络、更新网络的权值和阈值)、监控样本(用来防止网络过拟合的出现, 通过在网络训练过程中计算自身的误差变化以监控网络训练)和测试样本(用来评价模型的预测精度)三组, 以进行训练、监控和测试。

3.4. 网络训练结果的输出

将在 LMBP 网络中选择的 19,878 个样本数据, 输入网络进行训练, 当训练样本数据的均方误差和交叉检验样本数据的均方误差达到最小值时, 训练结束, 保存网络。图 3 显示当训练次数达到 25 次时, 网络训练结束, 均方误差为 0.00489495, 达到设定要求(期望输出值与实际输出值的训练误差为 0.005)。

图 3 中, 红色线为测试数据误差曲线, 蓝色线为训练数据误差曲线, 绿色线为监控数据误差曲线, 黑色线为目标误差曲线, 通过 LMBP 神经网络的模拟后, 输出结果和目标一致性的模拟近似度达到 0.982。

3.5. 网络预测

为了测试 LMBP 网络的预测功能, 本文选取了包

含不同月份的矿井瓦斯监测数据作为网络学习的训练样本数据, 即分别采用了包含 2 个月(2009 年 1 月和 2 月)、3 个月(2009 年 1~3 月)、4 个月(2009 年 1~4 月)、5 个月(2009 年 1~5 月)和 6 个月(2009 年 1~6 月)的矿井监测数据, 用于推测下一个月的瓦斯数据状况, 预测结果如表 2 所示。

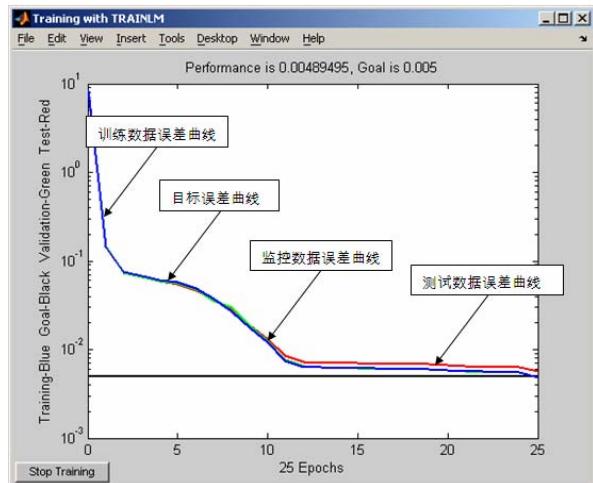


Figure 3. Error performance curve

图 3. 误差性能曲线

Table 2. The results comparison of neural network gas prediction model
表 2. 神经网络瓦斯预测结果比较

输入数据的月份	采样数	采样数据记录个数(每个位置点采集 5 个瓦斯数据)	相同位置点的预测数据与实际监测数据对应比较的误差率		
			LMBP 算法	拟牛顿优化 BP 算法	弹性优化 BP 算法
1	1000	5000	10.8%	11.8%	12.2%
2	1000	10,000	6.8%	8.5%	8.1%
3	800	12,000	4.9%	6.9%	7.2%
4	800	16,000	4.1%	5.5%	6.3%
5	800	20,000	3.5%	4.5%	5.5%
6	800	24,000	3.2%	4.3%	5.2%

由表 2 可以看出, 随着网络输入训练数据量的增加, 网络预测的准确度也随着提高。当训练数据采用 5 个月的监控数据时, 预测的误差率已经相对比较稳定, 随着学习时间增加, 预测精度逐步提高。同时, 本文利用相同数据, 测试了拟牛顿优化 BP 算法和弹性优化 BP 算法, 结果显示 LMBP 算法的预测结果最优, 即当采用 5 个月的监控数据时, LMBP 算法的误差率达到 3.5%, 而拟牛顿优化 BP 算法和弹性优化 BP 算法的误差率分别是 4.5% 和 5.5%, 均比 LMBP 算法的误差率高。

4. 结论

本文利用 BP 神经网络的 LM 优化算法, 在考虑井下空间实体相关性和实体空间分布的前提下, 对矿井瓦斯突出与爆炸灾害进行了预测预报, 实验结果表明, LM 神经网络算法收敛速度快, 预测精度高, 是一种很好的可以模拟矿山瓦斯突出与爆炸灾害事故的矿山空间数据挖掘算法之一。

参考文献 (References)

- [1] 郭强, 陈兴民, 张立汉. 灾害大百科[M]. 太原: 山西人民出版社, 1996.
- [2] 隋鹏程. 中国矿山灾害[M]. 长沙: 湖南人民出版社, 1998.
- [3] 国家安全生产科技发展规划煤矿领域研究报告(2004~2010)[R]. 国家安全生产监督管理局和国家煤矿安全监察局, 2003.
- [4] 吴自立. AE 信号参数预测预报煤与瓦斯突出危险性的进展及展望[J]. 矿业安全与环保, 2005, 32(1): 27-29.
- [5] 李成武, 何学秋. 工作面煤与瓦斯突出危险程度预测技术研究[J]. 中国矿业大学学报, 2005, 56(1): 71-76.
- [6] 王海锋, 程远平, 吴冬梅, 刘洪永. 近距离上保护层开采工作面瓦斯涌出及瓦斯抽采参数优化[J]. 煤炭学报, 2010, 47(4): 590-594.
- [7] 傅鹤林, 李园园. 隧道施工岩溶及瓦斯预测预报技术简述[J]. 采矿技术, 2007, 7(4): 46-48.
- [8] 赵旭生. 人工神经网络在煤与瓦斯突出强度预测中的应用[J]. 煤田地质与勘探, 2002, 30(2): 23-25.
- [9] 郝吉生. BP 算法及其在煤与瓦斯突出预测中的应用[J]. 辽宁工程技术大学学报, 2004, 23(1): 9-11.
- [10] 吴财芳, 曾勇, 秦勇. 神经网络分析方法在瓦斯预测中的应用[J]. 地球科学进展, 2004, 19(5): 860-866.
- [11] 齐刘宇, 周孟然, 王然. 神经网络 BP 算法在瓦斯吸收光谱中的应用研究[J]. 煤矿安全, 2008, 39(10): 1-3.
- [12] K. Levenberg. A method for the solution of certain nonlinear problems in least squares. The Quarterly of Applied Mathematics, 1944, 2(2): 164-166.
- [13] D. W. Marquardt. An Algorithm for least-squares estimation of nonlinear inequalities. SIAM Journal of Applied Mathematics, 1963, 11(2): 431-441.
- [14] 戴洪磊, 徐泮林, 陈兰森, 刘文宝. 矿山瓦斯灾害神经元网络理论与方法[M]. 地震出版社, 2011.
- [15] 边肇祺, 张长水. 模式识别[M]. 清华大学出版社, 2000: 284-295.