

文章编号:1671-251X(2014)03-0028-04 DOI:

韩婷婷,吴世跃,王鹏军.基于马尔科夫残差修正的瓦斯浓度预测[J].工矿自动化,2014,40(3):28-31.

基于马尔科夫残差修正的瓦斯浓度预测

韩婷婷¹, 吴世跃¹, 王鹏军²

(1.太原理工大学 矿业工程学院,山西 太原 030024;

2.山西亚美大宁能源有限公司,山西 晋城 048000)

摘要:针对采用灰色神经网络预测瓦斯浓度时部分预测值精度不高的问题,提出用马尔科夫模型对三阶灰色神经网络模型预测结果进行修正的方法;介绍了灰色神经网络模型的建立和马尔科夫修正残差方法,并采用该方法对某煤矿不同时间、不同地点的瓦斯浓度进行分析预测。实际应用结果表明,经马尔科夫残差修正后的瓦斯浓度预测值与实测值的最大相对误差从14%减小到6%,修正后的瓦斯浓度变化曲线更接近实际瓦斯浓度变化趋势。

关键词:瓦斯浓度预测;马尔科夫链;残差修正;灰色神经网络

中图分类号:TD712.5 文献标志码:A 网络出版时间:

网络出版地址:

Prediction of gas concentration based on residual correction of Markov chain

HAN Tingting¹, WU Shiyue¹, WANG Pengjun²

(1.College of Mining Engineering, Taiyuan University of Technology, Taiyuan 030024, China;

2.Shanxi Asian American Daning Energy Co., Ltd., Jincheng 048000, China)

Abstract: In view of problem of low accuracy of part of prediction values while using gray neural network for gas concentration prediction, the paper proposed a method of using Markov model to correct prediction results of three-order gray neural network model. It described establishment of gray neural network model and Markov residual correction method, and used the method to analyze and predict gas concentration in different locations of a coal mine at different times. Practical application results show that the maximum relative error of predicted gas concentration and measured value reduced from 14% to 6% after Markov residual correction, and the corrected gas concentration curve is closer to the actual changing trend of gas concentration.

Key words: prediction of gas concentration; Markov chain; residual correction; gray neural network

0 引言

井下瓦斯浓度变化受地质构造、煤层厚度、埋藏深度、工作面风量、煤层瓦斯抽放量等因素的影响,是一个影响因素繁多的非线性复杂系统。从预测时间角度出发,瓦斯浓度在短时间内的变化具有规律性。根据瓦斯浓度变化规律预测瓦斯浓度的方法有

时间序列模型预测法、商空间模型预测法、灰色动态模型预测法、神经网络模型预测法和马尔科夫模型预测法等^[1]。这些方法均利用实测瓦斯浓度的动态变化特性,对采集到的瓦斯浓度监测数据进行研究,结合各方法的适用条件对瓦斯浓度变化趋势进行预测,为预防瓦斯事故提供重要信息。单亚峰等人建立了基于改进极端学习机的混沌时间序列预测模

收稿日期:2013-06-08;修回日期:2013-11-26;责任编辑:胡娴。

基金项目:国家科技支撑计划项目(2007BAK29B01)。

作者简介:韩婷婷(1988—),女,山西太原人,硕士研究生,主要研究方向为煤矿瓦斯预测预警、安全信息系统,E-mail:kangting8890@163.com。

通讯作者:吴世跃。

型^[2]。该模型应用多变量混沌时间序列,对煤矿瓦斯浓度或涌出量进行预测,提高了预测精度,但为了简化分析,只考虑对煤矿瓦斯涌出量影响较大的因素,其考虑因素不全面致使有些预测值与实测值间存在较大误差。魏星等人基于矿山统计法,采用蒙特卡罗方法,在金融学 HJM 模型的基础上,利用 Microsoft Excel 的数据分析能力,对瓦斯浓度的历史数据进行分析,总结出瓦斯浓度变化规律^[3]。但该方法中应用的瓦斯数据量大,造成预测工作量较大。为减少工作量,满足预测精度要求,应选取合适的预测模型。中国矿业大学白庆生等人应用灰色神经网络组合模型预测瓦斯浓度,充分利用了灰色方法所需数据量少、可以处理少数据贫信息问题的优势,及 BP 神经网络方法的自学习能力,提高了瓦斯浓度的预测精度^[4]。但该模型中 GM(1,1)建模对数据的单调性要求较高,实际瓦斯浓度变化受多种因素影响,并不是单调递增或递减过程。黄莹等人分析灰色预测模型与 BP 神经网络算法的基础上,对现有的一阶灰色神经网络模型做了进一步优化和完善,建立了基于时间响应函数的三阶灰色神经网络 GNNM(3,1)模型,不仅可以反映单调的情形,还可以准确地反映非单调的或振荡的动态过程^[5]。但该模型的网络训练是一个艰难的过程,为了获得最接近实际的预测效果,需要重复试验多次,造成部分预测值的精度不高。针对以上问题,本文应用马尔科夫模型修正误差残值法预测瓦斯浓度,提高了预测精度,更精确地体现了真实瓦斯浓度的变化规律。

1 预测模型的建立

1.1 灰色神经网络模型

煤矿现用的瓦斯浓度监测系统获取的瓦斯浓度变化信息是一个非单调性的、信息不完全已知的灰色系统,参考文献[5]介绍了三阶灰色神经网络模型 GNNM(3,1),由于其具有 3 个特征根,所以能真实反映非单调情况。设实测瓦斯浓度观测数据序列为 $X^{(0)} = (X^{(0)}(1), X^{(0)}(2), \dots, X^{(0)}(n))$, 累加生成序列 $X^{(1)} = \{x^{(1)}(k)\}$, 其中 $X^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i)$, $k=0, 1, \dots, n-1$; 并有相应的多次累减序列 $\alpha^{(j)} X^{(1)} = \{\alpha^{(j)} X^{(1)}(k)\}$, $k=0, 1, \dots, n-1, j=1, 2, 3$ 。建立瓦斯浓度随时间变化的灰微分方程:

$$\frac{d^3 x^{(1)}(t)}{dt^3} + a_1 \frac{d^2 x^{(1)}(t)}{dt^2} + a_2 \frac{dx^{(1)}(t)}{dt} + a_3 x^{(1)}(t) = b \quad (1)$$

式中: a_1, a_2, a_3 为发展系数; b 为灰作用量。

式(1)对应齐次方程的特征方程为 $\lambda^3 + a_1 \lambda^2 + a_2 \lambda + a_3 = 0$, 设特征方程对应的特征根分别为 $\lambda_1, \lambda_2, \lambda_3$, 求得瓦斯浓度随时间变化的时间响应函数为

$$x^{(1)}(t) = C_1 \exp(\lambda_1 t) + C_2 \exp(\lambda_2 t) + C_3 \exp(\lambda_3 t) + \frac{c}{a_3} \quad (2)$$

式中: C_1, C_2, C_3, c 为常数项。

相应的 GNNM(3,1)的离散时间响应函数为 $y(k) = x^{(1)}(k) = C_1 \exp(\lambda_1 k) + C_2 \exp(\lambda_2 k) +$

$$C_3 \exp(\lambda_3 k) + \frac{c}{a_3} \quad (3)$$

将式(3)映射到神经网络中,得到 GNNM(3,1)网络结构,如图 1 所示。其中: $k(n)$ ($k=0, 1, \dots, N-1$) 为输入的样本值, N 为样本个数, n 为网络训练次数; w_{ji} 为神经元 i 与神经元 j 之间的权值; d_j 表示神经元 j 的输出实测值; y 为网络输出的模拟值; e_j 为输出误差。




图 1 映射出的 GNNM(3,1)网络结构

1.2 马尔科夫修正残差

马尔科夫链预测过程描述的是一个随机时间序列的动态变化过程,其残差修正模型的处理对象是随机波动性大的数据,与灰色神经网络模型形成互补。

根据实际情况对三阶灰色神经网络模型预测值与实际监测值间的误差大小进行归类,划定马尔科夫链状态区间。建立马尔科夫一步转移概率矩阵 $p(1)$ 及 m 步转移概率矩阵 $p(m)$:

$$p(1) = \begin{bmatrix} p_{11}^{(1)} & p_{12}^{(1)} & \cdots & p_{1n}^{(1)} \\ p_{21}^{(1)} & p_{22}^{(1)} & \cdots & p_{2n}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ p_{m1}^{(1)} & p_{m2}^{(1)} & \cdots & p_{mn}^{(1)} \end{bmatrix} \quad (4)$$

$$p(m) = \begin{bmatrix} p_{11}^{(m)} & p_{12}^{(m)} & \cdots & p_{1n}^{(m)} \\ p_{21}^{(m)} & p_{22}^{(m)} & \cdots & p_{2n}^{(m)} \\ \vdots & \vdots & \ddots & \vdots \\ p_{m1}^{(m)} & p_{m2}^{(m)} & \cdots & p_{mn}^{(m)} \end{bmatrix} \quad (5)$$

误差值从 i 状态经过 k 步以后处于 j 状态的概率可用式(6)解出:

$$p(m) = [p(1)]^m \quad (6)$$

根据上述原理,建立马尔科夫链预测模型:

$$p_{t+1} = p_0 [p^{(1)}]^{t+1} \quad (7)$$

式中: p_{t+1} 为 $t+1$ 时刻的概率分布; p_0 为初始时刻的无条件概率分布。

根据灰色神经网络的预测结果,按照预测结果相对误差的绝对值将预测序列划分为若干个状态区间;求得一步转移概率矩阵;确定预测参数的状态向量,代入式(7)即可求得基于马尔科夫链修正的灰色神经网络模型的转移概率矩阵,并利用式(8)对灰色神经网络模型预测值进行修正:

$$\frac{|Y - Y_g|}{Y} = X \quad (8)$$

式中: Y 为马尔科夫修正误差后的瓦斯浓度预测值; Y_g 为灰色神经网络预测值; X 为原状态区间的分界值。

模型中未考虑预测结果相对误差的符号变化规律,将预测序列相对误差分成 2 种状态:假设 s 时刻预测结果相对误差为正数,记为状态 1;若为负,记为状态 2。根据马尔科夫修正模型原理,得出预测结果相对误差的符号转移矩阵:

$$E = \begin{bmatrix} E_{11} & E_{12} \\ E_{21} & E_{22} \end{bmatrix} \quad (9)$$

则预测结果相对误差的符号预测模型为

$$Z_{t+1} = Z_0 [E^{(1)}]^{t+1} \quad (10)$$

式中: Z_{t+1} 为 $t+1$ 时刻的概率分布; Z_0 为初始时刻的符号状态分布; $E^{(1)}$ 为一步转移概率矩阵。

1.3 瓦斯浓度预测简要步骤

(1) 以近期井下瓦斯浓度监测资料为基础,根据灰色神经网络模型,将已知数据划分为训练样本数据和预测样本数据。

(2) 用灰色模型对训练样本数据进行预测,得到预测值。

(3) 将灰色预测值作为神经网络的训练样本,进行网络训练,得到灰色神经网络模型的最终预测值,并分析训练样本数据预测值与实测值间的相对误差。

(4) 根据误差分析结果,划定误差符号和误差绝对值的马尔科夫链状态区间,并根据划分状态集分别计算概率转移矩阵。

(5) 利用式(8)求得采用马尔科夫修正误差后的瓦斯浓度预测值。

2 实际应用

假定瓦斯浓度在短时间内的变化具有规律性,

任取某煤矿几个工作地点监测的瓦斯浓度作为研究对象,对未来时刻的瓦斯浓度变化趋势进行预测,验证本文所提方法的可行性。以某煤矿 N2105 回风巷 2010 年 4 月 7 日的瓦斯浓度监测数据为研究数据,预测未来时刻的瓦斯浓度值。灰色预测所需的数据量较少,将该天时刻平均分成 48 等分(图 2),以 0:00—18:00 的瓦斯浓度实测数据作为训练样本,18:30—24:00 的瓦斯浓度作为预测样本,建立瓦斯浓度预测 GNNM(3,1)模型。




图 2 N2105 回风巷瓦斯浓度实测值

根据最小二乘法求得灰色神经网络模型灰微分方程的各个系数值: $a_1 = 0.677\ 3$, $a_2 = 0.699\ 5$, $a_3 = -0.622\ 5$, $b = 0.017\ 5$ 。根据系数值确定神经网络初始权值与阈值。利用 Matlab 神经网络工具箱提供的 newff 函数创建 BP 神经网络模型,用训练样本数据对创建好的网络模型进行训练。训练参数:学习速率为 0.01,最大训练次数为 1 000,要求训练精度为 0.002。训练过程中误差变化趋势如图 3 所示,当网络学习迭代到 308 次时,学习自动停止,学习精度达到了 0.001 998 35,网络趋于稳定。




图 3 灰色神经网络训练误差曲线

灰色神经网络预测值与实测值的比较见表 1。从表 1 可以看出,一些样本的预测值并不理想,与实测值间的相对误差较大,故采用马尔科夫修正残差。根据误差值大小,划定修正值与实测值和灰色神经网络预测值的比较结果,如图 4 所示(横坐标表示监测时间序号,每间隔 30 min 一个序号)。从图 4 可以看出,修正后的结果更接近实测值的变化趋势,预测值与实测值间的相对误差范围从 12.74%—2.3%缩小到 4.87%—0.36%,表明本文所提方法能很好地预测回风巷中的瓦斯浓度变化。

表1 瓦斯浓度预测值与实测值的相对误差				
监测时间	序号	瓦斯浓度 实测值/%	预测值/%	相对误差
18:30	38	0.41	0.462 2	-0.127 3
19:00	39	0.40	0.419 0	-0.047 5
19:30	40	0.36	0.352 3	0.021 4
20:00	41	0.34	0.297 6	0.124 7
20:30	42	0.35	0.305 4	0.127 4
21:00	43	0.30	0.278 9	0.070 3
21:30	44	0.34	0.297 6	0.124 7
22:00	45	0.32	0.327 6	-0.023 8
22:30	46	0.29	0.255 4	0.119 3
23:00	47	0.29	0.255 4	0.119 3
23:30	48	0.26	0.250 8	0.035 4
24:00	49	0.35	0.305 4	0.127 4




图4 N2105回风巷各值比较

为了更好地体现本文方法的适应性,将该矿W9总回风巷2010年4月30日的瓦斯浓度数据分成48等分作为分析数据,对5月1日前6h的瓦斯浓度变化趋势进行预测,结果如图5所示(横坐标与图4相同)。从图5可看出,当天的瓦斯浓度波动比较大,灰色神经网络预测结果不理想,预测值与实测值间的最大相对误差达到了13.87%,经过马尔科夫修正后,预测值的变化趋势更接近实测值,最大相对误差仅为5.92%。




图5 W9总回风巷各值比较

2010年5月1日15:39:23时刻该矿105综采工作面瓦斯浓度高于报警值,发生报警。为实现提前预测,保证工作人员能够有充足时间进行处理,对

该日的瓦斯浓度进行预测,预测结果如图6所示(横坐标与图4相同)。从图6可看出,当天的瓦斯浓度总体走向逐步递增,在发生报警的1h前,预测的瓦斯浓度值已经接近报警值了,若在发生报警前知道瓦斯浓度发展趋势,则可以给工作人员充足的时间,使其可以及时采取增大风量等措施来降低瓦斯浓度,避免瓦斯事故的发生。




图6 105综采工作面各值比较

3 结语

将马尔科夫残差修正应用到瓦斯浓度预测模型中,对三阶灰色神经网络模型预测结果进行修正,克服了灰色神经网络预测的缺点,提高了预测精度。实际应用结果表明,修正后的瓦斯浓度变化曲线更接近实际瓦斯浓度变化趋势,预测值与实测值的最大相对误差从14%减小到6%。虽然瓦斯浓度在短时间内的变化具有规律性,灰色神经网络预测有数据少的优势,但是本文并未考虑相隔时间,未考虑多长时间、多少数据量能够得出最好的预测结果。笔者将对这些问题进行进一步研究。

参考文献:

[1] 曾倩倩. 基于商空间的煤矿瓦斯浓度预测的研究[D]. 太原:太原理工大学,2011.

[2] 单亚峰,侯福营,付华,等. 基于改进极端学习机的混沌时间序列瓦斯涌出量预测[J]. 中国安全科学学报, 2012,22(12):58-63.

[3] 魏星,王汝琳,巫金庭. 基于HJM模型和蒙特卡罗方法的瓦斯浓度预测研究[J]. 工矿自动化,2010,36(5):37-40.

[4] 白庆生,敬彦宁,张博. 基于灰色-神经网络组合模型的瓦斯涌出量预测[J]. 煤炭技术,2009,28(8):70-72.

[5] 黄莹,胡昌华. 三阶灰色-神经网络模型的建立及其在导弹故障预报中的应用[J]. 电光与控制,2006,13(5):39-41.

[6] 李小燕. 灰色神经网络预测模型的优化研究[D]. 武汉:武汉理工大学,2009.