

瓦斯涌出量的混合 pi-sigma 模糊神经网络预测模型

潘玉民*, 赵立永, 张全柱

(华北科技学院 电子信息工程学院, 北京 101601)

(*通信作者电子邮箱 pym_001@ncist.edu.cn)

摘要:提出了一种利用混合 pi-sigma 模糊神经推理方法建立瓦斯涌出量的预测模型。该模型采用高斯基函数作为模糊子集的隶属度函数,可在线动态调整隶属度函数和结论参数。与神经网络预测模型比较,该模型具有物理意义明确、原理清晰、收敛速度快、预测精度高等特点,在对某矿瓦斯涌出量数据的仿真结果表明,该方法预测准确度高、速度快,并且结果具有可重复性,证明该方法是有效的。为便于工程实际应用,在 Matlab 环境中开发了基于图形用户界面(GUI)的仿真应用界面,给出了使用方法和预测结果。实验同时表明,对所采用的数据,模型的训练精度设置为 0.001 时网络的泛化能力最好,网络训练精度和预测精度之间不具有正比关系。

关键词:混合 pi-sigma 模糊神经网络;瓦斯涌出量;预测;图形用户界面

中图分类号: TP273 **文献标志码:** A

Gas emission prediction model of hybrid pi-sigma fuzzy neural network

PAN Yu-min*, ZHAO Li-yong, ZHANG Quan-zhu

(College of Electronic Information Engineering, North China Institute of Science and Technology, Beijing 101601, China)

Abstract: A gas emission prediction model established by using reasoning method of hybrid pi-sigma fuzzy neural networks was proposed. The model adopted Gaussian function as a fuzzy membership function, and the membership functions and conclusions parameters of the model could be adjusted online dynamically. Compared with the neural network prediction model, the method has characteristics of clear physical meaning, clear principle, fast convergence, high prediction accuracy and so on. The gas emission data of a coal mine simulation results show that the prediction has a high accuracy, fast convergence and the prediction results can be repeated, it is proved that the method is effective. In order to facilitate the practical application, the authors developed a Graphical User Interface (GUI) application interface in the Matlab environment, and gave the method and prediction results. The experiments also show that, for the data, the generalization ability of the model is best when the training accuracy is set 0.001, and the training accuracy and the prediction accuracy of the model do not have positive relationship.

Key words: hybrid pi-sigma neural fuzzy network; gas emission; prediction; Graphical User Interface (GUI)

0 引言

瓦斯事故是煤矿安全生产中最主要的地质灾害,也是制约煤矿生产可持续发展的“瓶颈”。预防与监控瓦斯事故历来受到世界各主要采煤国的高度重视,也是国内外学者广泛关注的重要课题,实现从源头上治理瓦斯灾害,准确预测瓦斯涌出量是解决问题的关键之一。

瓦斯涌出量是一个非常复杂的地质参数,它受许多因素的影响,如地质构造、煤层厚度、煤体结构、埋藏深度等自然因素,以及与开采技术相关,这些因素本身是随机变量,各因素之间相互制约、互为因果。因此,瓦斯涌出量实际上是一个多变量、时变、灰色、高度非线性及复杂的动力学系统,通常很难精确预测。瓦斯涌出量的大小不仅反映不同煤层的危险程度,同时也是决定开发新井、新采区、新工作面规模、通风、安全技术水平的重要指标以及煤层气资源评价的基础^[1]。

目前,瓦斯涌出量的预测方法主要有:矿山统计法、瓦斯含量法、分源预测法、类比法、瓦斯地质法、数学模型法、速度

预测法^[2],这些方法属于线性预测法。近年来,出现了灰色系统预测、模糊综合评判法、神经网络预测等非线性预测方法,其中以神经网络预测方法尤为突出,近年来获得了广泛应用,取得了一系列研究成果^[1-3,12]。

目前神经网络预测方法主要是以 BP (Back-Propagation) 和径向基函数 (Radical Basis Function, RBF) 神经网络为主。其显著特点是仅借助于样本数据,即可实现由 \mathbf{R}^n 空间 (n 为网络输入节点数) 到 \mathbf{R}^m 空间 (m 为输出节点数) 的高度非线性映射,而且这种映射可以由足够的训练样本来保证。神经网络不依赖精确的数学模型,容错性和鲁棒性强,有很强的非线性函数逼近能力,为瓦斯涌出量这一高度非线性的预测提供了一个全新的途径。但是,在采用神经网络设计瓦斯涌出量预测模型时也存在如下几个问题:

- 1) 网络结构设计尚无统一的理论依据;
- 2) 预测结果通常为随机值;
- 3) 机理缺乏透明度;
- 4) 初始参数确定问题;

收稿日期:2011-11-02;修回日期:2011-12-10。 基金项目:河北省教育厅科学研究基金资助项目(Z2006439)。

作者简介:潘玉民(1958-),男,内蒙古赤峰人,副教授,硕士,主要研究方向:智能控制、复杂系统建模; 赵立永(1978-),男,河北唐山人,讲师,硕士,主要研究方向:模式识别、电力电子; 张全柱(1965-),男,内蒙古集宁人,教授,博士,主要研究方向:电力电子、交流传动。

5) 过度拟合现象;

6) 局部极小问题。

其中大多数问题需要在实验过程中加以确定,采用试凑法,从多次实验中找到“最合适”的一种。由于影响神经网络预测能力的参数很多,上述方法未必能找到真正意义上的最合适的预测模型结构和参数。为此,本文提出了一种采用混合 pi-sigma 模糊神经网络的瓦斯涌出量预测的新方法,并开发了仿真预测可视化应用界面。

1 混合 pi-sigma 模糊神经网络

神经-模糊建模预测是近年来基于模糊集理论发展起来的一种新的预测方法。最新研究表明,将人工神经网络和模糊逻辑推理相结合构成的自适应神经-模糊推理系统具有收敛速度快、拟合能力强、预测精度高、网络训练结果确定等优势。

模糊逻辑和神经网络具有很强的互补性,它们都是对同一参考系——人脑智能的模拟,因此具有自然的内在联系,类似“人脑”的软硬件。神经网络中引入模糊逻辑可使网络具有逻辑推理能力,彼此优势互补,物理意义和推理过程清晰。

针对多维模糊推理中的推理规则庞大的问题,学者 Takagi 和 Sugeno 提出了一种新的模糊推理模型,即 T-S 模型^[5]。该模型模糊规则中“if”部分与扎德规则中的“if”部分相似,但是其“then”部分是精确函数,通常是输入变量的多项式。T-S 模型可用少量的模糊规则生成较复杂的非线性函数,这在处理多变量系统时能有效地减少模糊规则个数,因而具有较大的优越性。由于 T-S 模型结论参数是线性函数而非模糊数,在实际系统中结论部分不能直接从专家经验和操作数据中得到,必须通过一定的算法进行训练。因此,模型参数的辨识成为建立 T-S 型模糊系统的主要问题。

T-S 模型比 Mamdani 模型简单,它的后件为输入变量的线性组合,计算结果为一精确值,故结构简洁,计算快速,并简化了模糊推理过程。

T-S 模型用以下“if-then”规则的形式定义模糊系统的规则^[5-6]。

$$R^i: \text{if } x_1 \text{ is } A_1^i, x_2 \text{ is } A_2^i, \dots, x_n \text{ is } A_n^i \text{ then } y^i = p_0 + p_1 x_1 + \dots + p_n x_n \quad (1)$$

其中: p_h 是结论多项式的系数, $h = 0, 1, 2, \dots, n, i = 1, 2, \dots, m, R^i$ 是第 i 个模糊规则。对于输入向量 $x = (x_1, x_2, \dots, x_k)^T$, 模糊系统的各规则输出 y_n 等于各 y_i 的加权平均:

$$y_n = \frac{\sum_{i=1}^m w^i y^i}{\sum_{i=1}^m w^i} \quad (2)$$

其中加权系数 w^i 包括规则 R^i 作用于输入取得的值。

$$w^i = \prod_{j=1}^k \mu_{A_j^i}(x_j) \quad (3)$$

1.1 网络结构及原理

混合型 pi-sigma 神经网络是一种自适应能力很强的模糊模型。这种模型不但实现了模糊模型的自动更新,而且能不断修正各模糊子集的隶属函数,使模糊建模更具合理性^[7]。

在混合 pi-sigma 模糊神经网络中,将模糊推理中的取小运算改为代数乘积运算,使模型计算简化,以一个 3 输入/单输出的混合型 pi-sigma 模糊神经网络预测模型为例,结构如图 1 所示,其中, S、P 和 (\cdot) 分别表示相加、相乘、相乘运算^[8]。

网络输出:

$$y_n = \frac{\sum_{i=1}^m w^i y^i}{\sum_{i=1}^m w^i} = \frac{\sum_{i=1}^m \left[\prod_{j=1}^3 \mu_{A_j^i}(x_j) \left(p_0 + \sum_{j=1}^3 p_j x_j \right) \right]}{\sum_{i=1}^m \left[\prod_{j=1}^3 \mu_{A_j^i}(x_j) \right]} \quad (4)$$

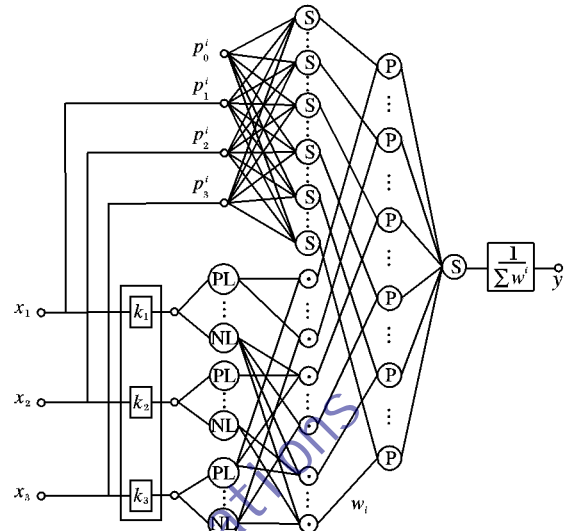


图 1 混合 pi-sigma 模糊神经网络结构

各模糊子集的隶属函数取高斯型,即:

$$\mu_{A_j^i} = \exp \left[- \frac{(x_j - c_j^i)^2}{b_j^i} \right] \quad (5)$$

1.2 网络学习算法

设网络的期望输出为 y_d , 定义代价函数:

$$E^r = \frac{1}{2} \sum_{r=1}^P (y_d^r - y_n^r)^2 \quad (6)$$

其中: P 为样本数, $r = 1, 2, \dots, P$ 。对每个样本代价函数记为 $E = (y_d - y_n)^2/2$, 所有样本的 E 求出后,再计算 E^r , 根据梯度下降法有^[9-10]:

$$p_j^i(k) = p_j^i(k-1) - \eta_p \frac{\partial E}{\partial p_j^i} + \alpha_p [p_j^i(k-1) - p_j^i(k-2)] \quad (7)$$

其中:

$$\frac{\partial E}{\partial p_j^i} = \frac{\partial E}{\partial y_n} \frac{\partial y_n}{\partial p_j^i} = - (y_d - y_n) w^i / \sum_{i=1}^m w^i \cdot \frac{\partial y^i}{\partial p_j^i} \quad (8)$$

其中 $j = 1, 2, 3$ 。对 c_j^i, b_j^i , 有:

$$c_j^i(k) = c_j^i(k-1) - \beta \frac{\partial E}{\partial c_j^i} + \alpha_c [c_j^i(k-1) - c_j^i(k-2)] \quad (9)$$

$$b_j^i(k) = b_j^i(k-1) - \beta \frac{\partial E}{\partial b_j^i} + \alpha_b [b_j^i(k-1) - b_j^i(k-2)] \quad (10)$$

$$\frac{\partial E}{\partial c_j^i} = - (y_d - y_n) \cdot \left[y^i \sum_{i=1}^m w^i - \sum_{i=1}^m (w^i y^i) \right] / \left(\sum_{i=1}^m w^i \right)^2 \cdot 2(x_j - c_j^i) w^i / b_j^i \quad (11)$$

$$\frac{\partial E}{\partial b_j^i} = - (y_d - y_n) \left[y^i \sum_{i=1}^m w^i - \sum_{i=1}^m (w^i y^i) \right] / \left(\sum_{i=1}^m w^i \right)^2 \cdot w^i (x_j - c_j^i)^2 / (b_j^i)^2 \quad (12)$$

其中: η_p, β 为学习速率; $\alpha_p, \alpha_c, \alpha_b$ 为动量因子。由式(7) ~

(12) 可知,基于混合 pi-sigma 神经网络的模糊推理可方便地实现模糊规则参数和隶属度函数修正,实现自适应模糊建模。该模糊系统可以很好地反映动态映射关系,并具有定性知识表达能力,以样本数据为指导产生规则来训练网络,使网络内部知识具有明确的物理意义,从而可以很容易地确定网络结构及参数^[11]。

2 仿真过程及结果分析

采用表 1 的样本数据^[12],设计预测模型和仿真实验,该数据是某矿 3 个采煤工作面 18 个回采月份瓦斯涌出量的统计资料。

表 1 预测模型训练样本集

No	x_1	x_2	x_3	x_4	x_5	x_6	y
1	408	2.0	1.92	20	4.42	1825	3.34
2	411	2.0	2.15	22	4.16	1537	2.97
3	420	1.8	2.14	19	4.13	1751	3.56
4	432	2.3	2.58	17	4.67	2078	3.62
5	456	2.2	2.40	20	4.51	2104	4.17
6	516	2.8	3.22	12	3.45	2242	4.60
7	527	2.5	2.8	11	3.28	1979	4.92
8	531	2.9	3.35	13	3.68	2288	4.78
9	550	2.9	3.61	14	4.02	2325	5.23
10	563	3.0	3.68	12	3.53	2410	5.56
11	590	5.9	4.21	18	2.85	3139	7.24
12	604	6.2	4.03	16	2.64	3354	7.80
13	607	6.1	4.34	17	2.77	3087	7.68
14	634	6.5	4.8	15	2.92	3620	8.51
15	640	6.3	4.67	15	2.75	3412	7.95
16	450	2.2	2.43	16	4.32	1996	4.06
17	544	2.7	3.16	13	3.81	2207	4.92
18	629	6.4	4.62	19	2.8	3456	8.04

注: x_1 为煤层埋藏深度(m); x_2 为煤层厚度(m); x_3 为煤层瓦斯含量(m^3/t); x_4 为煤层间距(m); x_5 为日进度(m/d); x_6 为日产量(t/d); y 为绝对瓦斯涌出量(m^3/min)。

根据采煤工作面采集的观测数据对混合 pi-sigma 神经网络进行训练,建立采煤工作面瓦斯涌出量的模糊预测模型。

2.1 数据预处理

模糊神经网络输入/输出变量的选取:表 1 中影响瓦斯涌出量的因素有 6 个: $x_1 \sim x_6$,即煤层埋藏深度、煤层厚度、煤层瓦斯含量、工作面煤层与邻近煤层的层间距、工作面平均日进度、工作面平均日产量。若将 6 个因素都作为网络输入会产生冗余现象,降低模型的有效性。本文采用灰色关联度分析法^[13],去掉与瓦斯涌出量关联较小的因素。

对表 1 中的 7 个时间序列组,按照 $y, x_1 \sim x_6$ 顺序编号为 0 ~ 6,采用式(13) ~ (15) 计算相互之间的关联度:

$$\gamma(X_0, X_i) = \frac{1}{n} \sum_{k=1}^n \gamma(x_0(k), x_i(k)) \quad (13)$$

其中 $\gamma(X_0, X_i)$ 为 X_0 和 X_i 的灰色关联度。

定义两极最大差与最小差:设 $\Delta_i(k) = |x'_0(k) - x'_i(k)|$,于是:

$$M = \max_i \max_k \Delta_i(k)$$

$$N = \min_i \min_k \Delta_i(k)$$

则灰色关联度为:

$$\gamma_{0i}(k) = \frac{N + \xi M}{\Delta_i(k) + \xi M} \quad (14)$$

$$\gamma_{0i} = \frac{1}{n} \sum_{k=1}^n \gamma_{0i}(k) \quad (15)$$

式(14)中, ξ 为分辨系数, $\xi \in (0, 1)$ 。灰色关联度分析结果为:

$$\gamma(0, 3) = 0.8888, \gamma(0, 2) = 0.7862, \gamma(0, 6) = 0.7858$$

$$\gamma(0, 1) = 0.7686, \gamma(0, 5) = 0.6129, \gamma(0, 4) = 0.5793$$

可以看出,煤层间距 x_4 与瓦斯涌出量的关联度最小(0.5793),煤层瓦斯含量与瓦斯涌出量的关联度最大(0.8888),因此,去掉煤层间距因素,采用其余 5 个因素作为混合 pi-sigma 模糊神经网络的输入,瓦斯涌出量作为网络输出。

本文采用 Matlab R2006b 为平台编程建模。数据归一化采用“normr”命令,反归一化采用“norm”,该方法比其他归一化方法简单,又能避免 0、1 的出现。将处理后的样本输入网络进行训练。

2.2 实验结果及分析

混合 pi-sigma 模糊神经网络采用结构为 5 个输入/1 个输出。参数设置:学习速率 η_1 取 0.05,动量因子为 0.05,训练误差精度设置为 0.001。

选取第 1 ~ 14 个样本为训练样本,第 15 ~ 18 个作为检验样本,网络经过迭代次数 $k = 168$ 达到精度要求,训练时间为 0.7809 s。网络训练和预测结果信息如图 2 所示。

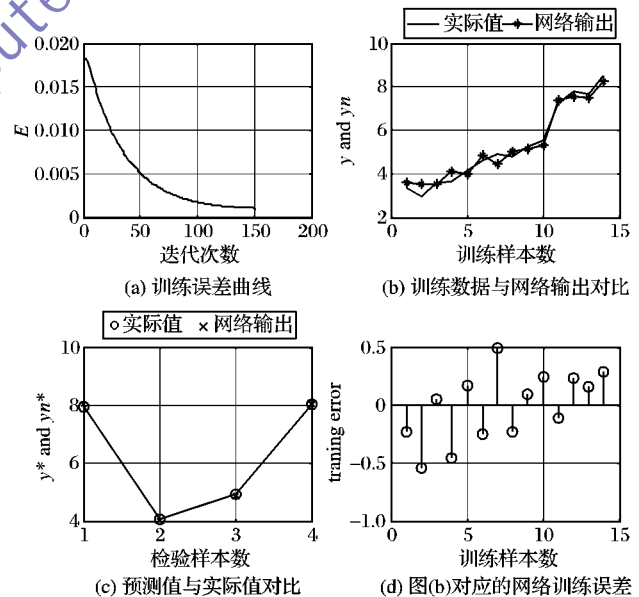


图 2 网络训练曲线和预测结果

网络训练误差:

$$\text{error1} = [-0.2120 \ -0.5325 \ 0.0588 \ -0.4620 \ 0.1695 \\ -0.2645 \ 0.4879 \ -0.2385 \ 0.0821 \ 0.2392 \\ -0.1072 \ 0.2460 \ 0.1700 \ 0.3103];$$

网络训练精度:

$$\text{ep1} = [-6.3485 \ -17.9304 \ 1.6528 \ -12.7636 \ 4.0648 \\ -5.7490 \ 9.9162 \ -4.9887 \ 1.5699 \ 4.3027 \\ -1.4813 \ 3.1536 \ 2.2134 \ 3.6460] \%$$

$$\text{elm} = \max(|\text{error1}|) = 0.5325$$

$$\text{ep1m} = \max(|\text{ep1}|) = 17.9304\%$$

由表 2 可知:

$$e2m = \max(|error2|) = 0.0457$$

$$ep2m = \max(|ep2|) = 0.8928\%$$

$$e1m/e2m = 11.6521$$

$$ep1m/ep2m = 20.0833$$

表 2 预测结果及预测精度

实际测量值	网络预测值	预测误差	预测精度 /%
7.95	7.9957	-0.0457	-0.5743
4.06	4.0275	0.0325	0.7998
4.92	4.8761	0.0439	0.8928
8.04	8.0215	0.0185	0.2300

比较训练结果和预测结果,发现预测精度比训练精度高的多(20.0833 倍),经实验表明,在神经网络预测模型中也广泛存在类似现象。通常认为网络训练精度不会低于预测精度,但从结果来看此时模糊神经网络已经将数据内在规律映射到网络之中。

如果把训练设置精度提高,如 0.00001,则训练精度可以达到很高,但预测拟合精度却很差,此时网络处于一种过拟合状态;反之,如果训练精度设置过低,如 0.1,预测效果也很差,说明网络还没有把握数据特征。经过反复实验,允许误差精度设为 0.001 时效果较好。训练误差越小,只能说明网络对训练样本具有很高的拟合能力,而不能保证网络具有很高的预测外推能力。

网络训练后参数值如下所示。

结论参数 $p(i)$ 的初始值: $p(i) = 0.1 * ones(9,1), i = 1 \sim 5$, 即网络结构为 5-9-1; 由于样本参数已归一化为 $[0,1]$ 的数值,因此可以设 $c_0 = [-2,0,2], b_0 = [2,2,2]$, 隶属度参数 c, b 的初始值根据 c_0, b_0 编程实现^[5]。经修正后的各参数值:

1) 结论参数。

$$p = [p_0 \quad p_1 \quad p_2 \quad p_3 \quad p_4 \quad p_5] =$$

0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
0.0953	0.0997	0.1009	0.1002	0.0980	0.1001
0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
0.0996	0.1000	0.1001	0.1000	0.0998	0.1000
0.0088	0.1803	0.3455	0.2475	-0.0399	0.2375
0.1053	0.1023	0.1040	0.1029	0.1000	0.1029
0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
0.1202	0.1092	0.1169	0.1122	0.0993	0.1120
0.1005	0.1002	0.1003	0.1002	0.1001	0.1002

2) 隶属度中心。

$$c = [c_1 \quad c_2 \quad c_3 \quad c_4 \quad c_5] =$$

-2.0000	-2.0000	-2.0000	-2.0000	-2.0000
-2.0009	-0.0001	-2.0009	-0.0001	-0.0001
-2.0000	2.0000	-2.0000	2.0000	2.0000
-0.0000	-2.0001	-0.0000	-2.0001	-2.0001
0.0009	0.0010	0.0009	0.0008	0.0009
-0.0002	2.0012	-0.0002	2.0012	2.0012
2.0000	-2.0000	2.0000	-2.0000	-2.0000
2.0045	-0.0006	2.0045	-0.0006	-0.0006
2.0001	2.0001	2.0001	2.0001	2.0001

3) 灵敏度参数。

$$b = [b_1 \quad b_2 \quad b_3 \quad b_4 \quad b_5] =$$

2.0000	2.0000	2.0000	2.0000	2.0000
1.9995	2.0000	1.9995	2.0000	2.0000
2.0000	2.0000	2.0000	2.0000	2.0000
2.0000	2.0000	2.0000	2.0000	2.0000
2.0001	2.0001	2.0001	2.0000	2.0001
2.0000	1.9995	2.0000	1.9995	1.9995
2.0000	2.0000	2.0000	2.0000	2.0000
1.9980	2.0000	1.9980	2.0000	2.0000
2.0000	2.0000	2.0000	2.0000	2.0000

2.3 网络泛化能力

为了评价网络的预测性能,采用泛化能力进行描述。泛化能力是指神经网络学习算法对新样本的适应能力,其目的是学习隐含在数据样本中的规律,经过训练后的网络对非训练样本也能给出合理的输出,该能力称为泛化能力。

泛化能力是评价网络预测性能的重要指标。需要指出的是,并非训练的次数越多或者设置的训练精度越高,就越能得出正确的预测结果。通常在网络的训练初期是学习数据的变化趋势,随着训练次数的增加主要记忆样本数值,因此过拟合状态时对于非训练样本的泛化能力反而变差。

此外,预测的准确性与外部输入样本数据有很大关系,如果样本数据不具有典型性和呈现一定的规律性,预测将失去意义。

泛化能力是衡量预测值与实测值差别的变量,采用平均相对变动值(Average Relative Variance, ARV)表示,ARV 等价于网络泛化能力。ARV 越小,网络的泛化能力越强,其表达式^[14]为:

$$ARV = \frac{\sum_{i=1}^N [x(i) - \hat{x}(i)]^2}{\sum_{i=1}^N [x(i) - \bar{x}(i)]^2} \quad (16)$$

其中: N 是比较数据的个数, $x(i)$ 为实测数据, $\bar{x}(i)$ 为实测数据的平均值, $\hat{x}(i)$ 为预测值。ARV 越小,泛化能力越强。上述预测时的 $ARV = 4.2658e-004$, 表明该预测模型有很强的泛化能力。

3 Matlab/GUI 界面开发

目前,可视化界面开发以 VC、VB 多见,而利用 Matlab/GUI 进行界面开发的很少。相对 VC、VB, Matlab 软件在复杂的数值分析、矩阵运算、信号及图像处理等方面具有显著优势。在瓦斯涌出量预测时需要处理大量的数据,同时利用 Matlab 编写的程序更易于嵌入 Matlab/GUI 界面,而且具有方便、快捷和灵活的特点。

为便于实际工程应用,按照上述混合 pi-sigma 模糊神经网络原理,在 Matlab/GUI 环境中开发了仿真系统界面,如图 3 所示。Matlab/GUI 界面使用 M 文件和 GUIDE 融合制作可视化 GUI 仿真预测系统界面^[15]。

该仿真界面可以全面显示网络训练、预测及网络参数等信息,使用者不需要知道代码的具体内容,只要了解操作步骤即可很方便地操作界面,界面直观友好。该系统支持三种方式导入数据: 1) *.mat 文件数据; 2) *.txt 数据; 3) *.exl 格式的数据。

操作流程: 1) 导入数据,选择训练样本和检测样本数; 2) 选择合适的网络参数; 3) 点击“网络训练”按钮,将显示训练曲线、预测结果图形; 4) 点击“预测结果”按钮会显示底部

数据,点击“Close”按钮关闭系统。

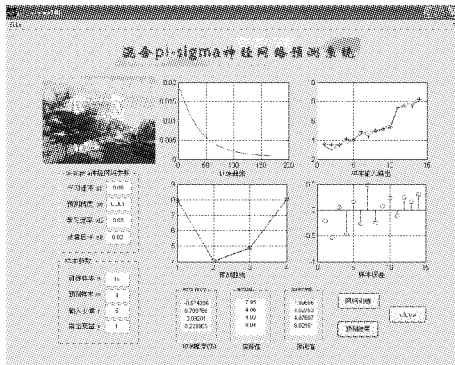


图3 混合 pi-sigma 模糊神经网络预测系统

4 结语

本文提出了一种新型瓦斯涌出量混合 pi-sigma 模糊神经网络预测模型,该模型具有物理意义清楚、原理和结构透明、网络训练速度快、预测精度高、预测结果非随机等特点,并且隶属函数和结论参数可在线调整,可充分发挥模糊逻辑和神经网络各自的优势,仿真结果证明了所建模型的有效性。笔者对常规模糊神经网络同时进行了实验比较,本文提出的方案明显优于一般模糊神经网络。通过开发 Matlab/GUI 界面,使仿真过程立体化,更接近工程实际应用,具有直观、可视化等特点,因此本文提出的预测模型具有一定的实际应用前景。

参考文献:

- [1] 唐朝伟,何国田,徐昌彪,等.神经网络在采煤工作面瓦斯涌出量预测中的应用[J].计算机应用,2007,27(12):202-204.
- [2] 王景山,宋金栋,张聪,等.矿井瓦斯涌出量预测方法综述[J].能源技术与管理,2008(4):49-51.

- [3] 朱红青,常文杰,张彬.回采工作面瓦斯涌出 BP 神经网络分源预测模型及应用[J].煤炭学报,2007,32(5):504-508.
- [4] 杨新,张陶红,余刚,等.基于 ANFIS 的选矿产品成本预测模型[J].系统仿真学报,2007,19(24):5688-5691.
- [5] 傅惠,许伦辉,胡刚,等.基于 Sugeno 型神经模糊系统的交通流状态预测算法[J].控制理论与应用,2010,27(12):1637-1640.
- [6] 杨奎河,王宝树,赵玲玲.模糊神经网络在非线性短期负荷预测中的应用[J].控制理论与应用,2004,21(5):791-794.
- [7] 王士同.神经模糊系统及其应用[M].北京:北京航空航天大学出版社,1998:210-245.
- [8] 刘金钊.智能控制[M].北京:电子工业出版社,2009:162-164.
- [9] 金耀初,蒋静坪.一种模糊神经网络及其应用[J].浙江大学学报,1995,29(3):340-347.
- [10] 修杰,夏长亮,王世宇.开关磁阻电机的 pi-sigma 模糊神经网络建模[J].电工技术学报,2009,24(8):46-51.
- [11] 彭晓波,桂卫华,李勇刚,等.动态 T-S 递归模糊神经网络及其应用[J].系统仿真学报,2009,21(18):5636-5644.
- [12] 朱川曲.采煤工作面瓦斯涌出量预测的神经网络模型[J].中国安全科学学报,1999,9(2):42-45.
- [13] 刘思峰,谢乃明.灰色系统理论及其应用[M].北京:科学出版社,2008:48-52.
- [14] CHOLEWO T, ZURADA J M. Sequential network construction for time series prediction[C]// Proceedings of the IEEE International Joint Conference on Neural Networks. Houston: IEEE, 1997: 2034-2039.
- [15] 陈亮光,毛涛涛,王正林,等.精通 Matlab GUI 设计[M].北京:电子工业出版社,2008:224-445.

(上接第 1032 页)

3 结语

本文所提出的蚁群聚类分级算法利用蚂蚁的按概率选择行为有效地防止了聚类中心陷入局部最优,并能够自动快速地实现对历史灾害的聚类分级,在聚类过程中受主观因素干扰少,并通过可反馈的灾害信息量化过程来实现历史专家的指导和监督作用,以保证分级的非盲目性,最后通过实验比较证明了该算法的优越性,具有较高的应用推广价值。

参考文献:

- [1] 防灾减灾空间信息建设亟待加强[EB/OL]. [2011-09-01]. http://news.xinhuanet.com/society/2011-05/12/c_121406775.htm.
- [2] 马细霞,李艳.基于主成分分析的农业旱灾等级区划研究[J].郑州大学学报,2011,32(1):125-128.
- [3] 张星.自然灾害灾情的熵权综合评价模型[J].自然灾害学报,2009,18(6):189-192.
- [4] 龚日朝,王爱平.基于信息融合的自然灾害等级评估方法研究[J].中国安全科学学报,2010,20(11):3-10.
- [5] 代博洋,李志强,李晓丽.基于物元理论的自然灾害损失等级划分方法[J].灾害学,2009,24(1):1-5.
- [6] 高燕,陈云翔.基于免疫遗传算法的洪灾神经网络评估模型[J].自然灾害学报,2006,15(1):110-114.
- [7] 徐海亮,陈亚宁.洪水灾害等级划分的模糊聚类分析[J].干旱区地理,2000,23(4):350-352.

- [8] ZHANG QIU-YU, YANG HUI-JUAN, WANG PENG, *et al.* Fuzzy clustering based on semantic body and its application in Chinese spam filtering[J]. JDCTA: International Journal of Digital Content Technology and its Applications, 2011, 5(4): 1-11.
- [9] 陈亚宁,杨思全.灰色聚类在洪水灾害等级划分中的应用[J].干旱区地理,1999,22(3):37-42.
- [10] WEN KUN-LI, YOU MEI-LI, LEE B-Y. Apply grey relational grade and rough set theory for the factor weighting analysis in liver function[J]. Journal of Convergence Information Technology, 2011, 6(9):420-428.
- [11] 李祚泳,汪嘉杨.基于蚁群算法的 BP 网络优化算法[J].计算机应用,2010,30(6):1513-1518.
- [12] 刘喜恩.用于连续空间寻优的一种蚁群算法[J].计算机应用,2009,29(10):2744-2747.
- [13] DORIGO M, STÜTZLE T. Ant colony optimization[M].北京:清华大学出版社,2005.
- [14] CHIANG CHUAN-WEN, HUANG YU-QING, LU GUO-QIN, *et al.* Ant-inspired search techniques for solving the zero-one knapsack problem with multiple constraints[J]. International Journal of Advancements in Computing Technology, 2011, 3(4): 242-255.
- [15] HOMBERGER J, GEHRING H. An ant colony optimization-based negotiation approach for lot-sizing in supply chains[J]. International Journal of Information Processing and Management, 2011, 2(3): 86-99.