

文章编号:0253-9993(2013)S2-0518-06

基于 ASGSO-SVR 模型的瓦斯传感器故障诊断

黄凯峰^{1,2}, 刘泽功¹, 王其军², 杨 静³, 高 魁¹

(1. 安徽理工大学 能源与安全学院, 安徽 淮南 232001; 2. 淮南职业技术学院 信电系, 安徽 淮南 232001; 3. 安徽理工大学 理学院, 安徽 淮南 232001)

摘 要:针对现行煤矿瓦斯传感器常见的卡死、冲击、漂移等故障,运用支持向量回归机建立多传感器数据融合的瓦斯浓度预测模型,详细研究影响该预测模型精度的相关参数选择方法,提出用 ASGSO 算法自适应优化支持向量机预测模型参数的算法,将模型预测结果与现场实测瓦斯浓度相比较得到残差 δ ,用于对瓦斯传感器故障的诊断。用现场监控数据对该方法进行离线仿真实验,得到残差信号的变化曲线。通过选择合理的阈值,判断传感器是否处于故障状态。结果表明,ASGSO 算法参数优化对提高 SVR 预测模型的精度有很大帮助,此方法对瓦斯传感器的常见故障的诊断是正确和有效的。

关键词:瓦斯传感器;故障诊断;ASGSO 算法;支持向量回归

中图分类号:TP212;TD67 **文献标志码:**A

Gas sensor fault diagnosis based on ASGSO-SVR

HUANG Kai-feng^{1,2}, LIU Ze-gong¹, WANG Qi-jun², YANG Jing³, GAO Kui¹

(1. School of Energy and Safety, Anhui University of Science and Technology, Huainan 232001, China; 2. Information and Electrical Engineering Department, Huainan Vocational and Technical College, Huainan 232001, China; 3. School of Science, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: For the common faults in the current coal mine gas sensor such as jamming, impact or drift, the gas concentration prediction model of multi-sensor data fusion was used, which was established by the support vector regression machine. Meanwhile, the related parameter selection method which influences the prediction model accuracy was worked up in detail and then the arithmetic was proposed to adaptively optimize the forecasting model parameters of the support vector machine through the Self-Adaptive Step Glowworm Swarm Optimization algorithm compared between the results of model prediction and the field measured gas concentration, the residual δ for gas sensor fault diagnosis was got. Upon the field monitoring data got through this method, the simulation experiment in Matlab was done to get residual signal change curve. Fault diagnosis was implemented by fault threshold selection. The results indicate that the parameter optimization by the AGSO algorithm is helpful to improve the support vector machine regression prediction model precision and it is correct and effective for this method to the common gas sensor fault diagnosis.

Key words: gas sensor; diagnosis; ASGSO algorithm; support vector regression machine

煤矿瓦斯监测系统和设备中瓦斯传感器是最关键的传感设备,监测系统通过它完成对矿井现场瓦斯浓度的检测,瓦斯传感器输出信号正确与否直接关系到瓦斯监测系统的性能好坏和煤矿生产安全^[1-3]。瓦斯传感器长期处于高温、高湿度、高粉尘、强干扰的

恶劣环境中,经常发生卡死、冲击、漂移等故障。可以说,瓦斯传感器是煤矿瓦斯监测系统中故障率较高的设备,对瓦斯传感器进行故障诊断具有重要意义。

目前,煤矿瓦斯传感器故障诊断的方法主要有多元回归分析、时间序列分析、神经网络逼近等,其中基

于学习的多传感器融合智能诊断方法是主要的发展方向之一^[4-8],但神经网络等学习算法对在小样本学习训练上有局限性。本文采用支持向量回归机能较好地解决神经网络的过拟合问题,具有全局惟一最优解、泛化能力强等优点,但支持向量回归机的性能对主要参数选择的依赖性高。自适应步长萤火虫算法(ASGSO)通过引入萤光因子自适应调整步长的大小,较之普通萤火虫算法更好的处理全局寻优能力和寻优精度之间的关系,使其具备强大的多目标参数搜索与优化能力,来解决支持向量机的参数选择问题,从而得到很好的逼近效果,提高预测与诊断的准确率。

1 常见瓦斯传感器布局

生产工作面瓦斯传感器布置如图1所示: T_0 瓦斯传感器布置在上隅角; T_1, T_2 瓦斯传感器布置在回风巷; T_3, T_4 瓦斯传感器布置在进风巷,同时还有实时监测风速、温度、CO 浓度等传感器。




图1 瓦斯传感器布局

Fig.1 Set-up diagram about gas sensor of the coal face

T_1 瓦斯传感器的浓度与周围环境中的风速、风量、温度、CO 浓度等条件有关,同时与 T_0, T_2 瓦斯传感器的浓度有很大的相关性,可以说 T_1 瓦斯传感器的浓度是由瓦斯浓度、风速、风量、温度值和 CO 浓度等相关因素相互耦合、共同作用下决定的, T_1 瓦斯传感器的监控数据与通过对这些相关因素的历史数据的数据融合结果相符。但是由于 T_1 瓦斯浓度与这些影响参数之间是非线性关系,这些相关因素参数都可由现行瓦斯监测系统中对应传感器得到,所以可利用高精度的支持向量回归机进行数据融合,实现对 T_1 瓦斯浓度的高精度逼近与预测。

2 基于 AGSO-SVR 的瓦斯浓度预测模型的故障诊断实现

2.1 支持向量回归机(Support Vector Regression, SVR)的原理^[9-11]

支持向量回归机(Support Vector

Regression, SVR)的基本思想是:用线性回归方程 $f(x) = \omega^T \Phi(x) + b$,拟合非线性空间 $(x_i, y_i), (i = 1, 2, \dots, n)$;函数 $\Phi(\cdot)$ 使得损失函数最少。而求得回归方程参数 ω 和 b 的过程就是利用 SRM 原则进行损失函数风险最小化的过程:

$$\min_{\omega, b, \xi, \xi^*} \frac{1}{2} \omega^T \omega + c \sum_{i=1}^l \xi_i + c \sum_{i=1}^l \xi_i^* \quad (1)$$

最小化约束条件为

$$\begin{cases} \omega^T \Phi(x_i) + b - Z_i \leq \epsilon + \xi_i \\ Z_i - \omega^T \Phi(x_i) - b \leq \epsilon + \xi_i^* \end{cases} \quad (2)$$

其中, $\xi_i, \xi_i^* \geq 0; i = 1, \dots, l$ 。

决策函数为

$$Z_i = \sum_{i=1}^n (a_i - a_i^*) K(x_i, x) + b \quad (3)$$

其中,常数 $c > 0$,为惩罚系数,表示对离群点带来的损失 $\epsilon > 0$ 的重视程度, c 越大,对目标函数的损失也越大; ξ_i, ξ_i^* 为松弛变量,它的值标示出了对应点离群的远近程度;不敏感损失系数 ϵ 值是回归允许的最大误差,其值影响支持向量的个数。 ϵ 越大,支持向量数越少,但函数估计精度越低,复杂度也就越低; ϵ 越小,支持向量数越多,回归精度越高,但可能导致模型过于复杂,得不到好的推广能力,本文仿真实验采用默认值 $\epsilon = 0.1$ 。

煤矿瓦斯浓度正常情况下变化缓慢,但要求报警点和断电点的瓦斯浓度输出必须真实可靠,以便及时发现传感器的故障信息,提高预测模型的准确性,所以应该选择 RBF 核函数。

$$K(x_i, x) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (4)$$

支持向量回归机的性能及效果对惩罚参数 c 与核函数参数 $g = \frac{1}{2\sigma^2}$ 的依赖程度很高,如选择不当会大大影响精度,参数的选取对于经验的依赖性比较强,到现在为止,还没有一个指导 SVR 参数选择的最佳理论。

2.2 基于自适应步长萤火虫算法(ASGSO)的参数寻优

2.2.1 自适应步长萤火虫算法

萤火虫优化(Glowworm Swarm Optimization, GSO)主要是模拟萤火虫发光趋光特性现象,通过各个萤火虫作为参数寻优的个体,通过向最亮的萤火虫移动来实现寻优的目的。但基本 GSO 算法存在易于陷入局部最优,后期收敛较慢且求解精度不高的问题。这些问题于搜索步长有关,步长大,易于搜索全局最优,但同时搜索精度降低了,甚至震荡现象;步长

小,搜索速度降低,搜索精度提高。针对这个问题,可以引入萤光因子:

$$H_i = \frac{\|X_i - X_{\text{ext}}\|}{d_{\text{max}}} \quad (5)$$

自适应调整步长的大小,处理好全局寻优能力和寻优精度之间的关系。其中 X_i 为第 i 只萤火虫个体的状态; X_{ext} 为此时萤光素浓度最大的萤火虫个体的状态; d_{max} 为最优萤火虫距其余所有萤火虫的距离的最大值。基于萤光因子的自适应调整步长策略:

$$s_i = s_{\text{min}} + (s_{\text{max}} - s_{\text{min}})H_i \quad (6)$$

式中, s_{max} 和 s_{min} 分别为步长的最大值和最小值。

根据式(5),(6)每次迭代的步长来动态调整本次迭代的步长,定义 s_{max} 和 s_{min} ,可以避免萤火虫分散过大导致步长太小等问题。自适应步长的萤火虫算法(ASGSO)在大范围内可以更快搜索全局最优的邻域;而在最优邻域附近的个体具有较小的步长,算法逐步演化为局部搜索进行精确搜索,可以更精确地搜索极值。

2.2.2 算法描述

基于自适应步长的萤火虫寻优算法的流程可以描述如下。

Step1 初始化。支持向量机参数惩罚参数 c 与核函数参数 g 作为寻优目标 $x_i(t)$ 。随机生成 n 个萤火虫,搜索空间维数 m ,初始化荧光素大小 l_0 和感知范围 r_0 ,萤火虫感知最大半径 r_s ,最大迭代次数 iter_{max} ,初始步长 $s_i(0)$,最大步长 s_{max} ,最小步长 s_{min} ,随机产生萤火虫初始位置 $x_i(0)$,萤光素挥发系数 p ,萤光素更新率 γ 。

Step2 萤光素更新。调用支持向量机算法得到萤光素 $x_i(t)$ 对应的目标函数值 $J(x_i(t))$,根据更新公式 $l_i(t) = (1-p)l_i(t-1) + \gamma J(x_i(t))$ 把萤火虫 i 在第 t 次迭代的位置,通过转化为荧光素值 $l_i(t)$,每只萤火虫在其动态决策域半径 $r_d^i(t)$ 内,选择荧光素值比自己高的个体组成其邻域集 $N_i(t)$,其中 $0 < r_d^i(t) \leq r_s$, r_s 为萤火虫个体的感知半径。

Step3 概率选择。利用概率选择公式 $p_{ij}(t) = \frac{l_j(t) - l_i(t)}{\sum_{k \in N_i(t)} l_k(t) - l_i(t)}$ 计算萤火虫 i 移向邻域集内个体 j 的概率 $p_{ij}(t)$ 。

Step4 动态自适应步长调整。利用萤光因子式(5)计算每个萤火虫个体的萤光因子,用自适应调整步长策略式(6)计算移动步长。

Step5 位置更新。根据位置更新公式 $x_i(t+1) = x_i(t) + s \left(\frac{x_j(t) - x_i(t)}{\|x_j(t) - x_i(t)\|} \right)$,进行移动。

Step6 动态决策域半径更新。根据公式 $r_d^i(t+1) = \min\{r_s, \max\{0, r_d^i(t) + \beta(n_i - |N_i(t)|)\}\}$ 更新动态决策域半径的值。

Step7 迭代结束。判断算法是否到达指定的最大迭代次数,如果是输出结果,否则跳回 Step2。

3 基于 ASGSO-SVR 的瓦斯浓度预测模型的仿真实验

以淮南矿业集团张集煤矿瓦斯监控系统数据为例,系统正常工作状态下,由系统分别连续风速、风量、温度、CO 及 T_0, T_1, T_2 的瓦斯浓度进行采样,得到以下样本向量:

CO 浓度(%): $\mathbf{X}_3 = [X_3(0), X_3(1), \dots, X_3(k-1), X_3(k)]$;

T_0 浓度(%): $\mathbf{X}_4 = [X_4(0), X_4(1), \dots, X_4(k-1), X_4(k)]$;

T_2 浓度(%): $\mathbf{X}_5 = [X_5(0), X_5(1), \dots, X_5(k-1), X_5(k)]$;

T_1 浓度(%): $\mathbf{Y} = [Y(0), Y(1), \dots, Y(k-1), Y(k)]$;

从而,组成样本空间: $(\mathbf{X}_i, \mathbf{Y}) = [\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3, \mathbf{X}_4, \mathbf{X}_5, \mathbf{Y}] (i=1, 2, 3, 4, 5)$ 。

如取监控系统历史采样数据 36 次,前 20 组数据作为仿真实验的训练集见表 1,用于建立 ASGSO 算法参数寻优支持向量回归模型,得到瓦斯浓度预测模型。后 16 组数据作为仿真实验的测试集见表 2,用于对所建立的瓦斯浓度预测模型测试。

将上述样本数据构成空间矩阵 $(\mathbf{X}_i, \mathbf{Y})$ 通过 ASGSO 算法寻优,使用 Matlab 仿真软件,得到自适应寻优结果:惩罚参数 $c=2.4$,核函数参数 $g=4.7$ 。从而构造瓦斯浓度预测模型。

输入训练集数据得到训练集预测的回归逼近效果如图 2 所示,输入测试集进行预测的效果如图 3 所示。分别检验进行优化的 SVM 和 ASGSO-SVR 算法的均方根误差(MSE),平方相关系数(r^2)比较效果见表 3。结果表明 ASGSO-SVR 预测模型较之未进行优化的 SVM 算法对瓦斯浓度有更强大的逼近能力,其效果比较如图 4 所示。

$$r^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

$$M_{SE} = \frac{1}{n} \sum_{i=0}^n (y_i - \hat{y})^2 \quad (8)$$

表1 训练集样本数据

Table 1 Data of training set

序号	风速/ ($m \cdot s^{-1}$)	温度/ ℃	T ₀ 瓦斯 浓度/%	T ₂ 瓦斯 浓度/%	CO 浓 度/%	T ₁ 瓦斯 浓度/%
1	1.31	24.2	0.81	0.58	0.04	0.65
2	1.31	24.1	0.82	0.56	0.05	0.66
3	1.32	24.4	0.79	0.55	0.05	0.64
4	1.30	24.4	0.80	0.59	0.04	0.63
5	1.32	24.1	0.84	0.61	0.06	0.67
6	1.31	24.4	0.81	0.63	0.06	0.62
7	1.35	24.2	0.76	0.61	0.04	0.59
8	1.37	24.1	0.81	0.66	0.03	0.72
9	1.25	24.5	0.79	0.67	0.05	0.66
10	1.34	24.6	0.78	0.58	0.09	0.65
11	1.31	24.5	0.76	0.58	0.04	0.66
12	1.32	24.7	0.78	0.55	0.05	0.66
13	1.32	24.4	0.75	0.57	0.05	0.67
14	1.20	24.7	0.71	0.52	0.06	0.53
15	1.12	24.7	0.67	0.46	0.05	0.45
16	1.14	25.3	0.63	0.42	0.06	0.46
17	1.20	25.3	0.58	0.35	0.05	0.54
18	1.36	24.6	0.61	0.47	0.07	0.71
19	1.10	24.7	0.58	0.53	0.04	0.46
20	1.25	24.7	0.56	0.54	0.04	0.54

表2 测试集样本数据

Table 2 Data of test set

序号	风速/ ($m \cdot s^{-1}$)	温度/ ℃	T ₀ 瓦斯 浓度/%	T ₂ 瓦斯 浓度/%	CO 浓 度/%	T ₁ 瓦斯 浓度/%
1	1.17	24.8	0.57	0.52	0.03	0.48
2	1.38	24.7	0.71	0.54	0.05	0.73
3	1.35	24.7	0.78	0.57	0.06	0.72
4	1.27	24.4	0.83	0.63	0.06	0.74
5	1.22	24.5	0.79	0.62	0.07	0.52
6	1.33	24.7	0.73	0.60	0.09	0.64
7	1.35	24.7	0.74	0.64	0.04	0.65
8	1.23	25.4	0.67	0.57	0.05	0.55
9	1.34	25.3	0.61	0.51	0.04	0.68
10	1.24	25.7	0.67	0.43	0.06	0.58
11	1.20	25.7	0.60	0.43	0.05	0.54
12	1.22	25.5	0.65	0.37	0.05	0.52
13	1.14	25.6	0.65	0.34	0.03	0.53
14	1.23	25.8	0.67	0.36	0.04	0.54
15	1.30	25.6	0.72	0.41	0.06	0.63
16	1.30	25.7	0.71	0.45	0.07	0.65




图2 ASGSO-SVR 训练集回归效果

Fig. 2 Train set regression predict by ASGSO-SVR




图3 ASGSO-SVR 测试集预测的效果

Fig. 3 Test set regression predict by ASGSO-SVR




图4 ASGSO-SVR 与 SVR 逼近效果比较

Fig. 4 Compared curves between ASGSO-SVR and SVR

表3 ASGSO 算法参数寻优结果

Table 3 Parameter optimization of ASGSO

选择 算法	惩罚参 数 c	核函数参 数 g	均方根误 差 (MSE)	平方相关 系数 (r^2)
SVM	3.0	0.1	0.089 3	0.89
ASGSO-SVM	2.4	4.7	0.035 0	0.94

所示,将监控历史数据组成样本进行归一化,输入支持向量回归机训练,同时对惩罚参数 c 与核函数参数 g 进行如图 2 所示的步骤参数自适应寻优,得到 ASGSO-SVR 瓦斯浓度预测模型,代入预测数据反归一化,得到回归逼近值 \hat{Y} ,并将 \hat{Y} 与当前时刻系统的实际输出 Y 相比较,得到残差 δ 。残差输出 δ 若大于预定阈值(0.8),则认为 T₁ 瓦斯传感器处于故障状态;残差输出 δ 若小于预定阈值(0.8),则认为 T₁ 瓦斯传感器处于正常工作状态。

在一定时间内 T₁ 瓦斯传感器处正常工作状态时, \hat{Y} 与当前时刻系统的实际输出 Y 相比较,得到残差 δ 基本服从于均值为 0 的正态分布,如图 6 所示。

如果在某时刻开始 T₁ 瓦斯传感器出现卡死故障, \hat{Y} 与当前时刻系统的实际输出 Y 相比较,得到残

4 基于 ASGSO-SVR 的瓦斯浓度预测模型的故障诊断实现

ASGSO-SVR 瓦斯传感器故障诊断模型如图 5

差 δ 超过阈值,如图 7 所示。




图 5 ASGSO-SVR 瓦斯传感器故障诊断模型

Fig. 5 Gas sensor fault diagnosis based on ASGSO-SVR




图 6 正常工作残差信号的变化曲线

Fig. 6 The residual signal change curve of the normal work




图 7 卡死故障状态残差信号的变化曲线

Fig. 7 The residual signal change curve of the jamming fault

如 T_1 瓦斯传感器处在某时刻出现冲击故障, \hat{Y} 与当前时刻系统的实际输出 Y 相比较,得到残差 δ ,如图 8 所示。




图 8 冲击故障状态残差信号的变化曲线

Fig. 8 The residual signal change curve of the impact fault

如 T_1 瓦斯传感器处在某时刻开始出现漂移故障, \hat{Y} 与当前时刻系统的实际输出 Y 相比较,得到残差 δ ,如图 9 所示。

T_1 瓦斯传感器出现上述故障时,由于 Y 值变为故障信号,导致 \hat{Y} 与当前时刻系统的实际输出 Y 相比较,得到残差 δ 大于预定阈值(0.8),则认为 T_1 瓦斯传感器处于故障状态;诊断系统立刻进行报警。




图 9 漂移故障状态残差信号的变化曲线

Fig. 9 The residual signal change curve of the drift fault

5 结 论

(1) 本文运用支持向量回归机算法相对于其他算法可以很好地解决瓦斯传感器故障这一小样本学习训练的问题,对瓦斯浓度的非线性的变化有很强的逼近能力。

(2) 通过仿真实验证明,ASGSO 算法为 SVR 的参数选取开辟了新的思路,可以有效提高支持向量回归的精度,避免人为选择参数的盲目性。

(3) 通过仿真诊断实验,得出基于 ASGSO-SVR 瓦斯传感器故障诊断方法对瓦斯传感器出现的日常故障诊断正确率较高。

(4) 瓦斯传感器 T_0, T_2, T_3, T_4 的测量值也都与风速、风量、温度、CO 浓度,以及其他瓦斯传感器测得的瓦斯浓度有关联,对于除 T_1 以外的其他瓦斯传感器的故障诊断也适用于此方法。

参考文献:

[1] 王军号,孟祥瑞,吴宏伟. 基于小波包与 EKF-RBF 神经网络辨识的瓦斯传感器故障诊断[J]. 煤炭学报,2011,35(5):868-872.
Wang Junhao, Meng Xiangrui, Wu Hongwei. Gas sensor fault diagnosis based on wavelet packet and EKF-RBF neural network identification [J]. Journal of China Coal Society 2011, 35(5):868-872.

[2] 王其军. 瓦斯监测系统故障智能诊断技术研究[D]. 青岛: 山东科技大学,2007:32-53.
Wang Qijun. Research on intelligent fault diagnosis of gas-monitoring system[D]. Qingdao: Shandong University of Science and Technology, 2007:32-53.

[3] 王其军,程久龙. 基于免疫神经网络模型的瓦斯浓度智能预测[J]. 煤炭学报,2008,33(6):665-669.
Wang Qijun, Cheng Jiulong. Forecast of coal mine gas concentration based on the immune neural network model [J]. Journal of China Coal Society, 2008, 33(6):665-669.

[4] 王 凯,俞启香. 煤与瓦斯突出的非线性特征及预测模型[M]. 徐州:中国矿业大学出版社,2005.
Wang Kai, Yu Qixiang. Nonlinear characteristics and prediction model of gas outburst [M]. Xuzhou: China University of Mining and Technology Press, 2005.

[5] 陈海洋,滕彦国,王金生. 基于 GA-SVR 的渗透系数参数反演方

- 法[J]. 水文地质工程地质, 2011, 38(2):14-17.
- Chen Haiyang, Teng Yanguo, Wang Jinsheng. Methods of estimation of hydraulic conductivity with genetic algorithm-support vector regression machine[J]. Hydrogeology and Engineering Geology, 2011, 38(2):14-17.
- [6] 赵洪波, 冯夏庭. 位移反分析的进化支持向量机研究[J]. 岩石力学与工程学报, 2003, 22(10):1618-1622.
- Zhao Hongbo, Feng Xiating. Study on genetic-support vector machine in displacement back analysis[J]. Chinese Journal of Rock Mechanics and Engineering, 2003, 22(10):1618-1622.
- [7] Patra J C, Van Denbos A. Modeling of an intelligent pressure sensor using functional link artificial neural networks[J]. ISA Transactions, 2000, 39(1):15-27.
- [8] Tsai Nanchyuan, Sue Chungyang. Review of MEMS-based drug delivery and dosing systems[J]. Sensors and Actuators A, 2007, 134:555-564.
- [9] Vapnik W N. 统计学习理论的本质[M]. 张学工, 译. 北京: 清华大学出版社, 2000.
- Vapnik W N. The nature of statistical learning theory[M]. Zhang Xuegong, trans. Beijing: Tsinghua University Press, 2000.
- [10] Doll Alexander F, Wischke Martin, Geipel Andreas, et al. A novel artificial sphincter prosthesis driven by a four-membrane silicon micropump[J]. Sensors and Actuators A, 2007, 139:208-209.
- [11] 陈 果. 基于遗传算法的支持向量机时间序列预测模型优化[J]. 仪器仪表学报, 2006, 27(9):1180-1184.
- Chen Guo. Optimizing of support vector machine time series forecasting model parameters based on genetic algorithms[J]. Chinese Journal of Scientific Instrument, 2006, 27(9):1180-1184.
- [12] Goldberg D. Genetic algorithms in search, optimization and machine learning[M]. Addison-Wesley, Reading, MA, 1989.
- [13] 周公博, 朱真才, 陈光柱. 基于传感器网络的瓦斯传感器故障诊断[J]. 振动、测试与诊断, 2010, 30(1):23-27.
- Zhou Gongbo, Zhu Zhencai, Chen Guangzhu. Fault diagnosis of gas sensor based on wireless sensor network[J]. Journal of Vibration Measurement and Diagnosis, 2010, 30(1):23-27.
- [14] 吴景龙, 杨淑霞, 刘承水. 基于遗传算法优化参数的支持向量机短期负荷预测方法[J]. 中南大学学报(自然科学版), 2009, 40(1):181-184.
- Wu Jinglong, Yang Shuxia, Liu Chengshui. Parameter selection for support vectormachines based on genetic algorithms to short-term power load forecasting[J]. Journal of Central South University(Science and Technology), 2009, 40(1):181-184.
- [15] Zhang Chunsun, Xing Da, Li Yuyuan. Micropumps, micrvalves and micromixers within PCR micro fluidic chips; Advances and trends[J]. Biotechnology Advances, 2007, 25:483-514.
- [16] 曹庆奎, 任向阳, 刘开第. 矿井工作面瓦斯涌出量的未确知聚类研究[J]. 煤炭学报, 2006, 31(3):337-341.
- Cao Qingkui, Ren Xiangyang, Liu Kaidi. Research on unascertained clusters on the gas emission of the working face[J]. Journal of China Coal Society, 2006, 31(3):337-341.
- [17] 吕 品, 马云歌, 周心权. 上隅角瓦斯浓度动态预测模型的研究及应用[J]. 煤炭学报, 2006, 31(4):461-465.
- Lü Pin, Ma Yunge, Zhou Xinquan. Research and application on dynamic forecasting model of gas consistence in top corner[J]. Journal of China Coal Society, 2006, 31(4):461-465.
- [18] 付 华, 杨 欣, 高 婷. 基于 SVR 的瓦斯传感器故障诊断方法[J]. 传感器与微系统, 2009, 28(2):10-12.
- Fu Hua, Yang Xin, Gao Ting. Method of gas sensor fault detection based on SVR[J]. Transducer and Microsystems Technologies, 2009, 28(2):10-12.
- [19] 邵良杉, 付贵祥. 基于数据融合理论的煤矿瓦斯动态预测技术[J]. 煤炭学报, 2008, 33(5):551-555.
- Shao Liangshan, Fu Guixiang. Dynamic prediction technology for gas based on data fusion theory[J]. Journal of China Coal Society, 2008, 33(5):551-555.
- [20] 孙 林, 杨世元. 基于 LS-SVM 的回采工作面瓦斯涌出量预测[J]. 煤炭学报, 2008, 33(12):1376-1380.
- Sun Lin, Yang Shiyuan. Prediction for gas emission quantity of the working face based on LS-SVM[J]. Journal of China Coal Society, 2008, 33(12):1376-1380.