

文章编号:1001-9081(2009)12-3259-04

热导传感器温度特性的 CPSO-SVM 数据融合校正

黄为勇^{1,2}, 童敏明², 任子晖²

(1. 徐州工程学院 信电工程学院, 江苏 徐州 221008; 2. 中国矿业大学 信息与电气工程学院, 江苏 徐州 221008)

(hwy@xzit.edu.cn)

摘要:为了消除环境温度对热导气体传感器的影响,提出了一种热导传感器温度特性的经典粒子群优化——支持向量机(CPSO-SVM)数据融合校正方法。该方法将热导传感器和温度传感器构成传感器组,利用支持向量机对传感器组的输出信号进行数据融合,采用经典粒子群优化算法和测试样本集均方根误差与平均绝对百分比误差同时最小原则选择和优化支持向量机的参数向量。对氢气浓度的检测实验表明,该方法能有效地改善传感器的温度特性,实现了气体浓度的精确检测。

关键词:热导传感器;温度特性校正;支持向量机;数据融合;经典粒子群优化

中图分类号: TP181; TP212 **文献标志码:** A

Using CPSO-SVM and data fusion to calibrate temperature characteristic of thermal sensor

HUANG Wei-yong^{1,2}, TONG Min-ming², REN Zi-hui²

(1. School of Information and Electrical Engineering, Xuzhou Institute of Technology, Xuzhou Jiangsu 221008, China;

2. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou Jiangsu 221008, China)

Abstract: To eliminate the influence of ambient temperature on thermal sensor in gas detection, the authors put forward a new calibration method for sensor temperature characteristic based on data fusion and Canonical Particle Swarm Optimization-Support Vector Machine (CPSO-SVM). The method adopted SVM to fuse the data of sensor pair composed of a thermal sensor and a temperature sensor, and applied CPSO and the principle of Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE) minimization of test samples set to tune the parameter vector of SVM. The experimental results of H₂ detection show that the proposed method can effectively improve the temperature quality of thermal sensor, and realizes accurate detection of gas concentration.

Key words: thermal sensor; temperature characteristic calibration; Support Vector Machine (SVM); data fusion; Canonical Particle Swarm Optimization (CPSO)

0 引言

热导传感器是根据不同浓度气体具有不同的导热系数这一物理特性实现气体浓度的检测,具有许多其他气体传感器所不具备的优良特性,在煤炭、化工、电力等领域得到了广泛应用。理论与实验研究表明^[1],环境温度的变化会对传感器的输出产生较大的影响,同一浓度气体的导热系数也随温度的变化而变化,加之传感器的电阻也具有温度特性,从而使得传感器的输出受环境温度影响的非线性程度进一步加剧,影响了气体浓度检测精度的提高。

过去人们通常采用硬件和数值分析两种方法对传感器温度特性进行校正^[2-4],但硬件校正存在校正电路硬件漂移问题,且无法做到全局补偿;最常用的数值分析方法——最小二乘法是一种基于梯度变化量的局部搜索技术,容易进入局部最优,难以得到最优解;另一种数值分析方法——多段折线逼近法的精度较低,通用性差,不适合多变量处理的场合。近年来一些学者提出了基于神经网络的传感器温度特性校正方法^[3-6],但该方法是一种建立在大数定理的渐近理论基础之

上的机器学习方法,采用经验风险最小化(Empirical Risk Minimization, ERM)准则,用十分复杂的模型去拟合有限的样本,存在过拟合和泛化能力差的问题。

支持向量机^[7](Support Vector Machine, SVM)是一种建立在 VC 维理论和结构风险最小化(Structural Risk Minimization, SRM)原则基础上的新型机器学习方法,在最小化经验风险的同时,最小化置信区间的上界,从而获得更强的泛化能力,有效地克服了神经网络的过学习、局部极小值和泛化能力差的缺陷,尤其适合小样本的学习。因此,采用基于结构风险最小化准则的支持向量机进行热导传感器的温度特性校正更具优越性和合理性。

虽然支持向量机用于回归估计只需求解一个凸二次规划问题,但支持向量机各参数之间存在一个最佳匹配,不恰当的参数设置甚至会恶化其回归与泛化性能,支持向量机参数的选择和优化一直是支持向量机应用和理论研究中的一个重要课题^[8]。目前主要采用网格搜索法、单纯形法、梯度下降法和遗传算法(Genetic Algorithm, GA)等方法确定支持向量机的参数向量。网格搜索法要完成一个完全的网格搜索需要巨

收稿日期:2009-06-10;修回日期:2009-08-24。 基金项目:国家 863 计划项目(2006AA06Z119);国家自然科学基金资助项目(50534050);江苏省高校自然科学基金计划项目(06KJD460174)。

作者简介:黄为勇(1963-),男,江苏江都人,副教授,博士研究生,CCF 会员,主要研究方向:计算机测控、传感器、智能信息处理;童敏明(1956-),男,浙江龙游人,教授,博士生导师,主要研究方向:传感器检测;任子晖(1962-),男,天津人,教授,博士生导师,主要研究方向:计算机测控。

大的时间代价,且寻优精度不高。单纯形法受初值及步长的影响较大,易陷入局部最优,造成寻优失败,且随函数维数的增加优化效果明显下降,而梯度下降法同样存在类似的缺点^[9-10]。GA 作为一种基于自然选择和遗传进化的随机搜索方法,克服了对初值的依赖,但存在早熟和解决实数编码问题时效果差的缺点^[11]。

鉴于粒子群优化已被证明是解决许多全局优化问题的有效方法^[12],本文应用经典粒子群算法(Canonical Particle Swarm Optimization, CPSO)选择和优化支持向量机参数向量,在此基础上构建热导传感器温度特性的支持向量机非线性校正模型,氢气浓度的检测实验结果验证了该方法的可行性和有效性。

1 原理与算法

1.1 热导传感器温度特性的数据融合校正原理

传感器数据融合可以通过一定的技术融合手段,协调不同传感器同时提供的冗余数据和互补数据,把不同传感器的局部不完整数据和相关数据加以综合和互补,降低其不确定性,挖掘多个传感器所决定的多维空间所蕴涵的系统信息,获得对被研究对象的一致性认识。因此本文采用温度传感器测量环境温度的变化,把热导传感器和温度传感器构成的传感器组的输出信号进行数据融合实现被测气体浓度的精确检测,其校正原理如图 1 所示。




图 1 热导气体传感器温度特性校正原理框图

由于被测气体浓度和环境温度对热导传感器的输出都有影响,故检测系统的方程可表示为:

$$\begin{cases} y_1(t) = f_1(x_1(t), x_2(t)) \\ y_2(t) = f_2(x_2(t)) \end{cases} \quad (1)$$

其中: $x_1(t)$, $x_2(t)$ 为被测气体浓度和环境温度; $(x_1(t), x_2(t))$ 构成传感器组的输入向量; $y_1(t)$, $y_2(t)$ 为热导传感器和温度传感器的输出; $(y_1(t), y_2(t))$ 构成传感器组的输出向量; $f_1(\cdot)$, $f_2(\cdot)$ 分别为热导传感器及与温度传感器的输入输出函数关系,二者皆为非线性函数。

式(1)的向量形式可写为:

$$\mathbf{Y}(t) = \mathbf{F}(\mathbf{X}(t)) \quad (2)$$

根据逆映射定理,式(2)所示的检测系统的逆函数可表示为:

$$\mathbf{X}(t) = \mathbf{G}(\mathbf{Y}(t)) \quad (3)$$

其中: $\mathbf{X}(t) = [x_1(t), x_2(t)]^T$, $\mathbf{Y}(t) = [y_1(t), y_2(t)]^T$, $\mathbf{G} = [g_1, g_2]^T$ 为函数向量, g_i 为 f_i 的逆映射($i = 1, 2$)。

由式(3)可以看出,只要采取合适的数学处理方法,对由热导传感器和温度传感器所组成的传感器组的输出信号 $y_1(t)$ 和 $y_2(t)$ 进行融合,即可挖掘出传感器组所决定的二维空间所蕴涵的系统信息,得到 $x_1(t)$ 的估计值 $\hat{x}_1(t)$ (即被测气体浓度的估计值)。

1.2 支持向量机回归原理

用支持向量机算法估计回归函数时,其基本思想是通过一个非线性映射 Φ ,把输入空间的数据 \mathbf{x} 映射到一个高维特

征空间中去,然后在这一高维空间做线性回归^[7]。

给定一数据集 $G\{(\mathbf{x}_i, y_i)\}_{i=1}^n$,其中 \mathbf{x}_i 为输入向量, y_i 是期望值, n 是数据点的总数。SVM 采用下式来估计函数:

$$f(\mathbf{x}) = \omega \cdot \Phi(\mathbf{x}) + b \quad (4)$$

其中 $\Phi(\mathbf{x})$ 是从输入空间到高维特征空间的非线性映射。系数 ω 和 b 通过最小化下式来估计:

$$R_{\text{reg}} = C \frac{1}{n} \sum_{i=1}^n L_{\varepsilon}(y_i, f(\mathbf{x}_i)) + \frac{1}{2} \|\omega\|^2 \quad (5)$$

其中 $C \frac{1}{n} \sum_{i=1}^n L_{\varepsilon}(y_i, f(\mathbf{x}_i))$ 是经验风险。

L_{ε} 为损失函数,本文采用 ε 不敏感损失函数,其表达式为:

$$L_{\varepsilon}(y, f(\mathbf{x})) = \begin{cases} |y - f(\mathbf{x})| - \varepsilon, & |y - f(\mathbf{x})| \geq \varepsilon \\ 0, & \text{其他} \end{cases}$$

$(1/2) \|\omega\|^2$ 是正则化部分,使函数更为平坦,以提高估计函数的泛化能力, C 是惩罚参数,它决定着经验风险与正则化部分之间的平衡。

为寻找系数 ω 和 b ,引入松弛变量 ξ_i 和 ξ_i^* ,从而得:

$$\begin{aligned} \min & \left\{ \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \right\} \\ \text{s. t. } & \omega \cdot \Phi(\mathbf{x}_i) + b - y_i \leq \varepsilon + \xi_i^* \\ & -\omega \cdot \Phi(\mathbf{x}_i) - b + y_i \leq \varepsilon + \xi_i \\ & \xi_i, \xi_i^* \geq 0 \\ & i = 1, \dots, n \end{aligned} \quad (6)$$

由对偶理论,式(6)可转化成二次规划问题,通过建立拉格朗日方程,并令 $K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$,可以得到优化问题的对偶式:

$$\begin{aligned} \min & \left\{ \frac{1}{2} \sum_{i,j=1}^n (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(\mathbf{x}_i, \mathbf{x}_j) - \sum_{i=1}^n \alpha_i^* (y_i - \varepsilon) - \alpha_i (y_i + \varepsilon) \right\} \\ \text{s. t. } & \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ & \alpha_i, \alpha_i^* \in [0, C] \end{aligned} \quad (7)$$

根据 Karush-Kuhn-Tucker 定理,最终可得回归函数的表达式为:

$$\begin{aligned} f(\mathbf{x}) &= \omega \cdot \Phi(\mathbf{x}) + b = \\ & \sum_{i=1}^n (\alpha_i - \alpha_i^*) \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}) + b = \\ & \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \end{aligned} \quad (8)$$

式(8)就是支持向量机,可以证明它具有从全局意义上逼近任意非线性函数的能力。支持向量机中的 $K(\mathbf{x}_i, \mathbf{x})$ 称为核函数,可以是任何一个满足 Mercer 条件的正定函数,该函数可在不知道非线性变换的具体形式下实现算法的非线性化,这是支持向量机的一个显著特点。常用的核函数有:多项式核函数、径向基核函数(Radial Basis Function, RBF)和 Sigmoid 核函数等。考虑到适当改变径向基函数的参数可以逼近其他形式的核函数,故采用 RBF 进行回归计算:

$$K(\mathbf{x}_i, \mathbf{x}) = \exp \left\{ -\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2\sigma^2} \right\} \quad (9)$$

支持向量机预测模型的参数向量 θ 可表示为 $\theta = (\varepsilon, C, \sigma)$ 。其中: ε 为不敏感损失函数的参数, C 为惩罚因子, σ 为 RBF 核函数核宽度控制常数。

1.3 经典粒子群优化算法

粒子群优化算法^[13](Particle Swarm Optimization, PSO)是

Kennedy 和 Eberhart 根据鸟类群体行为研究结果的启发而提出的一种全局优化技术。标准的 PSO 初始化为一群随机粒子,然后通过迭代找到最优解。在每一次迭代中,粒子通过跟踪两个“极值”来更新粒子在空间中的飞行速度 v 和位置 x 。第一个极值就是当前第 i 个粒子本身所找到的最优解 $Pbest_i = (pbest_{i1}, pbest_{i2}, \dots, pbest_{id})$,称为粒子的个体极值;另一个极值是当前整个粒子群找到的全优解 $Gbest = (gbest_1, gbest_2, \dots, gbest_d)$,称为粒子群的全局极值。由

$$v_{ij}(t+1) = \omega * v_{ij}(t) + c_1 * rand_1() * (pbest_{ij}(t) - x_{ij}(t)) + c_2 * rand_2() * (gbest_j(t) - x_{ij}(t)) \quad (10)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (11)$$

实现粒子的更新。其中: $i = 1, 2, \dots, N$ (N 为粒子群的规模); $j = 1, 2, \dots, d$ (d 为决策变量的维数); c_1, c_2 为加速常数(其值为非负数); $rand_1()$ 和 $rand_2()$ 是随机函数,产生 $(0, 1)$ 之间的随机数; $v_{ij} \in [v_{\min}, v_{\max}]$, v_{\min} 与 v_{\max} 是常数,由用户设定; ω 为惯性权重,它用来控制先前速度对当前速度的影响,从而协调粒子的全局搜索能力和局部搜索能力。

文献[14]对标准的 PSO 算法进行了改进,提出带收缩因子的粒子群算法,该算法能更有效地控制与约束粒子的飞行速度,同时增强算法的局部探索能力。带收缩因子的粒子的更新采用下式进行:

$$v_{ij}(t+1) = K * [v_{ij}(t) + c_1 * rand_1() * (pbest_{ij}(t) - x_{ij}(t)) + c_2 * rand_2() * (gbest_j(t) - x_{ij}(t))] \quad (12)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (13)$$

其中: K 为收缩因子, $K = 2 / (2 - c - \sqrt{c^2 - 4c})$, $c = c_1 + c_2$, 且 $c > 4$ 。

Carlisle 与 Dozier 综合了粒子群参数选择问题上的各种研究成果,并通过一系列的实验研究,详细地分析了不同控制参数对算法性能的影响,为粒子群算法提出了一组较完善、合理的参数(经典粒子群参数集),在这些基础上提出了经典粒子群算法模型(Canonical Particle Swarm Optimization, CPSO)^[15]。本文采用经典粒子群优化算法模型选择和优化支持向量机的参数向量。

2 热导传感器温度特性校正方法的实现

由第 1.1 节热导传感器温度特性的数据融合校正原理可知,气体浓度检测问题转化为对式(3)的近似估计问题,可利用支持向量回归方法来实现。通过传感器标定实验得到 n 组数据点:

$$(x_1(k), x_2(k); y_1(k), y_2(k)); k = 1, \dots, n) \quad (14)$$

在此基础上,用这 n 个数据点构造支持向量机的学习样本与测试样本,并选取适当的核函数及参数向量,然后用学习样本来训练支持向量机,用测试样本对支持向量机进行测试,经过不断地学习及测试,从而在输入向量与实际值之间建立一种非线性映射 $f(\cdot)$,在达到较高的精度之后,该支持向量机就可以作被测气体检测模型:

$$\hat{x}_1(t) = f_{svm}(Y(t), \theta) \quad (15)$$

其中: $f_{svm}(Y(t), \theta)$ 表示被测气体浓度(输入信号向量中第 1 个分量 $x_1(t)$)与输出信号向量 $Y(t)$ 的支持向量回归函数, θ 为支持向量机相应的参数向量。

鉴于支持向量机的参数向量选择实际上是一个多维函数优化问题,粒子群算法采用实数编码,粒子可直接编码为 $(C,$

$\varepsilon, \sigma)$ 。参数优化旨在测试样本集的均方根误差 $RMSE$ 和平均绝对百分比误差 $MAPE$ 都最小,故采用如下参数选择和优化的最优指标:

$$J = \lambda * RMSE + (1 - \lambda) * MAPE \quad (16)$$

其中: $RMSE$ 为均方根误差, $MAPE$ 为平均绝对百分比误差。均方根误差 $RMSE$ 和平均绝对百分比误差 $MAPE$ 的表达式分别定义为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{X}_i - X_i)^2} \quad (17)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{X}_i - X_i|}{X_i} \times 100\% \quad (18)$$

式(17)与式(18)中: \hat{X}_i 为校正后的氢气浓度值, X_i 为被测气体浓度的真值, n 为测试样本的个数。

式(16)中: “ $\lambda * RMSE$ ” 是为了抑制测传感器特性校正系统的均方根误差; “ $(1 - \lambda) * MAPE$ ” 是为了抑制传感器特性校正系统的平均绝对百分比误差; λ 为加权因子,用于调整这两种误差抑制的重要性。

根据上述基本算法和原理,基于粒子优化-支持向量机数据融合的热导传感器温度特性校正算法描述如下:

第 1 步 通过实验对传感器进行标定,构造学习样本集与测试样本集。

第 2 步 初始化粒子群算法的控制参数,并在变化范围内随机初始化支持向量机的参数初值。

第 3 步 将每个粒子的位置向量依次作为支持向量机参数,根据学习样本构造热导传感器温度特性的校正模型,并计算适应度 J ,若 J 满足要求或算法达到最大进化代数,转第 5 步,否则转第 4 步。

第 4 步 根据每个粒子的当前适应度值,由经典粒子群优化算法调整每个粒子的个体极值和全局极值,计算下一代支持向量机参数向量,转第 3 步。

第 5 步 得出最优化的支持向量机参数向量,构建校正能力最强的支持向量回归机模型,并输出校正后气体检测结果。

3 实验与结果

根据文献[6],通过实验设定 7 个不同的环境温度,调配不同体积分数的氢气通入传感器,记录热导传感器的输出电压值,不同环境温度下热导传感器对不同浓度氢气的测量试验数据如表 1 所示。

表 1 不同环境温度下热导传感器对不同浓度氢气的测量值

氢气 浓度/%	传感器输出电压/V						
	-10℃	-5℃	0℃	5℃	10℃	15℃	20℃
30	0.61	0.65	0.67	0.70	0.72	0.76	0.81
40	0.86	0.91	0.93	0.97	1.01	1.03	1.05
50	1.13	1.24	1.26	1.28	1.31	1.32	1.36
60	1.35	1.46	1.47	1.49	1.52	1.53	1.56
70	1.53	1.61	1.63	1.65	1.67	1.68	1.70
80	1.81	1.90	1.92	1.93	1.95	1.96	1.98
90	2.01	2.07	2.11	2.12	2.14	2.16	2.20

由表 1 构造支持向量机传感器校正的学习样本与测试样本,如表 2 所示。

将表 2 中的样本分为两组,其中第一组为学习样本(氢气浓度为 30%、40%、60%、80% 和 90% 的 35 个样本),第二组数据作为测试样本(氢气浓度为 50% 和 70% 的 14 个样

本),以检验该模型的检测效果。

表 2 学习与测试样本数据

序号	温度/ ℃	传感器 输出电压/V	氢气 浓度/%	序号	温度/ ℃	传感器 输出电压/V	氢气 浓度/%
1	-10	0.61	30	26	5	1.65	70
2	-10	0.86	40	27	5	1.93	80
3	-10	1.13	50	28	5	2.12	90
4	-10	1.35	60	29	10	0.72	30
5	-10	1.53	70	30	10	1.01	40
6	-10	1.81	80	31	10	1.31	50
7	-10	2.01	90	32	10	1.52	60
8	-5	0.65	30	33	10	1.67	70
9	-5	0.91	40	34	10	1.95	80
10	-5	1.24	50	35	10	2.14	90
11	-5	1.46	60	36	15	0.76	30
12	-5	1.61	70	37	15	1.03	40
13	-5	1.90	80	38	15	1.32	50
14	-5	2.07	90	39	15	1.53	60
15	0	0.67	30	40	15	1.68	70
16	0	0.93	40	41	15	1.96	80
17	0	1.26	50	42	15	2.16	90
18	0	1.47	60	43	20	0.81	30
19	0	1.63	70	44	20	1.05	40
20	0	1.92	80	45	20	1.36	50
21	0	2.11	90	46	20	1.56	60
22	5	0.70	30	47	20	1.70	70
23	5	0.97	40	48	20	1.98	80
24	5	1.28	50	49	20	2.20	90
25	5	1.49	60				

根据上述算法,在 Matlab 6.5 环境下进行编程。编程时设定支持向量参数的取值范围为: $1 \leq C \leq 1\,000$, $0.000\,1 \leq \varepsilon \leq 20$, $0.000\,1 \leq \sigma \leq 250$ 。经典粒子群优化算法的控制参数设为:收缩因子 $K = 0.729\,8$, 认知学习系数 $c_1 = 2.8$, 社会学习系数 $c_2 = 1.3$, $c = c_1 + c_2 = 4.1$, 粒子群规模 $N = 30$, 适应度函数的加权因子 $\lambda = 0.5$ 。实验表明,经过 42 次进化后目标函数收敛,得到支持向量机最佳参数如下: $C = 26.180\,6$, $\varepsilon = 1.760\,8$, $\sigma = 0.527\,4$, 从而最终构建了热导传感器温度特性校正模型。

将第二组 14 个测试样本代入支持向量机,得到不同温度下气体浓度的校正结果,如表 3 所示。

表 3 不同温度下气体浓度的检测结果

序号	温度/℃	被测氢气浓度/%	校正后的氢气浓度/%
1	-10	50	49.09
2	-5	50	50.36
3	0	50	50.72
4	5	50	50.42
5	10	50	48.42
6	15	50	50.07
7	20	50	50.64
8	-10	70	70.27
9	-5	70	68.56
10	0	70	69.12
11	5	70	69.29
12	10	70	65.31
13	15	70	69.03
14	20	70	68.53

由表 1 的传感器标定值可以看出,在输入气体浓度不变的情况下,工作环境温度在 $-10 \sim 20^\circ\text{C}$ 的范围变化时,传感器

的输出电压的最大波动范围达 32.78%。最小波动范围为 7.90%,平均波动范围为 17.10%,环境温度的变化对传感器输出的影响不可忽略。

根据表 3,经计算可知,本文提出的校正模型的最大绝对误差为 4.69%,最小绝对误差为 0.07%,平均绝对误差为 1.08%;最大绝对百分比误差为 6.70%,最小绝对百分比误差为 0.14%,平均绝对百分比误差为 1.73%;均方根误差为 1.54%。由此可见,环境温度的变化对传感器输出的影响已大幅降低,其气体检测结果几乎不随环境温度的变化而变化,达到了非常理想的校正效果。

4 结语

本文利用支持向量机对由热导传感器和温度传感器构成的传感器组的输出信号进行数据融合,构建传感器温度特性的校正模型,具有充分理论依据的支持,克服了传统方法在理论上的缺陷。氢气浓度的检测实验结果表明,本文提出的基于经典粒子群优化-支持向量机数据融合的热导传感器温度特性校正方法较好地消除了环境温度对传感器输出的影响,实现了气体浓度的精确检测,为传感器特性校正提供了一个新途径,具有非常好的实际应用价值。

参考文献:

- [1] 黄为勇,童敏明,任子晖.采用热导传感器检测气体浓度的新方法研究[J].传感技术学报,2006,19(4):973-975.
- [2] 苏亚,孙以材,李国玉.压力传感器热零点漂移补偿各种计算方法的比较[J].传感技术学报,2004,17(3):375-378.
- [3] 张朋,陈明,秦波,等.基于 BP 神经网络的振动筒压力传感器的温度补偿[J].传感技术学报,2007,20(10):2213-2217.
- [4] 张耀峰,孙以材,邢晓辉.基于人工神经网络的压力传感器的温度补偿[J].电子学报,2008,36(2):358-361.
- [5] 陈天璐,阙沛文.基于神经网络融合的温度误差补偿[J].工业仪表与自动化装置,2005(4):17-19.
- [6] 李伟,张涛.基于 BP 神经网络的热导气体分析仪[J].仪表技术与传感器,2007(12):62-63,73.
- [7] VAPNIK V N. Nature of statistical learning theory [M]. New York: Springer-Verlag, 1995.
- [8] 荣海娜,张葛祥,金炜东.系统辨识中支持向量机核函数及其参数的研究[J].系统仿真学报,2006,18(11):3204-3208.
- [9] LAGARIAS J C, REEDS J A, WRIGHT M H, et al. Convergence properties of the Nelder-Mead simplex method in low dimensions [J]. SIAM Journal on Optimization, 1998,9(1):112-147.
- [10] IMBAULT F, LEBART K. A stochastic optimization approach for parameter tuning of support vector machines [C]// Proceedings of the 17th International Conference on Pattern Recognition. Washington, DC: IEEE Computer Society, 2004:597-600.
- [11] 刘宏达,李殿璞,马忠丽.基于粒子群优化的船舶 PID 自动舵的改进[J].东南大学学报:自然科学版,2006,36(S1):198-200.
- [12] COELL C A, PULIDO G T, LECHUGA M S. Handling multiple objectives with particle swarm optimization [J]. IEEE Transactions on Evolutionary Computation, 2004,8(3):256-279.
- [13] KENNEDY J, EBERHART R C. Particle swarm optimization [C]// Proceedings of IEEE International Conference on Neural Networks. Piscataway: IEEE Press, 1995:1942-1948.
- [14] CLERC M, KENNEDY J. The particle swarm-explosion, stability, and convergence in a multidimensional complex space [J]. IEEE Transactions on Evolutionary Computation, 2002,6(1):58-73.
- [15] CARLISLE A, DOZIER G. An Off-the-Shelf PSO [C]// Proceedings of the workshop on particle swarm optimization. Indianapolis: Purdue School of Engineering and Technology, 2001:1-6.