

一种传感器特性的高精度拟合方法

黄为勇^{1,2}, 高玉芹^{1,2}, 田秀玲^{1,2}

(1. 徐州工程学院 江苏省大型工程装备检测与控制重点实验室, 江苏 徐州 221111;

2. 徐州工程学院 信电工程学院, 江苏 徐州 221111)

摘要: 为提高传感器非线性特性的拟合精度, 提出了一种基于最小二乘支持向量机 (LSSVM) 与量子粒子群优化算法 (QPSO) 的传感器特性拟合方法; 该方法采用最小二乘支持向量机构建传感器特性的非线性回归模型, 模型的参数向量由量子粒子群优化算法和学习样本平均绝对误差最小的准则进行优化; 实验结果验证了该方法的有效性, 其拟合绝对误差在 $10^{-9} \sim 10^{-7} \%$ 之间, 其拟合性能明显优于常规方法。

关键词: 传感器; 特性拟合; 最小二乘支持向量机; 量子粒子群优化

Fitting Sensor Characteristics with High Accuracy

Huang Weiyong^{1,2}, Gao Yuqing^{1,2}, Tian Xiuling^{1,2}

(1. Jiangsu Key Laboratory of Large Engineering Equipment Detection and Control, Xuzhou Institute of Technology,

Xuzhou 221111, China; 2. School of Information and Electrical Engineering, Xuzhou Institute of

Technology, Xuzhou 221111, China)

Abstract: To improve the fitting accuracy of nonlinear characteristics of the sensor characteristics, a new method is proposed based on the integration of least square support vector machine (LSSVM) and quantum-behaved particle swarm optimization algorithm (QPSO). Firstly, LSSVM is used to build the regression model of sensor characteristics. Then parameter vector of fitting model is intelligently tuned by QPSO and the principle of mean maximum absolute error minimization. The experimental results show that the absolute error is between $10^{-9} \sim 10^{-7} \%$, which means that the proposed method in this paper is effective, and performance of fitting model is superior to ordinary methods.

Keywords: sensor; characteristics fitting; least square support vector machine; quantum-behaved particle swarm optimization

0 引言

由于外界环境干扰、传感器元件老化等诸多不确定因素的影响, 导致传感器实际输出信号与被测物理量之间呈一种复杂的非线性关系^[1]。寻求传感器特性参数之间的有效数学模型, 实现传感器输入输出非线性特性的高精度拟合, 对保证传感器测控系统的精确性以及传感器的研究与设计都具有重要意义^[2]。

目前许多学者在该领域进行了较为深入的研究, 文献 [3-5] 提出了三次样条曲线函数、最小二乘法多项式曲线、神经网络等传感器特性的拟合方法, 取得了一定的效果。然而, 三次样条函数数学模型不是局部化的, 每个节点都会影响到全局, 使得样条插值也会有“多余”的波动^[6]; 最小二乘法多项式曲线拟合法是基于误差平方和下降的原则来求最优解, 易陷入局部最小点, 不易到到全局最优解, 当数据点多时, 甚至无法获得多项式系数; 神经网络 (ANN) 方法是建立在大数据理论渐近理论基础之上的一种机器学习方法, 采用经验风险最小化准则, 用十分复杂的模型去拟合有限的样本, 存在易陷入局部最小点、过拟合、模型不稳定及泛化能力差的问题^[7]。

文献 [1] 应用支持向量机 (SVM) 进行对传感器特性进行拟合, 较好地克服了 ANN 方法等诸多缺陷, 但也存在标准

SVM 方法需进行大规模一次寻优、建模速度慢的不足。文献 [8] 提出了一种基于最小二乘支持向量机 (LSSVM) 的传感器特性拟合方法, 具有建模速度快等优点^[9], 但该文没有提出模型参数的选择与优化方法, 影响了拟合精度的进一步提高。

粒子群优化算法自提出以来, 由于其具有计算快速性以及算法易实现等优点, 在支持向量机参数选择与优化方面得到了许多学者的关注与研究^[10], 但 Bergh 证明了粒子群优化算法存在不能收敛于全局最优解, 甚至于不能收敛于局部最优解的不足^[11]。文献 [12] 在深入分析粒子群优化算法的基础上, 认为粒子群系统是一个量子粒子系统, 每一个粒子具有量子行为, 可用波函数描述其状态, 并将 δ 势阱模型应用到 PSO 算法中, 提出了具有量子行为的粒子群优化算法 (QPSO)。相对于标准 PSO 算法, QPSO 算法具有进化方程简单、控制参数少、全局搜索能力强等优点, 在许多测试函数和实际应用中都取得了优于 PSO 算法的效果^[13]。

为此, 本文应用最小二乘支持向量机构建传感器特性的非线性拟合模型, 采用量子粒子群优化算法与训练样本平均绝对误差最小的准则进行自适应整定其模型的参数向量, 通过实验表明该模型的拟合精度明显提高, 具有较好的实用价值。

1 最小二乘支持向量机基本原理

LSSVM 回归的基本思想是利用如下形式的函数:

$$y = \omega^T \varphi(x) + b \quad (1)$$

来估计一个非线性系统的数据样本集 $D = \{(x_i, y_i) \mid i = 1, 2, \dots, N\}$, 其中: $x_i \in \mathbf{R}^n$ 为输入数据, $y_i \in \mathbf{R}$ 输出数据。根据经典支持向量机的基本思想, 通过非线性变换 $\varphi(\cdot)$ 将 n 维输入的样本从原空间映射到高维特征空间 F , 并在此空间中构造最优线性回归模型函数。优化函数问题可表示为在

收稿日期:2014-03-25; 修回日期:2014-04-25。

基金项目: 江苏省基础研究计划 (自然科学基金) 资助项目 (BK20131124); 徐州工程学院江苏省大型工程装备检测与控制重点实验室开放基金项目 (JSKLEDC201212)。

作者简介: 黄为勇 (1963-), 男, 江苏扬州人, 博士, 教授, 主要从事传感器信息处理、无线传感器网络技术等方面的研究。

$$y_i[\omega^T\varphi(x_i) + b] = 1 - \xi_i (i = 1, \dots, N) \quad (2)$$

的约束条件下, 求

$$\min_{\omega, b, \xi} \frac{1}{2}\omega^T\omega + \frac{1}{2}C \sum_{i=1}^l \xi_i^2 \quad (3)$$

其中: C 为惩罚因子, $\xi_i \geq 0$ 为松弛变量。

根据式 (3), 定义如下的 Lagrange 函数:

$$L = \frac{1}{2}\omega^T\omega + \sum_{i=1}^l \xi_i^2 - \sum_{i=1}^l \alpha_i \{y_i[\omega^T\varphi(x_i) + b] - 1 + \xi_i\} \quad (4)$$

式中, α_i 为拉格朗日乘子。再根据最优化学理论中的 KKT (Karush-Kuhn-Tucker) 条件, 得到如下等式和约束条件:

$$\begin{cases} \omega = \sum_{i=1}^l \alpha_i y_i \varphi(x_i) \\ \sum_{i=1}^l \alpha_i y_i = 0 \\ \alpha_i = \gamma \xi_i \\ y_i[\omega^T\varphi(x_i) + b] - 1 + \xi_i = 0 \end{cases} \quad (5)$$

对于 $i = 1, \dots, N$, 消去式 (5) 中的 ω 和 ξ ($\xi = [\xi_1, \dots, \xi_l]$)

可得如式 (6) 所示的线性矩阵方程:

$$\begin{bmatrix} 0 & \eta^T \\ s & \Omega + C^{-1}I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ Y \end{bmatrix} \quad (6)$$

式中, $\Omega \in R^{n \times n}$, $\Omega_{km} = \varphi^T(x_k)\varphi(x_m)$; $Y = [y_1 \dots y_l]^T$; $\eta = [1 \dots 1]^T$; $\alpha = [\alpha_1 \dots \alpha_l]$; I 为单位矩阵, s 为 l 维列向量, $s = [1 \dots 1]^T$ 。

式 (6) 为一线性方程组, 可用最小二乘法求出 α 和 b , 并利用核函数的方法, 令 $K(x, x_i) = \varphi^T(x)\varphi(x_i)$, 由此得到 LS-SVM 的回归函数为:

$$y(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (7)$$

常用的核函数有多项式核函数、RBF 核函数和 Sigmoid 核函数等多种。考虑到适当改变 RBF 核函数的参数可以逼近其他形式的核函数, 故可采用采用径向基核函数 (RBF) 进行回归计算:

$$K(x_i, x) = \exp\{-\|x - x_i\|^2 / 2\sigma^2\} \quad (8)$$

这样最小二乘支持向量机的参数向量可表示为: θ 可表示为 $\theta = \theta(C, \sigma)$, 其中: C 为惩罚因子, σ 为 RBF 核函数核宽度控制常数。

2 量子粒子群优化算法

在一个 n 维的目标搜索空间中, QPSO 算法有 m 个代表潜在问题解的粒子组成群体 $X = \{x_1, x_2, \dots, x_m\}$, 在 t 时刻, 第 i 个粒子的位置为 $x_i(t) = \{x_{i1}(t), x_{i2}(t), \dots, x_{in}(t)\}$, $i = 1, 2, \dots, m$ 。粒子没有速度向量。个体最好的位置 $P_i(t) = \{P_{i1}(t), P_{i2}(t), \dots, P_{im}(t)\}$; 群体全局最好的位置为 $P_g(t) = \{P_{g1}(t), P_{g2}(t), \dots, P_{gn}(t)\}$, 其中 g 为处于全局最好位置粒子的下标, $g \in \{1, 2, \dots, m\}$ 。

粒子的状态用波函数来描述且满足薛定谔方程, 用蒙特卡罗 (Monte Carlo) 法得到粒子的位置方程, 其表达式为:

$$x_{ij}(t+1) = p_{ij}(t) \pm \frac{L_{ij}(t)}{2} \ln \left[\frac{1}{u_{ij}(t)} \right] u_{ij}(t) \sim U(0, 1) \quad (9)$$

式 (9) 中 $L_{ij}(t)$ 被定义为:

$$L_{ij}(t) = 2\alpha \cdot |m_{bestj}(t) - x_{ij}(t)| \quad (10)$$

式 (10) 中的 α 称为收缩扩张系数, $m_{best}(t)$ 定义为所有粒

子最好位置的平均值, 即:

$$m_{best}(t) = (m_{best1}(t), m_{best2}(t), \dots, m_{bestn}(t)) = \left(\frac{1}{m} \sum_{i=1}^m P_{i1}(t), \frac{1}{m} \sum_{i=1}^m P_{i2}(t), \dots, \frac{1}{m} \sum_{i=1}^m P_{in}(t) \right) \quad (11)$$

最后得到粒子的进化公式变为:

$$x_{ij}(t+1) = p_{ij}(t) \pm \alpha \cdot |m_{bestj}(t) - x_{ij}(t)| \cdot \ln \left[\frac{1}{u_{ij}(t)} \right] u_{ij}(t) \sim U(0, 1) \quad (12)$$

在 QPSO 算法中, 除了种群规模、问题维和最大迭代次数参数以外, 收缩-扩张系数 α 是唯一需要人为设定的参数, 文献 [13] 在随机算法全局收敛的框架下证明了当 $\alpha < 1.781$ 时, 量子粒子群算法具有全局收敛性。

研究表明, 理想的搜索算法在迭代初期应取较大收缩-扩张系数 α 以保证粒子能在较大的空间内进行搜索, 防止局部收敛; 而在迭代后期应取较小的收缩-扩张系数 α 以保证粒子具有局部的搜索能力, 以提高收敛精度, 所以收缩-扩张系数必须采用先大后小的策略。为方便计, 可在 QPSO 算法的运行过程中, 该参数可采用线性减小的策略。

支持向量机的参数选择恰当与否对回归和预测的性能有决定性的影响, 直接影响回归和预测的结果, 鉴于量子粒子群算法的优越优化性能, 本文采用上述量子粒子群优化算法根据学习样本智能整定最小二乘支持向量机的参数向量 θ 。

3 支持向量机与量子粒子群算法集成的传感器特性拟合原理与方法流程

根据传感器特性、最小二乘支持向量机及量子粒子群优化原理, 传感器特性拟合原理, 如图 1 所示。

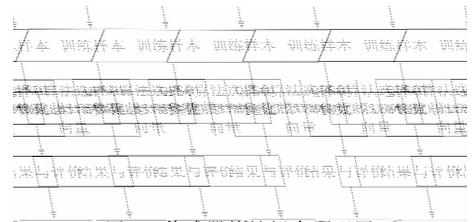


图 1 传感器特性拟合原理图

图 1 中, x 为传感器输入, 是来自实际系统的测量参数; y 为传感器输出; \hat{y} 为传感器的 LSSVM 拟合模型输出; 模型的参数 θ 由量子粒子群算法根据 LSSVM 拟合模型输出误差最小的准则进行智能整定。 t 为时间序列, $f(\cdot)$ 为模型函数; θ 为模型参数。

设传感器的 LSSVM 拟合模型输入输出关系可用下式描述:

$$\hat{y} = f(x) \quad (13)$$

其中: $f: x \in R^n \rightarrow y \in R$ 。

将系统建模问题与支持向量机回归问题相比较, 可以发现: 将 (x, y) 看成最小二乘支持向量机的训练样本时, 这两个问题是造价的, 即建模时, $f(\cdot)$ 的具体形式可由最小二乘支持向量机实现, 其中 θ 为最小二乘支持向量机的参数。

对于非线性系统, 采用核函数 $K(x_i, x_j)$ 技术, 根据 θ 求出 α 和 b 后, 最小二乘支持向量机的参数与输出结果为:

$$y(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (14)$$

由上可看出, 采用支持向量机方法, 既实现了系统建模,

又巧妙地利用了统计学习理论，使小样本、非线性、高维数和全局最优的优点在系统建模中得以体现，因此采用本方法来解决发动机动力的建模问题不仅可行，而且也是非常先进的，会取得比传统建模方法和神经网络等方法更好的结果。

结合量子粒子群算法的优化方法和最小二乘支持向量机的回归原理，本文提出的传感器特性拟合方法流程如图 2 所示。

(结 束)

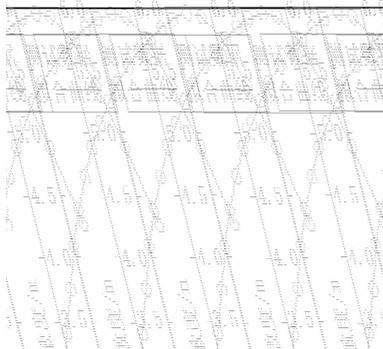


图 2 LSSVM 与 QPSO 相集成的传感器特性拟合流程图

与传统建模方法不同的是，本方法不受系统模型的限制，不需要知道输入/输出之间的精确数学映射，只根据系统的输入/输出数据对，通过学习得到一个描述系统输入/输出有关系的非线性映射。从控制的观点看，这里提出的方法是训练支持向量机来学习传感器系统的正向静态特性，从本质上说是一种传感器系统特性的正向建模方法。

4 实例验证与性能评价

为了便于进行对比研究，这里以文献 [3] 中的 190~480℃ 某传感器的灵敏度—温度对应关系的一组标定样本数据为数据源，其样本的时间间隔为 10℃，样本数量为 30，如表 1 所示。

表 1 传感器特性测试数据

温度/℃	灵敏度/V	温度/℃	灵敏度/V
190	1.44	340	4.88
200	1.41	350	5.07
210	1.40	360	5.24
220	1.44	370	5.39
230	1.53	380	5.52
240	1.71	390	5.64
250	1.97	400	5.74
260	2.30	410	5.83
270	2.67	420	5.90
280	3.04	430	5.95
290	3.40	440	5.92
300	3.76	450	5.75
310	4.09	460	5.38
320	4.39	470	4.88
330	4.65	480	4.27

为建模系统的稳健性^[14]，采用平均绝对误差 MAE (mean absolute error) 进行性能衡量和评价，量子粒子群优化算法的适应度表达式为：

$$MAE = \frac{1}{n} \sum_{i=1}^n | \hat{X}_i - X_i | \quad (15)$$

式 (15) 中， \hat{X}_i 为模型输出值； X_i 为真实值； n 为样本的个数，这里取 30。

选用 RBF 核函数，调用上述 LSSVM 与 QPSO 相集成的传感器特性拟合算法智能调校其参数向量。用全部 30 个学习样本来训练最小二乘支持向量机，采用训练样本平均绝对误差最小原则不断地学习及测试，从而在输入向量与实际值之间建立一种非线性映射，在达到最大迭代次数为 300 或 fitness 达到 10^{-12} 时停止寻优，得到最小二乘支持向量机的模型的最优参数为 $\theta = (C, \sigma) = (162\ 223.607\ 6, 0.028\ 8)$ ，此时该最小二乘支持向量机就可以作为传感器特性的拟合模型。建立模型后，输入训练样本后得到对应的输出结果，其拟合拟合曲线如图 3 所示。由图 3 可知，采用本文方法拟合的传感器特性曲线十分光滑，无论是整体还是局部，拟合曲线与测试数据的描点曲线非常接近。

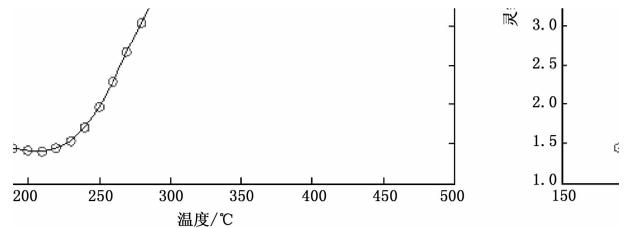


图 3 传感器特性拟合曲线

根据计算，所有样本点的绝对误差在 $6.660\ 2 \times 10^{-9} \sim 4.494\ 7 \times 10^{-7}$ 之间，相对误差在 $1.686\ 1 \times 10^{-7} \% \sim 3.121\ 2 \times 10^{-5} \%$ 之间。而文献 [5] 中采用的傅立叶正交基函数神经网络方法的相对误差在 $2.1 \times 10^{-5} \% \sim 1.1 \times 10^{-4} \%$ 之间，文献 [3] 三次样条方法相对误差在 $0.2 \% \sim 0.3 \%$ 之间。

由此可见，本文所提方法具有更强的高维非线性函数拟合性能，拟合输出结果与实际值非常接近，精度明显优于改进的神经网络方法与三次样条方法，达到了预期的建模效果。更为重要的是，本文所采用最小二乘支持向量机方法，具有坚实理论基础的支持，在小样本学习的情况下所建立拟合模型具有更好的泛化性能，更具实用价值。

需要指出的是：1) 本文没有对数据样本进行归一化处理，以保证与最小二乘支持向量机及量子粒子群优化算法计算快速的特点保持一致，为传感器特性的在线实时拟合建模与优化创造了条件；2) 由于最小二乘支持向量机具有高维信息处理的能力，本文所提方法同样适合其他一维以及高维传感器特性的拟合问题。

5 结束语

本文以传感器输入输出数据为样本，应用最小二乘支持向
(下转第 3083 页)

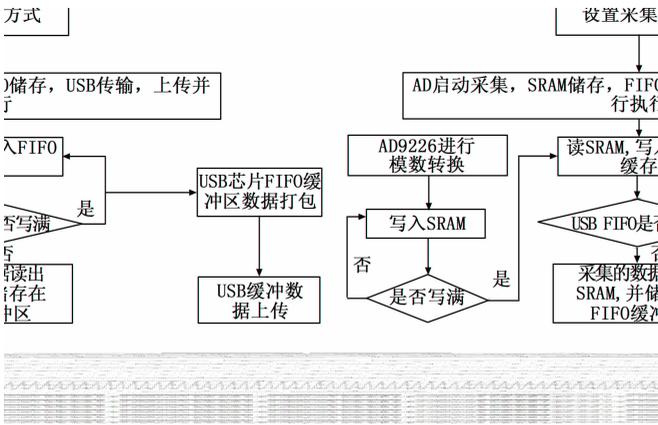


图 5 高速数据采集系统的总体控制流程

并将采集到的数据进行可视化处理, 测试选用一个波形发生器来产生模拟信号, 选用一个正弦波, 频率为 495 kHz, 幅值为 2.3 V 作为模拟输入端的输入进行数据采集和分析, 由于采样频率为 1 MHz, SRAM 容量为 512 k, 图 6 为上位机软件界面显示图, 通过软件计算, 得到采集后的信号频率为 494.812 MHz, 准确性达到 99.9%, 幅值为 2.295 V, 准确性达到 99.7%, 采样时间为 524 ms, 从而验证了本系统数据采集的正确性和实时性。

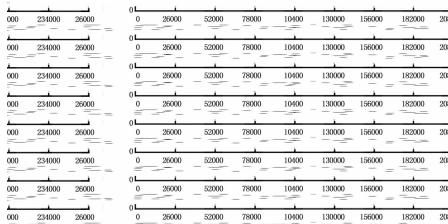


图 6 高速数据采集界面显示系统

5 结束语

本文介绍了一种锻造行业中对击锤打击力能参数的高速数据采集系统, 采用 FPGA 实现多路高速数据采集系统, 硬件系统充分利用了 FPGA 丰富的 I/O 资源和强大的并行处理能力, 选用高速 AD9226 作为 A/D 采样芯片, SRAM 作为数据缓存存储器, USB2.0 作为数据高速传输方式, 实现了系统并行、大容量、并行的技术要求, 单通道采样速率可以达到 1 MHz, USB 总线将采集到的数据批量打包实时上传到上位机, 传输速率可以达到 30 MB/s, 该采集系统的硬件接口简单, 采集速率高、功耗低, 精度高, 可以很方便的应用于其他行业数据采集系统中, 通过更换不同的传感器, 可以应用于不同场合的测控需要。

参考文献:

[1] 李 亭, 李 华. GPIF 与 FIFO 接口设计 [J]. 电测与仪表, 2006, 43 (6): 56-58.

[2] 王 宇, 任晓红, 张 超, 等. 基于 FPGA 的交流采样同步倍频算法及实现 [J]. 电测与仪表, 2013, (12): 47-50.

[3] 高迎慧, 侯忠霞. 基于 FPGA 和 USB 的高速数据采集与传输系统 [J]. 工矿自动化, 2007, 4 (8): 105-106.

[4] 焦斌亮, 韩志学. 基于 EZ-USB FX2 实现的高速数据采集系统 [J]. 仪表技术与传感器, 2005, (7): 21-22.

[5] 谭安菊, 龚 彬. USB2.0 控制器 CY7C68013 与 FPGA 接口的 Verilog HDL 实现 [J]. 电子工程师, 2007, 33 (7): 52-55.

[6] 曾 虹, 刘世杰, 张 翔, 等. 基于 USB 的高速并行数据采集系统的设计与实现 [J]. 计算机测量与控制, 2007, 15 (8): 1105-1106.

[7] 刘 吉, 杨德伟, 文怀涛, 等. 基于 USB 通信的 FPGA 高速数据采集系统 [J]. 现代电子技术, 2011, 34 (10): 186-192.

[8] 安 荣, 任勇峰, 李圣昆. 基于 FPGA 和 USB2.0 的数据采集系统 [J]. 仪表技术与传感器, 2009, (3): 49-51.

(上接第 3076 页)

量机构建传感器输入输出特性的回归拟合模型, 模型的参数向量由量子粒子群优化算法与平均绝对误差最小的准则进行自适应优化。实验结果验证了该方法的有效性, 其模型的拟合性能明显高常规方法, 对传感器非线性特性研究具有较好参考价值。

参考文献:

[1] 马迎坤, 张希农. 多维传感器标定的支持向量机复合式方法 [J]. 航空动力学报, 2011, 26 (6): 1274-1281.

[2] 程德福, 王 君, 凌振宝, 等. 传感器原理及应用 [M]. 北京: 机械工业出版社, 2013.

[3] 简弃非, 刘海燕. SnO₂ 纳米传感器灵敏度-温度特性曲线拟合研究 [J]. 传感技术学报, 2005, 18 (1): 50-52.

[4] 陈坤华, 卢文科. 载体催化型瓦斯传感器输出电压与瓦斯何种分数函数关系研究 [J]. 工矿自动化, 2013, 39 (2): 92-95.

[5] 曾吉昭, 竺 炜, 孙湘海, 等. 一种基于神经网络算法的高精度拟合传感器温度特性曲线的方法 [J]. 传感技术学报, 2007, 20 (2): 326-328.

[6] 徐萃薇. 计算方法引论 [M]. 北京: 高等教育出版社, 2001.

[7] 黄为勇, 童敏明, 任子晖. 热导传感器温度特性的 CPSO-SVM 数据融合校正 [J]. 计算机应用, 2009, 29 (12): 3259-3262.

[8] 孙 林, 杨世元. 基于 LS-SVM 的温度传感器非线性关系拟合及参考端温度补偿 [J]. 应用科学学报, 2009, 27 (6): 616-622.

[9] 闫俊荣, 郭西进. 基于最小二乘支持向量机的异步电机转子故障诊断 [J]. 计算机测量与控制, 2013, 21 (2): 336-339.

[10] Isis Didier Lins, Márcio das Chagas Moura, Enrico Zio, etc. A particle swarm-optimized support vector machine for reliability prediction [J]. Quality and Reliability Engineering International, 2012, 28 (2): 141-258.

[11] Bergh F V D. An Analysis of Particle Swarm Optimizers [D]. Pretoria: University of Pretoria, 2001.

[12] Sun J, Feng B, Xu W B. Particle swarm optimization with particles having quantum behavior [A]. IEEE Proc of Congress on Evolutionary Computation [C]. Piscataway: IEEE, 2004: 325-331.

[13] 孙 俊, 方 伟, 吴小俊, 等. 量子行为粒子群优化: 原理及其应用 [M]. 北京: 清华大学出版社, 2011.

[14] 张金玉, 张 炜. 装备智能故障诊断与预测 [M]. 北京: 国防工业出版社, 2013.