

基于 Wiener 模型的传感器动态非线性辨识研究

雷 超, 韩华亭, 刘 滔

(空军工程大学 防空反导学院, 西安 710051)

摘要: 针对实际测量中传感器存在较大非线性的缺点, 提出利用改进型 Wiener 模型描述传感器动态非线性模型; 将 Wiener 模型的动态线性环节和静态非线性环节分别利用 Laguerre 函数和最小二乘支持向量机进行辨识, 最终实现传感器模型的建立; 通过仿真实验验证比较不同方法的辨识误差与速度, 最终结果表明该方法在非线性动态传感器模型辨识方面具有明显的速度和精度优势。

关键词: 传感器; Wiener 模型; 最小二乘支持向量机

Study on Identification of Dynamic Nonlinear Sensor Based on Wiener Model

Lei Chao, Han Huating, Liu Tao

(Air Defense and Antimissile College, Air Force Engineering University, Xi'an 710051, China)

Abstract: In the view of the actual measurement sensor is nonlinear, The method of using modified Wiener model to describe the dynamic nonlinear sensor model is proposed in this paper. Respectively using Laguerre function and least squares support vector machine for the identification of dynamic linear part and nonlinear static link of the Wiener model. Through simulation experiment to compare the speed and identification error of different methods, the results show that this method in the identification of nonlinear dynamic sensors has an obvious advantage.

Keywords: sensor; Wiener model; LSSVM

0 引言

目前研究传感测试系统, 在测试要求不高或测试系统非线性不明显的条件下, 一般将其看成是线性系统, 采用线性的方法进行研究^[1], 但对于非线性特性非常明显的系统, 采用线性的方法会产生非常大的误差或严重错误。而实际测试中, 动态非线性几乎存在于所有传感测试系统中, 而一个传感测试系统的非线性特性, 主要集中在传感器上面。为了研究整个传感测试系统的特性, 就必须首先建立合适的传感器动态非线性模型。

Wiener 模型作为一种典型的 block-oriented 模型, 由动态线性子环节串联静态非线性环节组成, 因其结构简单, 且能够描述大量动态非线性过程, 当前已经成为传感器动态非线性辨识领域的热门, 如: D. H. Yu 采用递归神经网络的方法^[2], J. S. Wang 采用模糊神经网络的方法^[3], A. Marconato 采用支持向量机的方法^[4], Ke-Jun Xu 采用 Volterra 级数的方法^[5]。但在实际应用中, 这些方法都存在一定的缺陷。第一是算法参数多导致算法复杂, 收敛速度慢; 第二是认为动态线性环节和静态非线性环节之间的信号是可测的。作者在总结前人成果的基础上, 提出利用 Laguerre-LSSVM 辨识 Wiener 的方法, 即先用 Laguerre 函数描述 Wiener 模型的动态线性环节, 然后利用最小二乘支持向量机 (LSSVM) 函数描述其非线性环节, 最终实现动态非线性传感测试系统的辨识。仿真验证以及对比试验结果验证了该方法的优越性。

1 非线性动态传感系统的 Wiener 模型辨识原理

1.1 Wiener 模型

Wiener 模型结构如图 1 所示。文献 [6] 说明 Wiener 模型相较于 H 模型在描述系统动态性方面更有优势。Wiener 模型的线性部分可由状态空间模型、阶跃响应模型、脉冲响应模型、ARX 模型、有限脉冲响应模型 (FIR)、Laguerre 正交函数等描述。模型的非线性部分可由神经网络模型、多项式结构、PWL 模型、SVM 结构等描述。

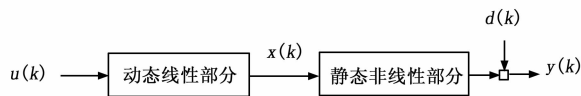


图 1 Wiener 模型

Laguerre 函数, Kautz 函数等正交函数在模拟线性模型方面具有良好的效果, 且 Laguerre 正交函数相比于 ARX 模型结构, 能够以较低的模型阶次获得较优的逼近效果, 同时其对采样时间具有不敏感特性, 因而 Wiener 模型动态线性环节的辨识采用 Laguerre 正交函数多项式函数结构简单, 能够近似描述非线性环节, 但是其对于强非线性特性的系统进行描述时, 效果非常不理想^[7]。神经网络、支持向量机等具有更强的非线性逼近能力, 因而可将其应用于 Wiener 模型非线性部分的辨识。但是神经网络需要大量的样本作支撑, 而支持向量机需要样本小, 且能达到神经网络同样的非线性逼近效果, 同时 LSSVM 相比于 SVR 其在计算量及训练速度上更具优势, 因此本文在 SVR 基础上选取 LSSVM 进行非线性部分的辨识。

1.2 Wiener 模型辨识原理

辨识的主要思路: 首先利用 Laguerre 级数辨识 Wiener 模型的线性环节, 然后利用 LSSVM 的非线性拟合能力将分解后的 Laguerre 级数进行一个非线性映射, 最终得到传感器的非

收稿日期: 2014-03-05; 修回日期: 2014-04-15。

作者简介: 雷 超 (1989-), 男, 陕西兴平人, 在读硕士, 主要从事战术导弹发射系统测控技术方向的研究。

线性动态辨识模型, 对于 SISO 系统, 本文所建立的 Wiener 模型结构如图 2 所示。

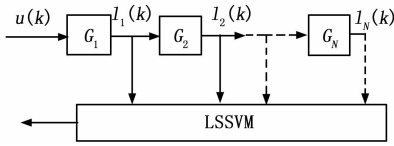


图 2 Laguerre-LSSVM 辨识模型

其表达式为:

$$\mathbf{L}(k+1) = \mathbf{A}\mathbf{L}(k) + \mathbf{B}u(k) \quad (1)$$

$$y(k) = f(\mathbf{L}(k)) \quad (2)$$

$$\mathbf{L}(k) = [l_1(k), l_2(k), \dots, l_N(k)]^T \quad (3)$$

式中, $u(k)$ 为模型的输入, $y(k)$ 为模型的输出。A 和 B 为系数矩阵, Laguerre 函数的状态矢量 $\mathbf{L}(k) = [l_1(k), l_2(k), \dots, l_N(k)]^T$ 为 LSSVM 的输入, $f(\cdot)$ 表示非线性映射关系。

2 LSSVM 回归原理

为了解决样本数量较大时 SVM 算法运算速度较慢的缺点, Suykens 于 1999 年^[8-9]对标准 SVM 算法进行了改进, 最小二乘支持向量机 (LSSVM)。

LSSVM 的回归算法就是 LSSVM 在回归学习中的应用。考虑一般情况, 用非线性函数 $f(x) = (\omega \cdot \varphi(x)) + b$ 估计有 N 个数据的训练样本集 $D = \{(x_i, y_i) | i = 1, 2, \dots, N\}$, 其中, $x_i \in \mathbf{R}^n$ 为输入数据, $y_i \in \mathbf{R}^n$ 为输出数据。 ω 为权向量, b 为偏差量。LSSVM 以误差 e_i 的平方和作为损失函数, 因而 LSSVM 的函数估计问题可转化为寻找最优目标:

$$\min_{\omega, b, e} J(\omega, e) = \frac{1}{2} \omega^T \omega + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 \quad (4)$$

$$s.t. \quad y_i = (\omega \cdot \varphi(x_i)) + b + e_i, i = 1, 2, \dots, N$$

式中, $\varphi(\cdot): \mathbf{R}^n \rightarrow \mathbf{R}^H$ 是将原始空间映射到一个高维 Hilbert 特征空间的核空间函数, 以便从原始空间中抽取特征, 同时将原始空间中的样本映射为高维空间中的一个向量, 从而解决原始空间中不可分的问题。 $e_i \in \mathbf{R}$ 为误差变量, $\gamma > 0$ 为正则化参数, γ 是对模型复杂度与训练误差的折中。 γ 值越小, 模型的复杂度就会降低; γ 值越大, 模型的回归误差将会越小。 γ 使得所求的目标函数具有很好的泛化能力。同时, LSSVM 将 SVM 中的不等式约束改为了等式约束。对于目标函数的求解, 根据 KKT 条件, 将式 (4) 中的模型进行对偶转换, 于是定义 Lagrange 函数

$$L(\omega, b, e, \alpha) = J(\omega, e) - \sum_{i=1}^N \alpha_i \{(\omega \cdot \varphi(x_i)) + b + e_i - y_i\} \quad (5)$$

式中, $\alpha_i \geq 0, i = 1, 2, \dots, N$ 为 Lagrange 乘子, 被称为支持值 (Support Values)。L(ω, b, e, α) 分别对 ω, b, e, α 求偏导, 并令它们都为零, 得:

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 & \Rightarrow \omega = \sum_{i=1}^N \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 & \Rightarrow \sum_{i=1}^N \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 & \Rightarrow \alpha_i = \gamma e_i \\ \frac{\partial L}{\partial \alpha_i} = 0 & \Rightarrow (\omega \cdot \varphi(x_i)) + b + e_i - y_i = 0 \end{cases} \quad (6)$$

消除变量 ω 和 e , 可得如下矩阵方程:

$$\begin{bmatrix} 0 & \mathbf{l}_v^T \\ \mathbf{l}_v & \mathbf{\Omega} + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (7)$$

式中, $\mathbf{l}_v = [1, \dots, 1]^T, \mathbf{y} = [y_1, \dots, y_N]^T, \boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_N]^T, \mathbf{\Omega}$ 为一个 $N \times N$ 的方阵, 第 i 行 j 列值 $\Omega_{ij} = \varphi(x_i)^T \varphi(x_j), i = 1, 2, \dots, N$ 。

若 $\Phi = \begin{bmatrix} 0 & \mathbf{l}_v^T \\ \mathbf{l}_v & \mathbf{\Omega} + \gamma^{-1} \mathbf{I} \end{bmatrix}$ 是可逆的, 则参数 α 和 b 的求解公式为

$$\begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \Phi^{-1} \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (8)$$

根据 Mercer 条件, 存在映射函数 $\varphi(\cdot)$ 和核函数 $K(\cdot, \cdot)$ 使得

$$K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (9)$$

根据所求结果得到 LSSVM 的回归函数为

$$f(x) = \sum_{i=1}^N \alpha_i (\varphi(x_i) \cdot \varphi(x)) + b = \sum_{i=1}^N \alpha_i K(x_i, x) + b \quad (10)$$

从上式可看出, LSSVM 采用最小二乘线性系统作为损失函数, 这样可通过等式约束目标函数转化为线性方程, 代替 SVM 中的二次规划问题。LSSVM 较大地降低了算法的复杂度, 提高了算法学习速度, 使得计算成本降低。当核函数为径向基核函数时, LSSVM 仅需确定 γ, σ 两个参数。

3 基于 Laguerre-LSSVM 的非线性动态辨识构造

本文 Wiener 模型的辨识方法为: 首先通过多次实验选择合适的 Laguerre 参数, 这样先确立了线性环节的辨识模型, 在此基础上, 根据输入输出数据集 $\{L(k), y(k)\}_{k=1}^N$, 进行非线性环节的辨识。

3.1 线性动态环节

对于单输入单输出的传感测试系统, 可由下式描述:

$$\hat{y}(z) = \left(\sum_{i=1}^N c_i L_i(z) \right) u(z) \quad (11)$$

第 i 阶 Laguerre 函数可由下式确定:

$$L_i(z) = \sqrt{(1-\alpha^2)T} \frac{(1-\alpha z)^{i-1}}{(z-\alpha)^i} \quad (12)$$

式中, $\alpha = e^{-pT}, N$ 为 Laguerre 函数的维数, p 为 Laguerre 函数的时标参数, T 为采样时间。

假设 N 维状态向量 $\mathbf{L}(k) = [l_1(k), l_2(k), \dots, l_N(k)]^T$, Laguerre 函数的状态空间表达式为:

$$\mathbf{L}(k+1) = \mathbf{A}\mathbf{L}(k) + \mathbf{B}u(k) \quad (13)$$

再做如下定义:

$$\begin{aligned} \tau_1 &= \exp(-pT) \\ \tau_2 &= T + \frac{2}{p} (\exp(-pT) - 1) \\ \tau_3 &= -\exp(-pT) - \frac{2}{p} (\exp(-pT) - 1) \\ \tau_4 &= \sqrt{2p} \frac{(1-\tau_1)}{p} \end{aligned} \quad (14)$$

可得到如下系数矩阵:

$$A = \begin{bmatrix} \tau_1 & 0 & \cdots & 0 \\ \frac{-\tau_1\tau_2 - \tau_3}{T} & \tau_1 & \cdots & 0 \\ \cdots & \cdots & \cdots & \cdots \\ \frac{(-1)^{N-1}\tau_2^{N-2}(\tau_1\tau_2 + \tau_3)}{T^{N-1}} & \cdots & \frac{-\tau_1\tau_2 - \tau_3}{T} & \tau_1 \end{bmatrix} \quad (15)$$

$$B = [\tau_1 \quad (-\tau_2/T)\tau_1 \quad \cdots \quad (-\tau_2/T)^{N-1} \quad \tau_1] \quad (16)$$

式中, 当 $p > 0$, 系统为稳定的。为提高算法的收敛速度, Walberg^[10]把系统主时间常数定为 $1/p$ 。

用 Laguerre 函数状态的加权和作为式 (11) 描述的线性系统的输出, 即

$$\hat{y}(k) = C^T L(k) \quad (17)$$

其中: $C = [c_1, c_2, \dots, c_N]$ 为 Laguerre 函数的系数。

3.2 静态非线性环节

为了利用 Laguerre 函数构建 wiener 模型, 需要用非线性映射代替式 (17) 中的线性关系, 模型输出可描述为

$$\hat{y}(k) = f(L(k)) \quad (18)$$

其中: $f(\cdot): \mathbf{R}^N \rightarrow \mathbf{R}$ 表示非线性映射关系。

文献 [11] 采用多项式函数逼近非线性环节, 由下式描述式 (17)

$$x'(k) = h_0 + \sum_{i=1}^N h_i l_i(k) + \cdots + \sum_{i=1}^N \sum_{j=i}^N \cdots \sum_{k=r}^N \sum_{m=k}^N h_{ij \cdots km} l_i(k) l_j(k) \cdots l_k(k) l_m(k) \quad (19)$$

上式可写成 $\hat{y}(k) = H^T \varphi(k)$, 其中向量 $\varphi(k)$ 为:

$$\varphi(k) = [1, l_1, \dots, l_N, l_1^2, l_1 l_2, \dots, l_N^2, l_1 l_2, \dots, l_N^3, \dots, l_N^M]^T \quad (20)$$

$$H = [h_0, h_1, \dots, h_R]^T$$

要求解的参数, 可通过给定输入输出数据集由最小二乘法得到。待求解的参数个数 R 为

$$R = \sum_{i=1}^n \binom{N+i-1}{i} \quad (21)$$

从式 (14) 中可看出, 当 Laguerre 函数维数 N 或多项式函数阶次 n 的增大时, R 显著增加, 会产生维数灾难问题, 为解决此问题, S. Tötterman 等^[12]用 SVR 描述非线性环节, 但是在样本多的时候, 采用 SVR 训练, 训练速度非常慢, 而 LSSVM 用等式约束取代了不等式约束, 训练速度比 SVR 速度快的多, 故本文采用 LSSVM 来近似描述 Wiener 模型的非线性环节。则

$$\hat{y}(k) = f(L(k)) = w^T \varphi(L(k)) + b \quad (22)$$

其中: $w \in \mathbf{R}^n$ 为加权向量, $\varphi(\cdot): \mathbf{R}^N \rightarrow \mathbf{R}^n$ 为输入空间到特征空间的非线性映射, b 为偏差量。

本文利用输入输出数据集 $\{u(k), y(k)\}_{k=1}^N$ 对 Wiener 模型进行辨识。为了加以区分, 我们利用脚标 s 描述训练样本。可以看到, Laguerre 函数状态向量 $L_s(k)$ 可以利用式 (13) 计算, 因此可以利用数据集 $\{L_s(k), y_s(k)\}_{k=1}^N$ 辨识 LSSVM 模型。

LSSVM 参数的求取采用上节中所介绍的方法, 由此定义拉格朗日函数为:

$$\xi(w, b, e; \alpha) = J(w, e) - \sum_{k=1}^N \alpha_k (\mathbf{w}^T \varphi(L(k)) + b + e_k - y_s(k)) \quad (23)$$

其中: $\alpha_k \in \mathbf{R} (k=1, 2, \dots, N)$ 为 Lagrange 乘子, 对上式进行优化求解, 可得

$$\begin{bmatrix} 0 & I_N^T \\ I_N & \Omega + \gamma^{-1} I_N \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ Y_s \end{bmatrix} \quad (24)$$

式中, $I_N = [1, \dots, 1]^T$, $\Omega_{ij} = K(L_s(i), L_s(j)) = \varphi(L_s(i))^T \varphi(L_s(j))$, $\forall i, j = 1, 2, \dots, N$, $\alpha = [\alpha_1, \dots, \alpha_M]$, $Y_s = [y_s(1), \dots, y_s(N)]^T$ 。

对于新的 LSSVM 模型输入 L^* , 则输出

$$f(L^*) = \sum_{k=1}^N \alpha_k K(L_s(k), L) + b' \quad (25)$$

其中: α_k 和 b' 为式 (24) 的解。

至此, 上述 Wiener 模型的所有待辨识参数求解完毕,

4 仿真实验

为了验证模型效果, 对如下的传感系统进行 Wiener 模型辨识仿真实验, 其动态线性环节为:

$$H(z) = \frac{z^3 - 0.1z^2 - 0.1z + 0.4}{z^3 - 1.1z^2 - 0.25z + 0.65} \quad (26)$$

静态非线性增益为:

$$y(k) = f(L(k)) = 1.1L(k) + 0.9L^2(k) \quad (27)$$

传感器动态测试系统的标定经常采用冲击信号, 在这里也采用冲击信号作为模型激励信号, 测得其冲击输入和模型响应。同时, 为了检验该算法的抗干扰能力和鲁棒性, 我们在输入信号时域中加入均值为 0, 方差为 0.01 的高斯白噪声。图 3 中曲线 1 表示动态非线性模型对冲击输入的响应输出。

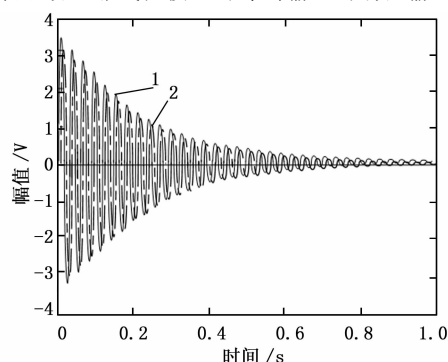


图 3 非线性动态模型辨识仿真实验结果

根据输入信号 $u(t)$ 和传感系统响应信号 $y(t)$ 产生训练样本 $D = \{(x_i, y_i) | i = 1, 2, \dots, N\}$, 先利用 Laguerre 正交函数辨识系统线性环节, 产生 LSSVM 的训练样本 $\{L_s(k), y_s(k)\}_{k=1}^N$, 进行静态非线性环节的辨识。

传感系统非线性模型辨识完成之后, 将原激励信号输入辨识好的非线性模型中, 测试辨识效果, 模型的辨识输出曲线如图 3 中的曲线 2 所示。同时为了进一步验证该方法的优点, 我们选 Laguerre-SVR 算法同上述算法进行对比, 验证其对 Wiener 模型的辨识效果, 主要是对比两种方法的建模速度和精度, 建模精度用平均绝对误差来衡量 (MAE), 我们通过叠加不同采样长度和不同强度的高斯白噪声进行对比。表 1 给出了不同条件下两种方法的辨识结果。

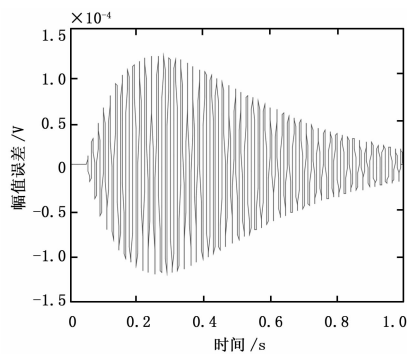


图 4 非线性动态辨识误差曲线图

表 1 两种不同方法对传感器辨识结果对比

采样长度	噪声方差	算法	时间(s)	MAE(V)
20	0.01	SVR	0.263 0	0.044 7
		LSSVM	0.050 0	0.036 5
20	0.02	SVR	0.193 3	0.063 8
		LSSVM	0.020 0	0.033 7
50	0.01	SVR	2.537 0	0.062 1
		LSSVM	0.211 0	0.017 8
50	0.02	SVR	2.421 0	0.411 0
		LSSVM	0.198 0	0.096 3
120	0.01	SVR	69.331 0	0.109 4
		LSSVM	1.245 0	0.031 0
120	0.02	SVR	65.312 0	0.121 5
		LSSVM	1.026 0	0.069 2

从表 1 可以看出，当采样长度较短时，两种算法的耗时相差不大，建模精度 LSSVM 略高于 SVR，但是当样本数量进一步增大时，差距明显增大，当采样长度增大到 12 时，SVR 耗时比 LSSVM 高出将近两个数量级，这是由其算法的机理所决定的，前文已经介绍了 LSSVM 算法相较于 SVR 算法的优势，通过仿真实验进一步验证了这一理论。

5 小结

本文提出了 Wiener 模型传感器非线性系统辨识新方法，将 Wiener 模型的动态线性环节和静态非线性环节分别利用 Laguerre 正交函数和 LSSVM 函数描述。利用 LSSVM 求解 Wiener 模型非线性环节的方法相比于 SVR，只需要求解线性方程组便可获得 LSSVM 参数，省去了 SVR 中较为繁琐的 QP

优化问题，当样本数量比较大时，这一方法的优势非常明显。最后，对实际传感测试系统进行了仿真实验，验证了该方法的可行性，同时，与支持向量回归机（SVR）辨识方法进行了对比，结果表明本文所采用算法辨识精度更高，速度更快，能够有效的辨识非线性动态传感器模型。

参考文献：

[1] 任 好. 汽车发动机相关传感器动态特性的研究 [D]. 合肥：合肥工业大学，2005.

[2] Yu D H, Liu F, Lai P Y. Nonlinear dynamic compensation of sensors using inverse - model - based neural network [J]. IEEE Trans. Instrum. Meas, 2008, 57 (10): 2364 - 2376.

[3] Wang J S, Chen Y P. A hammerstein recurrent neuro - fuzzy network with an online minimal realization learning algorithm [J]. IEEE Trans. Fuz. Sys, 2008, 16 (6) : 1597 - 1612.

[4] Marconato A, Hu M Q, Boni A. Dynamic compensation of nonlinear sensors by a learning - from - examples approach [J]. IEEE Trans. Instrum. Meas, 2008, 57 (8): 1689 - 1694.

[5] Xu K J, Wang X F. Identification of sensor block model using volt-erra series and frequency response function [J]. Measurement, 2008 (41) : 1135 - 1143.

[6] Cervantes A L, Agamennoni O E, Figueroa J L. A nonlinear model predictive control system based on wiener piecewise linear models [J]. Journal of Process Control, 2003, 13 (7): 655 - 666.

[7] Norquay S J, Palazoglu A, Romagnoli J A. Application of Wiener model predictive control (WMPC) to a pH neutralization experiment [J]. IEEE Transactions on Control Systems Technology, 1999, 7 (4): 437 - 445.

[8] Suykens J A K, De Brababter J, Tony Van Gestel. Least Squares Support Vector Machines [M]. World Scientific, 2002.

[9] Suykens J A K, De Brababter J, Lukas L et al. Weighted least squares support vector machines: robustness and sparse approximation [J]. Neuro computing, 2002, 48, 1 - 4, 85 - 105.

[10] Walberg B. System identification using Laguerre models [J]. IEEE Transactions on Automatic Control, 1991, 36 (5): 551 - 562.

[11] 朱 照, 张志杰. 传感器实时动态补偿方法与误差分析 [J]. 传感器与微系统, 2010, 29 (6): 68 - 74.

[12] Tötterman S, Toivonen H T. Support vector method for identification of Wiener models [J]. Journal of Process Control, 2009, 19 (7): 1174 - 1181.

~~~~~

(上接第 2327 页)

[4] 宇天文, 刘晓燕, 沈嘉权. 实时嵌入式构件模型组装方法及时间性推理 [J]. 计算机工程与应用, 2009, 45 (25): 74 - 77.

[5] 陈 波. 基于软件体系结构的构件模型和语言研究 [D]. 长沙：国防科学技术大学，2007.

[6] Sha L, Rajkumar R, Lehoczky J. Priority inheritance protocols: An approach to real-time synchronization [J]. IEEE Transactions on Computers, 1990, 39 (9): 1175 - 1185.

[7] Etienne Borde, Jan Carlson. Toward Verified Synthesis of Pro-

Com, a Component Model for Real-Time Embedded Systems [J]. IEEE Transactions on Software Engineering, 2011, 20 (24): 129 - 138.

[8] Bonakdarpour B, Bozga M, Jaber M, et al. From high-level component-based models to distributed implementation [A]. In ACM International Conference on Embedded Software (EMS - OFT) [C], 2010: 209 - 218.

[9] 任艳斐, 元传伟. 基于嵌入式技术的汽车防撞报警系统的设计与应用 [J]. 计算机测量与控制, 2014, 22 (2): 516 - 518.