

# 基于 LS-SVM 的非线性多功能传感器信号重构方法研究

魏国<sup>1</sup> 刘剑<sup>1</sup> 孙金玮<sup>1</sup> 孙圣和<sup>1</sup>

**摘要** 提出了基于最小二乘支持向量机 (Least squares support vector machine, LS-SVM) 的非线性多功能传感器信号重构方法. 不同于通常采用的经验风险最小化重构方法, 支持向量机 (Support vector machine, SVM) 是基于结构风险最小化准则的新型机器学习方法, 适用于小样本标定数据情况, 可有效抑制过拟合问题并改善泛化性能. 在 SVM 基础上, LS-SVM 将不等式约束转化为等式约束, 极大地简化了二次规划问题的求解. 研究中通过  $L$ -折交叉验证实现调整参数优化, 在两种非线性情况下对多功能传感器的输入信号进行了重构, 实验结果显示重构精度分别达到 0.154% 和 1.146%, 表明提出的 LS-SVM 重构方法具有高可靠性和稳定性, 验证了方法的有效性.

**关键词** 多功能传感器, 信号重构, 最小二乘支持向量机, 交叉验证  
**中图分类号** TP212

## Study on Nonlinear Multifunctional Sensor Signal Reconstruction Method Based on LS-SVM

WEI Guo<sup>1</sup> LIU Jian<sup>1</sup> SUN Jin-Wei<sup>1</sup> SUN Sheng-He<sup>1</sup>

**Abstract** In this paper, the nonlinear multifunctional sensor signal reconstruction method based on the least squares support vector machine (LS-SVM) is proposed. Different from the reconstruction methods with empirical risk minimization, the support vector machine (SVM) is a new machine learning method based on structural risk minimization, which is applicable to the case of small sample size calibration data, and can efficiently restrain overfitting and improve generalization capability. With SVM as a basis, the LS-SVM involves equality constraints instead of inequality constraints, so the solving process of the quadratic programming problem can be greatly simplified. In this study,  $L$ -fold cross validation is adopted to optimize the adjustable parameters. The reconstruction of input signals of a multifunctional sensor was carried out in two situations of different nonlinearities for which the reconstruction accuracies were 0.154% and 1.146%, respectively. The experimental results demonstrate the high reliability and high stability of the proposed LS-SVM reconstruction method, as well as the feasibility.

**Key words** Multifunctional sensor, signal reconstruction, least squares support vector machine (LS-SVM), cross validation

对于实际存在的一类多参数测量问题, 由于多个被测量同时交叉作用于传感器, 使得传统测量方法难以应用或导致测量准确度降低. 而多功能传感器表现出多输入多输出特性, 可同时敏感多个物理、化学参量, 通过巧妙利用传感器的交叉敏感特性来实现多参数测量任务, 提高测量准确度. 近年来, 随着微机电加工技术的发展, 多功能传感器以其体积小、功耗低、多功能等优势逐渐成为现代传感器发展的主流趋势之一. 多功能传感器在环境参数和一

般工业测量<sup>[1-2]</sup> 中已经得到开发应用, 预计在航空、航天、医学等领域也会有很大的发展潜力和广阔的应用前景.

一般而言, 多功能传感技术包含两方面内容: 可敏感多个参量的多功能传感器设计和基于多功能传感器输出信号的被测量重构算法研究<sup>[3]</sup>. 所谓多功能传感器信号重构, 就是由多个观测信号 (传感器输出信号) 通过适当的估计算法获取多个被测量 (传感器输入信号) 的过程. 多功能传感器传递函数的反函数通常呈高维非线性状态, 导致被测参量的求解空间都在三维或三维以上. 而多功能传感器标定时, 通过多次实验所获取的标定数据相对多功能传感器输入输出空间是一个小样本集合, 如何实现小样本标定数据情况下的信息值分离和重构是多功能传感器信号处理亟待解决的关键问题. 这方面的研究有助于合理减少标定样本, 优化标定策略. 目前, 针对多功能传感器信号重构算法的深入研究已经开展<sup>[4-5]</sup>, 但这些方法普遍采用的是经验风险最小化准则, 该准则在样本数量足够大时满足经验风险趋近

收稿日期 2007-04-16 收修改稿日期 2007-10-08  
Received April 16, 2007; in revised form October 8, 2007  
国家自然科学基金 (60772007, 60672008), 中国博士后科学基金 (20070410258), 教育部留学回国人员科研启动基金 (BAQQ 24403602) 资助  
Supported by National Natural Science Foundation of China (60772007, 60672008), China Postdoctoral Science Foundation (20070410258), the Scientific Research Foundation for the Returned Overseas Chinese Scholars of State Education Ministry (BAQQ24403602)  
1. 哈尔滨工业大学自动化测试与控制系 哈尔滨 150001  
1. Department of Automatic Measurement and Control, Harbin Institute of Technology, Harbin 150001  
DOI 10.3724/SP.J.1004.2008.00869

于真实风险;而当样本数量较少时,最小化经验风险并不能够保证最小化真实风险,因而易导致泛化性差和过拟合等问题<sup>[6]</sup>.支持向量机(Support vector machine, SVM)是适用于小样本情况的新机器学习方法,它利用结构风险最小化准则来代替传统的经验风险最小化准则,该方法体现了对给定数据逼近精度和逼近函数复杂度之间的折中思想,因而更适合小样本情况下的学习问题.

文献[7]将SVM用于非线性多功能传感器信号重构,但其只讨论了非线性较小情形,对非线性较大情形没有加以研究.SVM的求解涉及二次规划问题,计算复杂、效率低,而最小二乘支持向量机(Least squares support vector machine, LS-SVM)<sup>[8-9]</sup>很好地解决了这个问题.LS-SVM将不等式约束转化为等式约束,只需求解一个线性方程组,计算效率高<sup>[10]</sup>.因而,实现小样本标定数据情况下的非线性多功能传感器信号重构,LS-SVM较SVM更具优越性.

本文以二输入二输出多功能传感器为对象,研究利用LS-SVM方法实现非线性多功能传感器信号重构,同时考虑了非线性较小和较大两种情形.具体地,介绍了LS-SVM基本理论及其在非线性多功能传感器信号重构中的算法实现,对L-折交叉验证(L-fold cross validation)实现调整参数优化及重构实验结果作了详细分析和讨论.

## 1 LS-SVM 简介

SVM最早是针对模式分类问题提出来的,随着Vapnik对 $\varepsilon$ -不敏感损失函数的引入<sup>[11]</sup>,SVM已推广到非线性系统的回归估计.LS-SVM是SVM的发展,用偏差平方和代价函数替换 $\varepsilon$ -不敏感损失函数,将不等式约束转化为等式约束.

给定样本数据集

$$D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_k, y_k), \dots, (\mathbf{x}_N, y_N)\} \\ \mathbf{x}_k \in \mathbf{R}^n, y_k \in \mathbf{R} \quad (1)$$

LS-SVM用如下形式的回归函数对未知函数进行估计

$$f(\mathbf{x}) = \langle \boldsymbol{\omega}, \varphi(\mathbf{x}) \rangle + b \quad (2)$$

上述函数估计问题转化为如下优化问题

$$\min_{\boldsymbol{\omega}, b, \mathbf{e}} J(\boldsymbol{\omega}, \mathbf{e}) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2 \\ \text{s.t. } y_k = \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle + b + e_k, k = 1, \dots, N \quad (3)$$

其中 $\langle \cdot, \cdot \rangle$ 表示内积, $\boldsymbol{\omega} \in \mathbf{R}^{n_h}$ 是权值向量, $\varphi(\cdot) : \mathbf{R}^n \rightarrow \mathbf{R}^{n_h}$ 是把输入空间映射到高维线性特征空间

的非线性函数,特征空间维数 $n_h$ 可以无穷大,阈值 $b \in \mathbf{R}$ ,偏差变量 $e_k \in \mathbf{R}$ ,惩罚参数 $\gamma \geq 0$ .

为求解优化问题(3),构造Lagrangian函数

$$\mathcal{L}(\boldsymbol{\omega}, b, \mathbf{e}; \boldsymbol{\alpha}) = J(\boldsymbol{\omega}, \mathbf{e}) - \sum_{k=1}^N \alpha_k \{ \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle + b + e_k - y_k \} \quad (4)$$

其中, $\alpha_k \in \mathbf{R}$ 为拉格朗日乘子.根据最优性条件有

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial \boldsymbol{\omega}} = 0 \rightarrow \boldsymbol{\omega} = \sum_{k=1}^N \alpha_k \varphi(\mathbf{x}_k) \\ \frac{\partial \mathcal{L}}{\partial b} = 0 \rightarrow \sum_{k=1}^N \alpha_k = 0 \\ \frac{\partial \mathcal{L}}{\partial e_k} = 0 \rightarrow \alpha_k = \gamma e_k, k = 1, \dots, N \\ \frac{\partial \mathcal{L}}{\partial \alpha_k} = 0 \rightarrow \langle \boldsymbol{\omega}, \varphi(\mathbf{x}_k) \rangle + b + e_k - y_k = 0 \end{cases} \quad (5)$$

消去 $\boldsymbol{\omega}, \mathbf{e}$ 得到线性方程组

$$\begin{bmatrix} 0 & \mathbf{1}_\nu^\top \\ \mathbf{1}_\nu & \Omega + I/\gamma \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (6)$$

其中, $\mathbf{y} = [y_1, \dots, y_N]^\top$ , $\boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_N]^\top$ , $\mathbf{1}_\nu = [1, \dots, 1]^\top$ , $\Omega_{k,l} = \langle \varphi(\mathbf{x}_k), \varphi(\mathbf{x}_l) \rangle$ , $\Omega_{k,l}$ 为矩阵 $\Omega$ 的第k行第l列元素.根据Mercer条件<sup>[12]</sup>,内积可由一个核函数 $K(\cdot, \cdot)$ 表示,则有 $\Omega_{k,l} = K(\mathbf{x}_k, \mathbf{x}_l)$ ,其中 $k, l = 1, \dots, N$ .

求解方程组(6)得到 $b$ 和 $\boldsymbol{\alpha}$ ,并结合最优条件(5),由LS-SVM确定的回归函数可表示为

$$f(\mathbf{x}) = \sum_{k=1}^N \alpha_k K(\mathbf{x}, \mathbf{x}_k) + b \quad (7)$$

核函数 $K(\cdot, \cdot)$ 的选择有多种可能,常用的包括线性核函数、多项式核函数、多层感知器核函数和高斯径向基核函数,还可以使用自己定义并证明满足Mercer条件的核函数.本文采用应用最为普遍的高斯径向基核函数,其表达式为

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

其中 $\sigma$ 为核宽度.这样,LS-SVM将二次规划问题转化为线性方程组求解问题,而且其调整参数(惩罚参数 $\gamma$ 和核宽度参数 $\sigma$ )比SVM减少了一个,从而降低了计算复杂性.

## 2 多功能传感器模型及其信号重构算法实现

图1为二输入二输出多功能传感器系统模拟电阻网络,输入为滑动电阻器 $RP_1$ 和 $RP_2$ 的下部电

阻值与总电阻值的比值  $x$  和  $y$ , 输出为电压值  $u$  和  $v$ . 图中  $V_{cc} = 5\text{V}$ ,  $R_1 = R_2 = R_3 = 1\text{k}\Omega$ , 取  $RP_1 = RP_2$ , 并令  $P = RP_1/R_1 = RP_2/R_2$ , 由基尔霍夫定律得该多功能传感器传递函数为

$$\begin{cases} u = \frac{5[2x + y + Pxy(2 - x - y)]}{3 + P[y(1 - y) + x(1 - x)]} \\ v = \frac{5[2y + x + Pxy(2 - x - y)]}{3 + P[y(1 - y) + x(1 - x)]} \end{cases} \quad (9)$$




图1 二输入二输出多功能传感器电路模型

Fig. 1 A circuit model of multifunctional sensor with two inputs and two outputs

本研究利用 LS-SVM 方法实现上述多功能传感器模拟电阻网络的信号重构, 即构造传感器传递函数的反函数 (由  $u$ 、 $v$  分别重构  $x$ 、 $y$ ). 这里  $x$ 、 $y$  的重构区域皆选取为  $[0.1, 0.9]$ . 标定实验数据的获取按照如下规则进行: 输入  $x$ 、 $y$  在重构区域  $[0.1, 0.9]$  内以 0.05 为间隔进行取值, 呈均匀网格分布, 再由式 (9) 计算相应的输出  $u$ 、 $v$ , 可得到  $N = 17 \times 17 = 289$  组标定输入输出数据. 本文具体研究不同非线性情形下传感器输入信号的重构问题, 而  $P$  值在一定程度上反映了传感器系统的非线性情况:  $P$  值小, 非线性小;  $P$  值大, 非线性大. 由于  $x$  和  $y$  的取值范围相同, 且  $u$  和  $v$  的取值范围也相同, 可以用  $u$  与  $x$  的关系直观表示非线性程度 (见图 2): 当  $y$  值确定时,  $u$  与  $x$  的关系曲线在  $P = 10$  时明显比  $P = 2$  时弯曲. 图 3 为  $x$ 、 $y$  呈均匀网格分布情况下的系统输出  $u$ 、 $v$  分布图, 可见系统非线性越大, 输出  $u$ 、 $v$  分布越集中, 且这种分布是散乱的.

由于系统输出与输入在数值上相差较大且量纲不一致, 需对数据进行预处理, 即将数据归一化到区间  $[0, 1]$ . 归一化后的传感器输入输出信号分别表示为  $x'$  和  $y'$ 、 $u'$  和  $v'$ , 这里又将  $u'$  和  $v'$  表示为向量形式  $\mathbf{s} = [u', v']$ . 利用标定实验数据, 通过适当方法优化参数  $\gamma$ 、 $\sigma^2$ , 随之求解相应的  $b$ 、 $\alpha$ , 最终得到形如式 (7) 的反映传感器传递函数反函数的回归函数

$$x'(\mathbf{s}) = \sum_{k=1}^N \alpha_{x,k} K(\mathbf{s}, \mathbf{s}_k) + b_x \quad (10)$$




图2 传感器系统输出  $u$  与输入  $x$  关系 ( $y = 0.1$ )

Fig. 2 Relationship between output  $u$  and input  $x$  of sensor system ( $y = 0.1$ )




图3 传感器系统输出  $u$ 、 $v$  分布

Fig. 3 Distribution of outputs  $u$  and  $v$  of sensor system

$$y'(\mathbf{s}) = \sum_{k=1}^N \alpha_{y,k} K(\mathbf{s}, \mathbf{s}_k) + b_y \quad (11)$$

调整参数  $\gamma$  和  $\sigma^2$  的优化方法很多, 如交叉验证、VC 界方法、统计学习理论以及贝叶斯学习等方法<sup>[9]</sup>, 其中交叉验证 (尤其是 10-折交叉验证) 在实际中运用最为普遍, 且取得了很好的效果<sup>[10, 13-14]</sup>. 本文同时考察了贝叶斯推论和作为交叉验证特例的快速留一法, 它们对调整参数优化的效果都不如 10-折交叉验证.

$L$ -折交叉验证的基本过程为: 将样本数据集  $D$  (含有  $N$  组标定实验数据) 随机分成  $L$  等份, 分别标记为  $D_1, D_2, \dots, D_L$  (每份含有  $N/L$  组数据); 依次以  $D_i$  ( $i = 1, \dots, L$ ) 为验证集, 其余  $L - 1$  份作为训练集, 对 LS-SVM 进行总共  $L$  次训练和验证, 累加  $L$  次验证过程的验证集中重构数据的均方差 ( $MSE_i$ ), 作为本次  $L$ -折交叉验证的性能参数. 累加

结果可表示为

$$MSE = \sum_{i=1}^L MSE_i = \frac{L}{N} \sum_{k=1}^N e_k^2 \quad (12)$$

其中  $e_k = f_P - f_D$ ,  $f_P$  为样本估计值,  $f_D$  为样本真值. 文中  $f_D$  代表  $x'$  或  $y'$ ,  $f_P$  代表相对应的估计值.

在利用  $L$ -折交叉验证对调整参数  $\gamma$  和  $\sigma^2$  进行优化时, 使用了网格搜索方法. 具体步骤为: 给定两个调整参数的取值范围, 取自然对数并均分为  $M$  等份, 产生  $M^2$  种参数组合, 在每一种参数组合下分别对 LS-SVM 进行交叉验证, 并存储相应的  $MSE$ , 最后共获得  $M^2$  个  $MSE$ , 认为最小的  $MSE$  所对应的调整参数组合是最优的, 这一步记为循环 1; 以循环 1 中获得的最优调整参数为中心, 重新给定每个参数一个更小的取值范围, 重复循环 1 的过程, 这一步记为循环 2, 循环 2 的实施是为了在循环 1 的基础上进一步优化调整参数. 有时为获得更理想的重构精度, 需要多次对标定实验数据随机划分并进行  $L$ -折交叉验证.

获得反映传感器传递函数反函数的回归函数后, 还需要通过测试数据进一步考察逼近效果. 测试数据的获取方法与标定实验数据的获取方法类似, 只是  $x$ 、 $y$  的取值间隔更小 (这里为 0.01), 这样可以保证在考察范围内, 测试数据包含所有的标定实验数据. 完成标定和测试之后, 就可以利用回归函数 (10)、(11) 并经过数据处理后得到被测输入信号的估计值, 从而实现被测量  $x$ 、 $y$  的重构.

### 3 实验结果及分析

实践经验表明, 进行  $L$ -折交叉验证时, 选取过大的  $L$  并不能保证调整参数优化效果得到显著提高, 研究中采用较为普遍使用的 10-折交叉验证对调整参数  $\gamma$  和  $\sigma^2$  进行优化, 图 4、图 5 给出了  $P = 2$  情形下对被测量  $x$  重构时的调整参数优化结果. 由图 4 可知, 循环 1 获得的优化调整参数为  $(\ln(\gamma), \ln(\sigma^2)) = (11.6530, -1.8259)$  (图 4(b) 中 “◆” 所示), 对应  $(\gamma, \sigma^2) = (115\ 031.99, 0.1611)$ , 此时  $MSE = 5.1226E - 008$ ; 以上述优化调整参数组合为中心 (图 5(b) 中 “◆” 所示), 重新给定更小的取值范围, 循环 2 获得的最优调整参数为  $(\ln(\gamma), \ln(\sigma^2)) = (11.8973, -2.0063)$  (图 5(b) 中 “●” 所示), 对应  $(\gamma, \sigma^2) = (146\ 870.01, 0.1345)$ , 此时  $MSE = 3.3536E - 008$ , 明显比循环 1 中的结果要小, 该  $\gamma$  和  $\sigma^2$  可作为最终优化调整参数加以使用. 同理, 可求得  $P = 2$  情形下对被测量  $y$  重构时的最终优化调整参数  $(\gamma, \sigma^2) = (307\ 172.17, 0.1727)$ .

在上述选定的最优调整参数情形下,  $x$ 、 $y$  的重构相对误差分布如图 6、图 7 所示, 具体结果见表 1.

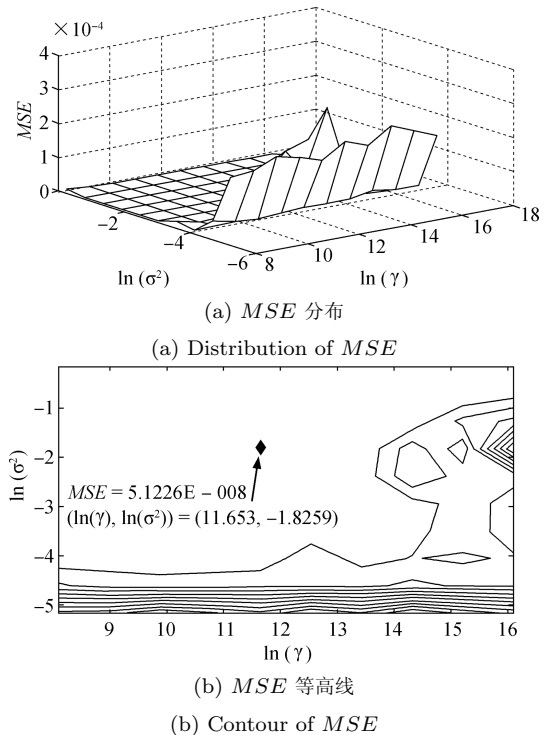


图 4 交叉验证循环 1 调整参数优化结果

Fig. 4 Optimized results of the adjustable parameters in Iteration 1 during cross validation

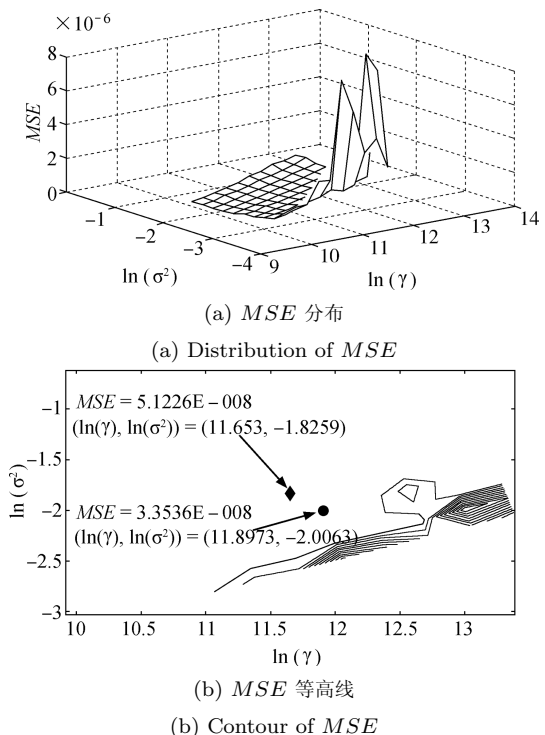


图 5 交叉验证循环 2 调整参数优化结果

Fig. 5 Optimized results of the adjustable parameters in Iteration 2 during cross validation




图 6 输入  $x$  的重构相对误差分布 ( $P = 2$ )

Fig. 6 Distribution of the reconstruction relative errors for input  $x$  ( $P = 2$ )




图 7 输入  $y$  的重构相对误差分布 ( $P = 2$ )

Fig. 7 Distribution of the reconstruction relative errors for input  $y$  ( $P = 2$ )

表 1  $P = 2$  情形下输入  $x$ 、 $y$  的重构结果

Table 1 Reconstruction results for inputs  $x$  and  $y$  when  $P = 2$

重构对象	考查区域 [0.1, 0.9]		考查区域 [0.2, 0.8]	
	相对误差 (%)	满量程误差 (%)	相对误差 (%)	满量程误差 (%)
$x$	$\pm 0.154$	$\pm 0.024$	$\pm 0.060$	$\pm 0.017$
$y$	$\pm 0.154$	$\pm 0.025$	$\pm 0.074$	$\pm 0.020$

当  $P = 2$  时, 在  $[0.1, 0.9]$  整个重构区域内,  $x$  的重构相对误差  $\leq \pm 0.154\%$ , 满量程误差  $\leq \pm 0.024\%$ ;  $y$  的重构相对误差  $\leq \pm 0.154\%$ , 满量程误差  $\leq \pm 0.025\%$ . 这些实验数据表明, 在非线性多功能传感器系统非线性较小时, LS-SVM 方法可以很高的精度实现被测信号的重构.

类似地,  $P = 10$  情形下对  $x$  和  $y$  进行重构时的最终最优调整参数对  $(\gamma, \sigma^2)$  分别为  $(6\ 484.44,$

$0.0228)$  和  $(12\ 252.95, 0.0256)$ ,  $x$ 、 $y$  的重构相对误差分布如图 8、图 9 所示, 具体结果见表 2. 虽然在  $P = 10$  情形下, 被测量的重构相对误差较  $P = 2$  情形有所增加, 但考虑到  $P = 10$  对应的传感器系统非线性较大, 出现这种结果完全合理; 另外, 从满量程误差和绝对误差 ( $x$ 、 $y$  的重构绝对误差分别小于  $\pm 0.0019$  和  $\pm 0.0020$ ) 看, 重构精度仍然较高, 能够满足实际应用的要求.




图 8 输入  $x$  的重构相对误差分布 ( $P = 10$ )

Fig. 8 Distribution of the reconstruction relative errors for input  $x$  ( $P = 10$ )




图 9 输入  $y$  的重构相对误差分布 ( $P = 10$ )

Fig. 9 Distribution of the reconstruction relative errors for input  $y$  ( $P = 10$ )

表 2  $P = 10$  情形下输入  $x$ 、 $y$  的重构结果

Table 2 Reconstruction results for inputs  $x$  and  $y$  when  $P = 10$

重构对象	考查区域 [0.1, 0.9]		考查区域 [0.2, 0.8]	
	相对误差 (%)	满量程误差 (%)	相对误差 (%)	满量程误差 (%)
$x$	$\pm 1.017$	$\pm 0.212$	$\pm 0.464$	$\pm 0.128$
$y$	$\pm 1.146$	$\pm 0.224$	$\pm 0.626$	$\pm 0.176$

以上实验结果显示,在不同的非线性情形下( $P = 2, P = 10$ ), LS-SVM 均显现出高重构精度,同时也表明 LS-SVM 对非线性不甚敏感,在信号重构中具有较高的稳定性. 观察图 6~图 9 发现,被测量  $x$ 、 $y$  的重构误差均在边缘区域稍大,在中间区域则小得多,表 1 和表 2 列出的考察区域为  $[0.2, 0.8]$  的具体实验数据也体现了这种情况. 因此,如果在实际应用过程中将被测量的测量范围限制在比标定区域稍小的区域,可获得更高的重构精度.

本文最后将 LS-SVM 与 SVM 和 B 样条整体最小二乘(B-spline TLS)进行了比较,表 3 给出了三种方法对  $y$  重构的结果. 根据前面的内容可知,对  $y$  重构属于散乱数据处理. 高维 B 样条通过张量积构造,这种构造特点使得 B-spline TLS 适合处理规则网格分布数据,而 LS-SVM 和 SVM 在处理高维散乱数据方面的能力很强. 因此,理论和表 3 给出的实际结果表明,LS-SVM 和 SVM 对  $y$  重构的效果均优于 B-spline TLS. LS-SVM 与 SVM 最显著的区别在于代价函数不同,LS-SVM 在 SVM 基础上将  $\epsilon$ -不敏感损失函数替换为误差平方和代价函数,使得对偶空间中二次规划问题的不等式约束转化为等式约束,将优化问题的求解转化为一般线性方程组的求解,通过简单的迭代即可完成,而不需要通过繁琐的优化方法解决,具有更高的计算效率. 从表 3 给出的重构结果来看,LS-SVM 和 SVM 重构效果基本相当. 当然,由于 SVM 中  $\epsilon$ -不敏感损失函数的  $\epsilon$  也充当了一个可调整参数(其值可以取得很小甚至为 0),且有较多二次规划优化方法可供选择,可以预见,如果能够选取到合适的  $\epsilon$  值和二次规划优化方法,SVM 的重构效果会更好一些. 但是,寻找合适的  $\epsilon$  和二次规划优化方法过程本身就是一个优化问题,并且还需要同时优化调整参数,因此,SVM 方法需要较长的运算时间才能得到理想结果. 由于上述原因,从计算效率上考虑,在回归分析中 LS-SVM 比 SVM 更具优势. 另外,根据文献 [10] 可知,通过简单的稀疏性调整,LS-SVM 也能够具有 SVM 的稀疏性特点(本文中标定数据相对较少,没有作稀疏性调整);同时,由于误差平方和代价函数的引入,LS-SVM 比 SVM 具有更好的抑制噪声能力.

文献 [7] 将 SVM 用于非线性多功能传感器信号重构,标定样本数据取为  $9 \times 9$  形式. 该文只讨论了非线性较小( $P = 2$ )情形,给出的重构相对误差为 0.40%,而对非线性较大( $P = 10$ )情形没有研究. 本文实际运算表明,在标定样本数据为  $9 \times 9$  形式情况下,当  $P = 2$  时,LS-SVM 方法对传感器输入信号的重构精度为 0.39%,与文献结果一致;当  $P = 10$  时,LS-SVM 和 SVM 方法的重构精度均低于 6%,效果难以令人满意. 因此,为获得较为理想

的重构精度,本文将标定样本数据取得稍多一些,为  $17 \times 17$  形式.

表 3 输入  $y$  的重构结果比较  
Table 3 Comparison of the reconstruction results for input  $y$

非线性	重构方法	考查区域 [0.1, 0.9]		考查区域 [0.2, 0.8]	
		相对误差 (%)	满量程误差 (%)	相对误差 (%)	满量程误差 (%)
$P = 2$	三次 B 样条	$\pm 0.594$	$\pm 0.280$	$\pm 0.142$	$\pm 0.061$
	SVM	$\pm 0.142$	$\pm 0.019$	$\pm 0.058$	$\pm 0.013$
	LS-SVM	$\pm 0.154$	$\pm 0.025$	$\pm 0.074$	$\pm 0.020$
$P = 10$	三次 B 样条	$\pm 2.484$	$\pm 0.553$	$\pm 1.202$	$\pm 0.306$
	SVM	$\pm 1.194$	$\pm 0.157$	$\pm 0.362$	$\pm 0.081$
	LS-SVM	$\pm 1.146$	$\pm 0.224$	$\pm 0.626$	$\pm 0.176$

## 4 结论

非线性多功能传感器标定实验数据相对于系统输入输出空间是小样本集合,针对基于经验风险最小化准则的方法在小样本情形下泛化能力较差的实际情况,本文提出了利用基于结构风险最小化准则的 LS-SVM 方法来实现非线性多功能传感器信号重构. 研究中通过  $L$ -折交叉验证实现调整参数优化,在两种非线性情况下对多功能传感器的输入信号进行了重构. 理论分析和实验表明,LS-SVM 中构建的回归函数对非线性多功能传感器传递函数的反函数具有很好的逼近性能,在不同非线性情形下,均能够以高精度和高稳定性实现被测量的重构,呈现出较好的泛化性能. 另外,LS-SVM 对被测信号的重构计算量小、速度快,便于实时检测应用.

LS-SVM 中调整参数的快速优化一直是研究的难点问题,SVM 也同样存在这个问题. 虽然交叉验证应用普遍,效果较好,但运算时间较长. 因此,关于调整参数的优化问题还需进一步研究.

## References

- 1 Sun J W, Shida K. Multilayer sensing and aggregation approach to environmental perception with one multifunctional sensor. *IEEE Sensors Journal*, 2002, **2**(2): 62–72
- 2 Eftimov T A, Bock W J. A simple multifunctional fiber optic level/moisture/vapor sensor using large-core quartz polymer fiber pairs. *IEEE Transactions on Instrumentation and Measurement*, 2006, **55**(6): 2080–2087
- 3 Wei G, Shida K. Estimation of concentrations of ternary solution with NaCl and sucrose based on multifunctional sensing technique. *IEEE Transactions on Instrumentation and Measurement*, 2006, **55**(2): 675–681
- 4 Flammini A, Marioli D, Taroni A. Application of an optimal look-up table to sensor data processing. *IEEE Transactions on Instrumentation and Measurement*, 1999, **48**(4): 813–816

- 5 Sun Jin-Wei, Liu Xin, Sun Sheng-He. TLS algorithm-based study on multi-functional sensor data reconstruction. *Acta Electronic Sinica*, 2004, **32**(3): 391–394  
(孙金玮, 刘昕, 孙圣和. 基于总体最小二乘的多功能传感器信号重构方法研究. 电子学报, 2004, **32**(3): 391–394)
- 6 Zhang Xue-Gong. Introduction to statistical learning theory and support vector machines. *Acta Automatica Sinica*, 2000, **26**(1): 32–42  
(张学工. 关于统计学习理论与支持向量机. 自动化学报, 2000, **26**(1): 32–42)
- 7 Liu Xin, Sun Jin-Wei, Liu Dan. Nonlinear multifunctional sensor signal reconstruction based on support vector regression. *Chinese Journal of Sensors and Actuators*, 2006, **19**(4): 1167–1170  
(刘昕, 孙金玮, 刘丹. 基于支持向量回归的非线性多功能传感器信号重构. 传感技术学报, 2006, **19**(4): 1167–1170)
- 8 Suykens J A K, Vandewalle J. Least squares support vector machine classifiers. *Neural Processing Letters*, 1999, **9**(3): 293–300
- 9 Suykens J A K. Nonlinear modeling and support vector machines. In: *Proceedings of the 18th IEEE Instrumentation and Measurement Technology Conference*. Budapest, Hungary: IEEE, 2001. 287–294
- 10 Wang H F, Hu D J. Comparison of SVM and LS-SVM for regression. In: *Proceedings of 2005 International Conference on Neural Networks and Brain*. Beijing, China: IEEE, 2005. 279–283
- 11 Vapnik V [Writer], Zhang Xue-Gong [Translator]. *The Nature of Statistical Learning Theory*. Beijing: Tsinghua University Press, 2000. 126–127  
(Vapnik V [著], 张学工 [译]. 统计学习理论的本质. 北京: 清华大学出版社, 2000. 126–127)
- 12 Cristianini N, Shawe-Taylor J [Writer], Li Guo-Zheng, Wang Meng, Zeng Hua-Jun [Translator]. *An Introduction to Support Vector Machines*. Beijing: Publishing House of Electronics Industry, 2004. 30–34  
(Cristianini N, Shawe-Taylor J [著], 李国正, 王猛, 曾华军 [译]. 支持向量机导论. 北京: 电子工业出版社, 2004. 30–34)
- 13 Zheng Shui-Bo, Han Zheng-Zhi, Tang Hou-Jun, Zhang Yong. Application of LS-SVMs in the automobile dynamical system identification. *Journal of Shanghai Jiaotong University*, 2005, **39**(3): 392–395  
(郑水波, 韩正之, 唐厚君, 张勇. 最小二乘支持向量机在汽车动态系统辨识中的应用. 上海交通大学学报, 2005, **39**(3): 392–395)
- 14 Yan Wei-Wu, Zhu Hong-Dong, Shao Hui-He. Soft sensor modeling based on support vector machines. *Journal of System Simulation*, 2003, **15**(10): 1494–1496

(阎威武, 朱宏栋, 邵惠鹤. 基于最小二乘支持向量机的软测量建模. 系统仿真学报, 2003, **15**(10): 1494–1496)




**魏 国** 哈尔滨工业大学教授. 主要研究方向为测控系统、多功能敏感技术和信号处理. 本文通信作者.

E-mail: wg.weiguo@yahoo.com.cn

(**WEI Guo** Professor at Harbin Institute of Technology. His research interest covers measurement and control

system, multifunctional sensing technology, and signal processing. Corresponding author of this paper.)



**刘 剑** 哈尔滨工业大学博士研究生. 主要研究方向为多功能传感器及其信号处理. E-mail: liujianhit@hit.edu.cn

(**LIU Jian** Ph.D. candidate at Harbin Institute of Technology. His research interest covers multifunctional sensor and its signal processing.)



**孙金玮** 哈尔滨工业大学教授. 主要研究方向为传感器技术, 仪器测量及信号处理. E-mail: jwsun@hit.edu.cn

(**SUN Jin-Wei** Professor at Harbin Institute of Technology. His research interest covers sensor technology, testing instruments, and signal processing.)



**孙圣和** 哈尔滨工业大学教授. 主要研究方向为自动化测试、信号与信息处理和光纤传感技术.

(**SUN Sheng-He** Professor at Harbin Institute of Technology. His research interest covers automatic measurement, signal and information processing, and optic fiber sensing technology.)