

# 基于支持向量机的压力传感器校正模型

白鹏<sup>1,2</sup>, 张喜斌<sup>3</sup>, 陈长兴<sup>2</sup>, 朱长纯<sup>1</sup>

(1. 西安交通大学 电子信息工程学院, 陕西 西安 710004; 2. 空军工程大学 理学院, 陕西 西安 710051; 3. 空军工程大学 训练部, 陕西 西安 710051)

**摘要:**针对压力传感器输出特性受温度变化和电压波动影响的问题,提出了应用支持向量机对压力传感器输出特性进行非线性补偿的校正模型。校正模型利用支持向量机具有逼近任意非线性函数的特点,通过建立压力传感器输出特性与其实际电压值之间非线性映射关系的校正模型,实现压力传感器非线性补偿校正。实验结果表明,最大相对波动从22.2%降为0.64%,能有效地消除温度和电压波动的影响,在校正模型的输出端得到期望的压力传感器输出特性。

**关键词:**支持向量机;压力传感器;补偿;校正模型

**中图分类号:** TP 212.9 **文献标识码:** A **文章编号:** 1009-3516(2007)05-0037-04

在测控系统中,压力传感器是重要环节之一。压力传感器的输出特性直接影响测控系统的性能,压力传感器的输出特性受温度变化和电源波动等因素影响。为了改善压力传感器的输出特性,通常的校正模型使用校正方法有查表法、分段线性法和硬件补偿法等<sup>[1]</sup>,这些方法难以做到全程补偿,校正精度也不高,应用受到一定的限制。近年来,由于人工神经网络(Artificial Neural Network, ANN)具有很强的非线性逼近能力,被应用到压力传感器校正模型中<sup>[2-3]</sup>,但是 ANN 训练速度慢、容易陷入局部最小点、存在过拟合现象以及泛化能力较差等局限性使其难以达到预期精度。支持向量机(Support Vector Machine, SVM)是一种新的机器学习方法<sup>[4-5]</sup>,建立在统计学习理论(Statistical Learning Theory, SLT)的基础上,采用结构风险最小化原则,提高了泛化能力,保证全局最优解,能够较好地解决小样本、非线性的问题。因此,将 SVM 引入压力传感器输出特性校正中,提出了一种新的压力传感器输出特性校正模型,实验结果表明,与目前采用的其它校正模型相比,在校正精度和泛化能力上都具有一定的优越性。

## 1 SVM 与压力传感器输出特性校正模型

### 1.1 校正原理

利用 SVM 进行压力传感器输出特性校正的原理见图 1。压力传感器的输出特性为

$$y = f(x, v, t) \quad (1)$$

式中: $x$  为待测目标参量; $t$  为温度量; $v$  为电压波动量; $y$  为压力传感器输出; $p$  为消除了温度变化、电压波动等影响的目标参量。

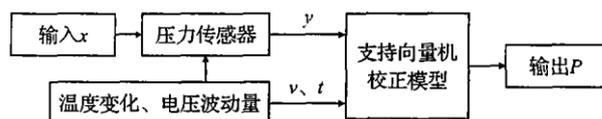


图1 压力传感器输出特性 SVM 校正原理示意图

图1中,若 $y$ 和 $t, v$ 均为 $x$ 单值函数,则式(1)反函数存在,即 $x = f^{-1}(y, t, v)$ ,但反函数相当复杂,很难

收稿日期:2007-01-10

基金项目:陕西省科技计划资助项目(2007K05-05)

作者简介:白鹏(1967-),男,吉林省辽源人,博士(后),主要从事传感器及智能仪器研究。

用具体函数来描述,可用支持向量机校正模型来逼近这种非线性关系。将压力传感器输出  $y$ 、温度变化  $t$ 、电压波动  $v$  等作为支持向量机校正模型的输入,经支持向量机校正模型处理后的输出  $p$  为消除了温度变化、电压波动等影响的被测目标参量。

## 1.2 SVM 校正模型

SVM 用于压力传感器输出特性校正时,其实质是回归问题。进行回归分析时的样本只有一类,所寻求的最优分类面是使所有样本离最优分类面的偏差最小<sup>[6-7]</sup>。支持向量机校正模型的原理是利用非线性映射  $\phi$ ,将输入的数据映射到高维空间,在高维空间变换后进行回归分析,建立输入  $y, t, v$  与输出  $p$  的函数关系。因此,压力传感器输出特性校正模型可定义为如下的 SVM 回归分析问题:

设采集的压力传感器输入和输出所构成的数据样本集为  $\{x_i, y_i\}, i=1, 2, \dots, n$  其中  $x_i \in R^N$ , 为压力传感器的输入;  $y_i \in R$ , 为压力传感器的输出, SVM 校正模型需要求解的回归函数可表示为:

$$f(x) = \omega \cdot \phi(x) + b \quad (2)$$

式中:  $\omega \cdot \phi(x)$  表示向量  $\omega$  与  $\phi(x)$  的内积,  $\omega$  的维数为高维空间维数,  $b \in R$ , 为阈值。

为求解  $\omega$  与  $b$ , 实际应用中,引入松弛变量  $\xi, \xi^* \geq 0$ , 将式(2)转换为式(3), 约束条件为式(4)。

$$\min_{\omega, \xi} \left[ \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi + \xi^*) \right] \quad (3)$$

$$\begin{aligned} y_i - \omega \cdot \phi(x_i) - b &\leq \varepsilon + \xi_i \\ -y_i + \omega \cdot \phi(x_i) + b &\leq \varepsilon + \xi_i^* \end{aligned} \quad i = 1, 2, \dots, n \quad (4)$$

式中:  $C$  为惩罚系数,  $C$  越大表示对训练误差大于  $\varepsilon$  的样本惩罚越大;  $\varepsilon$  规定了回归函数的误差要求,  $\varepsilon$  越小, 回归函数的误差越小, 回归精度越高。

在解式(3)优化问题时,引入 Lagrange 算子  $\alpha$  和  $\alpha^*$ , 将式(3)的优化问题转换为其对偶形式进行求解:

$$\max_{\alpha, \alpha^*} \omega(\alpha_i, \alpha_i^*) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) y_i - \frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle \phi(x_i) \cdot \phi(x_j) \rangle - \sum_{i=1}^n (\alpha_i + \alpha_i^*) \varepsilon \quad (5)$$

约束条件为

$$\sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \quad \alpha_i, \alpha_i^* \in [0, C] \quad (6)$$

式(5)中  $\langle \phi(x_i) \cdot \phi(x_j) \rangle$  为高维空间的点积运算, 函数  $\phi$  是未知的高维函数。SVM 只考虑高维特征空间的点积运算  $K(x_i, x_j) = \langle \phi(x_i) \cdot \phi(x_j) \rangle$ , 不直接使用函数  $\phi$ , 从而有效地解决了这个问题, 称  $K(x_i, x_j)$  为核函数, 满足 Mercer 条件的对称函数均可作为核函数, 常用的核函数有: 线性核函数、多项式核函数、径向基核函数(RBF)等。

利用式(6)的约束条件,求得  $\alpha$  值,有式(7)。确定回归函数为式(8)。

$$\omega = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \phi(x_i) \quad (7) \quad f(x) = \omega \cdot \phi(x) + b = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (8)$$

根据 Karush - Kuhn - Tucker 条件<sup>[5]</sup>, 计算后有:

$$\begin{cases} b = y_i - \varepsilon - \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x), \alpha_i \in [0, C] \\ b = y_j + \varepsilon - \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x), \alpha_i^* \in [0, C] \end{cases} \quad (9)$$

## 1.3 SVM 校正模型的训练和检验

用已经获得的数据样本对 SVM 校正模型进行训练和检验, 流程如图 2 所示。

首先,对 SVM 校正模型进行训练。确定一组 SVM 校正模型参数,包括 SVM 类型、核函数、惩罚因子  $C$  及损失函数  $\varepsilon$  的数值等。然后用一部分样本对 SVM 校正模型进行训练,确定  $\alpha_i$  和  $b$ 。当输出与期望值误差满足要求时,训练结束;如果不满足要求,根据误差,重新调整 SVM 校正模型参数。用另一部分样本对 SVM

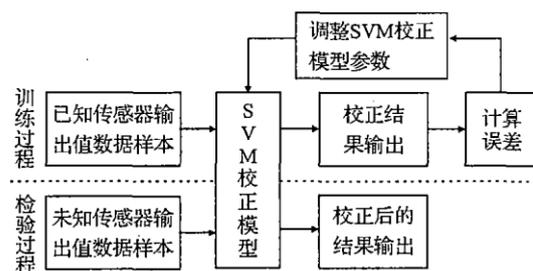


图2 SVM 校正模型训练和检验流程图

校正模型进行检验,如果检验满足误差要求,SVM 校正模型的参数被最终确定,检验过程结束。

### 1.4 自适应参数调节

式(3)中的惩罚系数  $C$  直接影响误差,而  $C$  值的选择很难用理论方法确定。惩罚系数  $C$  的自适应参数调节准则如下:①检查某特定加权的修正是否确实减小了误差;②如果产生了超调,那么  $C$  就减小;③若连续几步迭代都是降低误差, $C$  值就应该增加一个量。

$C$  的增加量最好是一个常数, $C$  的减小量应按几何规律,自适应关系见式(10)。

$$\Delta C = \begin{cases} +a & \text{如果连续 } \Delta e < 0 \\ -bC & \text{如果 } \Delta e > 0 \\ 0 & \text{其他} \end{cases} \quad (10)$$

$\Delta e$  为每次迭代误差变化,  $a, b$  为适当常数。实验经验表明,此方法对于确定校正模型中惩罚系数  $C$  很有效,惩罚系数  $C$  与训练平均误差、最大误差的关系如表 1 所示。

根据表 1 的数据,确定惩罚系数  $C$  为 2.0,损失函数  $\varepsilon$  取 0.01。

表 1 惩罚系数  $C$  与误差关系表

$C$	平均误差(%)	最大误差(%)
0.1	0.80	3.07
0.5	0.77	2.09
1.0	0.62	1.80
2.0	0.49	1.67
3.0	0.39	1.49
4.0	0.32	1.42
6.0	0.35	1.32
8.0	0.35	1.18
10.0	0.31	1.09
15.0	0.30	0.89
20.0	0.23	0.71

## 2 实验及分析

### 2.1 压力传感器标定

压力传感器输出  $y$  不仅与被测压力  $x$  有关,且与工作温度和电源波动有关,压力传感器输出信号  $u = f(p, u_t, \gamma)$ ,  $u_t$  为温度传感器输出,  $\gamma$  为电源波动,  $p$  为输入压力。表 2 为 CYJ-101 型压力传感器标定数据表,图 3 为温度变化时压力传感器的输出特性曲线。

表 2 压力传感器标定数据表

压力标定值 / $10^4$ Pa	$T = 22^\circ\text{C}$			$T = 44^\circ\text{C}$			$T = 70^\circ\text{C}$		
	$U/\text{mV}$	$U_t/\text{mV}$	$\gamma(\%)$	$U/\text{mV}$	$U_t/\text{mV}$	$\gamma(\%)$	$U/\text{mV}$	$U_t/\text{mV}$	$\gamma(\%)$
0.00	0.00	290.50		0.00	542.20		0.00	826.10	
1.00	25.27	268.80		16.12	517.80		11.10	800.20	
2.00	44.00	247.20	3.00	33.25	493.00	-1.00	28.10	769.10	-3.00
3.00	62.72	224.50		50.42	465.30		44.93	740.00	
4.00	81.40	206.00		67.62	435.60		61.38	706.20	
5.00	100.12	184.40		84.73	410.80		78.57	669.30	

从表 2 可知,对同一标准压力标定值输入,压力传感器输出电压  $u$  随温度变化及电源波动而变化,最大相对波动  $\alpha = |\Delta y|_{\max}/y_{\text{FS}}$ ,  $|\Delta y|_{\max}$  为压力传感器输出最大绝对误差,  $y_{\text{FS}}$  为在温度为  $22^\circ\text{C}$ ,  $\gamma = 0$  时压力传感器满量程输出,  $y_{\text{FS}} = 97.12 \text{ mV}$ ,根据表 2 中数据可求得  $|\Delta y|_{\max} = 100.12 - 78.57 = 21.55 \text{ mV}$ ,  $\alpha = 22.2\%$ 。可见,该压力传感器的输出电压受温度变化及电压波动等因素影响很大,需对其校正以消除影响。

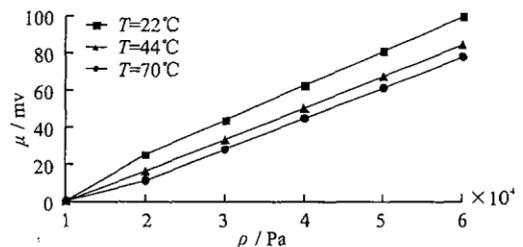


图 3 温度变化时压力传感器的输出特性曲线

### 2.2 校正效果比较

用 Matlab 语言编制训练程序,将  $u, u_t, \gamma$  作为支持向量机校正模型的输入,  $p$  作为输出,SVM 校正模型处理后的结果如表 3 所示。

表 3 SVM 校正模型处理后的结果表

$T/^\circ\text{C}$	$\gamma(\%)$	标定值	修正值								
22	3.00	1.00	1.029	2.00	1.973	3.00	2.997	4.00	3.971	5.00	5.002
44	-1.00	1.00	1.012	2.00	1.987	3.00	3.002	4.00	4.032	5.00	4.996
70	-3.00	1.00	0.990	2.00	2.020	3.00	2.991	4.00	4.011	5.00	5.003

表3中,处理后最大相对波动为,  $\alpha' = |\Delta y|_{\max} / y_{FS}, y_{FS} = 5 \times 10^4 \text{ Pa}$ , 根据表3中数据可求得  $|\Delta y|_{\max} = 4.032 - 4 = 0.032 \times 10^4 \text{ Pa}$ , 求得  $\alpha = |\Delta y|_{\max} / y_{FS} = 0.64\%$ 。校正模型处理前的最大相对波动  $\alpha = 22.2\%$ , 处理后的  $\alpha' = 0.64\%$ 。可见,通过校正模型处理后,在相同的温度变化和电源波动下,压力传感器的输出特性得到改善,稳定性可大大提高。

### 3 结论

SVM作为一种处理问题的新方法,已经广泛应用到传感器信息处理、信号处理、自动控制、通信等许多领域,本文的实验结果表明,压力传感器经过校正模型处理后,其输出特性得到了改善。

实际应用中,许多传感器都受温度变化、电压波动等多种因素的影响,因此该方法在解决此类问题上有明显效果。

#### 参考文献:

- [1] 刘君华. 现代检测技术与测试系统设计[M]. 西安:西安交通大学出版社,1999.
- [2] 朱庆保. 用于传感器非线性误差校正的新颖神经网络[J]. 软件学报,1999,10(12):1298-1303.
- [3] 杨延西, 刘 丁. 基于 ANFIS 的温度传感器非线性校正方法[J]. 仪器仪表学报,2005,26(5):511-514.
- [4] Vapnik V. Statistical Learning Theory[M]. New York:Springer,1998.
- [5] Vapnik V N. Learning hidden information: SVM+[J]. 2006 IEEE International Conference on Granular Computing,2006:22-22.
- [6] Chang Chih-Chung, Lin Chih-Jen. LIBSVM. a library for support vector machines[EB/OL]. [2006-01-16]. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [7] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报,2000,26(1):32-42.

(编辑:姚树峰)

## A Correction Model of Pressure Sensor Based on Support Vector Machine

BAI Peng<sup>1,2</sup>, ZHANG Xi-bin<sup>3</sup>, CHEN Chang-xing<sup>2</sup>, ZHU Chang-chun<sup>1</sup>

(1. School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. The Science Institute, Air Force Engineering University, Xi'an 710051, China; 3. Dept. of Training, Air Force Engineering University, Xi'an 710051, China)

**Abstract:** In view of characteristics of pressure sensor affected by temperature changes and voltage fluctuation, a correction model of pressure sensor is presented based on Support Vector Machine. The approximate ability of the SVM to any nonlinear function is utilized to drill the correction model, so as to enable it to be setup at different temperatures and voltage fluctuation, thus allowing the sensor output to be in a nonlinear mapping relation to the voltage values the sensor actually sensed. The experimental results show that maximum relative fluctuation comes down from 22.2% to 0.64%, and the model can not only eliminate the influence from temperature and voltage fluctuation, but also can obtain the expected linear output from the output terminal of correction model.

**Key words:** Support Vector Machine; pressure sensor; compensation; correction model