

文章编号:1000-8055(2011)06-1274-08

多维传感器标定的支持向量机复合式方法

马迎坤, 张希农

(西安交通大学 航天航空学院 强度与振动教育部重点实验室, 西安 710049)

摘 要: 提出了多维传感器标定的支持向量机复合式标定方法, 解决了多维传感器标定中的参数不确定性和耦合非线性因素. 对一个多维传感器进行了支持向量机复合标定的仿真研究, 将这一方法应用到六维力传感器测量系统的标定试验中. 结果表明, 与传统标定方法相比, 支持向量机复合标定的方法在不增加数据样本的情况下, 能够显著提高传感器标定的精度; 同时也比纯支持向量机标定有更强的泛化能力, 复合标定的模型还可以为传感器的设计提供依据.

关 键 词: 支持向量机; 复合标定; 多维传感器; 耦合; 非线性

中图分类号: TP183

文献标志码: A

Support vector machine complex method for multi-dimensional sensor calibration

MA Ying-kun, ZHANG Xi-nong

(The Key Laboratory of Strength and Vibration of Ministry of Education,
School of Aerospace, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A support vector machine (SVM) complex calibration approach was proposed to solve the parameters uncertainty and coupling nonlinearity. The simulation of the calibration of a multi-dimensional sensor was conducted by the SVM complex calibration method, which was then utilized to calibrate a six-dimensional force sensor system. It can be seen from the results that, as compared with other traditional calibration methods, the SVM complex calibration method can improve the calibration accuracy significantly, without increasing data samples; additionally, the complex calibration method also has better generalization performance in comparison with the SVM black box modeling, indicating that it can provide a basis for the design of sensors.

Key words: support vector machine; complex calibration; multi-dimensional sensor; coupling; nonlinearity

在工程测试中, 多维传感器得到了越来越广泛的应用. 尽管其输出信号通常被设计成与被测物理量成线性关系, 但是实际测量时存在着测量系统的误差、外界环境的干扰、传感器元件的老化等诸多不确定因素的影响, 且其众多的输入输出通道之间还存在着明显的维间非线性耦合, 导致传感器实际输出信号与被测物理量之间呈复杂的

非线性关系. 为了保证测试结果的精度, 需要对使用的传感器进行标定, 以确定被测物理量与传感器输出信号之间的实际关系.

传统的标定方法中, 采用数据拟合标定传感器的方法需耗费大量时间, 且无法描述传感器的非线性因素, 精度不高^[1-2]; BP(back propagation)神经网络方法具有逼近任意非线性函数的能力,

收稿日期: 2010-05-11; 修订日期: 2010-09-07

基金项目: 国家自然科学基金(10772142)

作者简介: 马迎坤(1985—), 男, 山东枣庄人, 博士生, 从事智能结构振动控制、动力学建模等领域的研究工作.

但是其网络规模较大,网络学习周期长,由于完全依赖样本数据,因而推广泛化能力也比较差^[3-6].支持向量机(SVM)理论是基于统计学习理论发展起来的一种最新的数据挖掘算法,相比神经网络有更大的优越性^[6].本文将支持向量机理论引入到多维传感器的输入-输出非线性特性的标定过程中,与传统方法相结合,给出了基于支持向量机理论的复合标定方法,将这一方法应用于一个简单的多输入多输出传感器的标定仿真实验中,验证此方法的综合性能,并进一步对一个十字梁结构的六维力传感器进行了基于支持向量机的复合式标定试验研究.

1 支持向量机及其回归算法

支持向量机方法是首先从解决模式识别问题发展起来的,支持向量回归机(SVR)是模式识别问题中得到的结果在回归情况下的推广,在回归情况下引入不敏感损失函数 ϵ ,用结构风险最小化原则构建线性回归估计的优化问题.假设对于给定的训练数据 $(x_1, y_1), \dots, (x_l, y_l) \in \mathbf{R}^n \times \mathbf{R}$,用线性函数: $f(x) = (w \cdot x) + b$ 拟合数据,其优化问题为^[7]

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \hat{\xi}_i) \\ \text{s. t.} \quad & \begin{cases} (w^T x_i + b) - y_i \leq \epsilon + \xi_i \\ y_i - (w^T x_i + b) \leq \epsilon + \hat{\xi}_i \\ \xi_i, \hat{\xi}_i \geq 0, \quad i = 1, 2, \dots, N \end{cases} \end{aligned} \quad (1)$$

ξ_i 和 $\hat{\xi}_i$ 是允许拟合误差的松弛因子,常数 C 是对超出误差 ϵ 的样本的惩罚程度,起平衡函数泛化能力和精度的作用.

对于非线性回归,需通过事先选择的非线性映射将输入向量映射到一个高维特征空间,在这个特征空间中构造最优决策超平面.其求解仅涉及到向量的内积运算,因此为了在特征空间中构造超平面,并不需以显式的形式来考虑特征空间,只需知道这个空间中的内积运算. SVM 通过引入核函数 $\mathbf{K}(x, x')$ 实现高维特征空间的内积运算,从而通过式(2)所示 ϵ -支持向量回归机在高维空间中构造决策超平面^[7]

$$\begin{aligned} \min W(a) = & \epsilon \sum_{i=1}^l (a_i + a_i^*) - \sum_{i=1}^l y_i (a_i - a_i^*) + \\ & \frac{1}{2} \sum_{i,j=1}^l (a_i - a_i^*) (a_j - a_j^*) \mathbf{K}(x_i, x_j) \quad (2) \\ \text{s. t.} \quad & \begin{cases} \sum_{i=1}^l (a_i - a_i^*) = 0 \\ a_i, a_i^* \in [0, C] \end{cases} \end{aligned}$$

对应的决策函数的形式为

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) \mathbf{K}(x_i, x) + b$$

其中

$$b = y_j - \sum_{i=1}^l y_i a_i \mathbf{K}(x_i, x_j), \quad j \in \{j \mid 0 < a_j^* < C\}.$$

本文使用的是径向基核函数(RBF 核函数),其形式为 $\mathbf{K}(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$.

但是在 ϵ -支持向量回归机中,需要事先确定参数 ϵ , 然而确定合适的 ϵ 并不容易,所以又引入能够自动计算 ϵ 的 ν -支持向量回归机如式(3)所示^[7]

$$\begin{aligned} \min W(a) = & - \sum_{i=1}^l y_i (a_i - a_i^*) + \\ & \frac{1}{2} \sum_{i,j=1}^l (a_i - a_i^*) (a_j - a_j^*) \mathbf{K}(x_i, x_j) \quad (3) \\ \text{s. t.} \quad & \begin{cases} \sum_{i=1}^l (a_i - a_i^*) = 0 \\ 0 \leq a_i, a_i^* \leq \frac{C}{l}, \quad i = 1, \dots, l \\ \sum_{i=1}^l (a_i + a_i^*) \leq C\nu \end{cases} \end{aligned}$$

在式(3)中,如果解 $a^{(*)} = (a_1, a_1^*, \dots, a_l, a_l^*)^T$ 对应的分量 $a_i \neq 0$ 或者 $a_i^* \neq 0$, 则对应的输入 x_i 即为支持向量,只有属于支持向量的样本才对训练结果有影响; ν 的意义是错误样本的个数所占总样本点数份额的上界,同时又是支持向量的个数所占总样本数份额的下界,所以大体可以用 $\nu(0 \leq \nu \leq 1)$ 来控制支持向量个数或者错误样本点的个数,这就为 ν 值的选取提供依据,所以,从这个意义上说, ν -支持向量回归机优于 ϵ -支持向量回归机.

从上述算法可以看出, SVM 是把输入空间映射到某一个高维空间(特征空间),从而把原空间中的非线性问题转化为特征空间的线性问题,由于在高维特征空间只需要做训练样本间的内积计算,因此计算的复杂度较神经网络也大大降低;另外,由于支持向量机求解的最优化问题是凸优化问题,得到的是唯一的全球最优解而不像神经网络训练那样容易陷入局部极小点; SVM 是基于结构风险最小化原则,最小化的是推广误差的上界,从而通过在模型的复杂性和训练误差之间寻求平衡点,得到一个最优的网络结构,较好地解决了过学习和欠学习问题,比神经网络有更好地推广泛化能力.

2 传感器标定仿真

本节对一个简单多维传感器进行了基于支持向量机的复合标定的仿真研究,详细描述了支持向量机复合标定的过程,并将标定的效果同其他方法进行了比较,以检验支持向量机复合式标定方法在传感器标定中的综合性能。

假设一个二维输入、二维输出的传感器,其被测物理量与传感器输出信号间的关系表示为

$$\mathbf{p} = \mathbf{M}\mathbf{U} + \boldsymbol{\varepsilon}(u) \quad (4)$$

其中 $\mathbf{p} = [p_1, p_2]^T$, $\mathbf{U} = [u_1, u_2]^T$, $\boldsymbol{\varepsilon}(u)$ 表示维间输出的非线性耦合项, $\mathbf{M}$ 表示标定系数矩阵。假定此传感器实际输入输出特性依据下式:

$$\mathbf{M} = \begin{bmatrix} m_{11} & m_{12} \\ m_{21} & m_{22} \end{bmatrix} = \begin{bmatrix} 120 & 1 \\ 8 & 140 \end{bmatrix},$$

$$\boldsymbol{\varepsilon}(u) = \begin{bmatrix} \varepsilon_1(u) \\ \varepsilon_2(u) \end{bmatrix} = \begin{bmatrix} 0.8 u_1 u_2^2 \\ 0.5 u_1^2 u_2 \end{bmatrix} \quad (5)$$

传感器输出信号 $u_1 \in [0, 5\text{V}]$, $u_2 \in [0, 5\text{V}]$ 。测量样本数据通过给定 20 组正态随机分布的传感器输出信号 (u_1, u_2), 然后根据式(4)和式(5)计算产生。假定只考虑多维传感器的维间线性耦合, 则其输入输出关系表示为以下形式:

$$\bar{\mathbf{p}} = \bar{\mathbf{M}}\mathbf{U} \quad (6)$$

根据式(6), 对测量样本采用最小二乘数据拟合, 可得标定系数矩阵为

$$\bar{\mathbf{M}} = \begin{bmatrix} 120.74 & 8.50 \\ 10.71 & 142.15 \end{bmatrix} \quad (7)$$

将标定系数矩阵(7)代入到式(6)中, 输出电压测量信号 u_1, u_2 均取 $[0:0.01:5](\text{V})$, 求得式(6)的输入输出变化曲线, 并同由式(4)得到的真实曲线进行比较。

图1给出了由标定系数矩阵通过式(6)预测的物理量同输出信号的关系, 以及实际传感器的输入输出变化曲线。可以看出, 仅由标定矩阵预测的结果和真实值存在明显误差, 而且在高幅值测量区域, 误差还会增大, 表1给出了用最小二乘拟合标定的均方误差。而且通过数据仿真发现增大样本数目对于减小最小二乘拟合均方误差的效果并不明显。

将最小二乘拟合得到的结果即式(7)作为知识基模型, 即 $f_1(u)$, 进一步利用支持向量机对存在的模型误差进行建模, 训练集的输入部分为传感器的输出电压信号 $\mathbf{U}$, 训练集的输出部分为知识基模型的预测值同传感器实际输入输出模型间




图1 标定系数矩阵预测结果比较

Fig.1 Results of two channels predicted with coefficient matrix compared with true values

表1 几种方法标定结果的均方误差比较

Table 1 Comparison of 4 methods' mean square error

最小二乘 拟合标定		支持向量机 复合式标定		支持向量纯 黑箱标定		神经网络 复合式标定	
p_1	p_2	p_1	p_2	p_1	p_2	p_1	p_2
349.4	148.5	1.118	0.468	499.5	312.6	62.12	12.67

的误差 ($f_2(u) = \mathbf{p} - \bar{\mathbf{p}}$). 训练数据仍采用计算标定矩阵时的 20 组随机分布的传感器输出信号及其对应的输入载荷。支持向量机参数 C 和 γ 的选择对支持向量机训练模型的准确性有很大影响, 所以参数选择是应用支持向量机标定过程中耗时最长的工作。参数选择的方法有很多种, 本文采用网格搜索加 10 倍交叉验证的方法确定支持向量机训练的参数: 即将训练样本分为 10 等份, 轮流以 9 份作为训练样本, 另外 1 份做测试, 记录 10 次结果的均方误差, 将 C 和 γ 在 $[0.001, 1.000]$ 以 2 的指数倍步长遍历一遍, 选取误差最小的一对作为训练参数, 这样就可以得到平稳可靠的训练模型。最终选取 $C=488$ 的 ν -支持向量回归机, 核

参数 $\gamma=0.081$ 的径向基核函数,训练得到误差的支持向量机模型.将支持向量机模型与知识基模型即标定矩阵组合,即得到多输入多输出传感器标定的支持向量机复合模型.同样对输入信号序列 u_1, u_2 取 $[0:0.01:5](V)$,图 2 给出了通过支持向量机复合模型标定的传感器输入输出特性曲线,同图 1 用标定矩阵确定的特性曲线比较,可以明显看出用复合模型确定的输入输出特性曲线与真实的特性曲线更吻合,表 1 给出了复合模型标定的均方误差,这些结果说明采用支持向量机复合模型方法可以大大提高多输入多输出传感器的标定精度.




图 2 支持向量机复合模型标定结果与真实值比较

Fig. 2 Result of two channels predicted with SVM complex method compared with true values

此外,还采用支持向量机黑箱建模的方法标定了特性曲线:也选用 ν -支持向量回归机,以传感器的输出电压信号 $\mathbf{U}$ 作为训练集的输入部分,而直接以传感器的输入载荷 $\mathbf{p}$ 作为训练集的输出部分,也以上述 20 组随机分布的样本数据作为训练集,取交叉验证的最优参数 $C=500, \gamma=0.012$,训练得到支持向量机的黑箱模型,并对同样的测

量序列进行标定,图 3 给出了用支持向量机黑箱模型标定的特性曲线,其均方误差也在表 1 中列出,可以看出,在只有少量样本集的情况下,仅用最小二乘拟合或者仅用支持向量机黑箱建模的方法其标定精度都远不如支持向量机复合模型.




图 3 支持向量机黑箱建模标定结果与真实值比较

Fig. 3 Result of two channels predicted with pure SVM compared with true values

为了验证支持向量机对比神经网络的优越性,本节还采用神经网络复合式标定的方法确定了传感器的特性曲线如图 4 所示,其标定误差见表 1.可见神经网络复合式标定方法的精度高于仅采用数据拟合或者支持向量机的单一方法;但是要低于基于支持向量机的复合式标定方法的精度.由于神经网络是基于经验风险最小化的原则,所以容易往往得到的是局部最优解,在仿真中也可以发现:神经网络几乎可以趋近于任意的训练精度,但是选取的训练精度越高,标定预测的精度反而会大大下降,这就反映出支持向量机在泛化能力上的优势了;此外,神经网络的隐含层数和节点数决定了网络的规模,网络的规模与其性能密切相关,网络规模小,则逼近能力不足,容易导致欠拟合,但是如果规模过大,则会出现过拟合,表

现为推广泛化能力的下降,因此确定网络规模是神经网络设计的一个重要内容,但是如何确定网络规模又缺乏理论依据,所以通常只能靠经验来确定网络规模,且神经网络的模型结构形式较为复杂,而支持向量机训练得到的模型仅仅是由核函数和支持向量组成的结构体,形式上非常简单;由于本身算法的原因,神经网络还存在网络模型不稳定的问题,例如神经网络在初始化网络权值的时候是随机确定的,因此在仿真时就会出现在相同的训练样本和训练参数的情况下,每一次用神经网络训练得到的模型都是不确定的,预测误差也差别很大,而支持向量机在确定训练样本和训练参数后,训练模型就确定了,所以稳定性强。综合上面的结果可以说明复合式标定方法优于传统单一的标定方法;而在复合式标定方法中,基于支持向量机的复合式方法优于神经网络复合式方法。




图4 神经网络复合标定结果与真实值比较

Fig. 4 Result of two channels predicted with neural networks complex method compared with true values

3 六维力传感器标定试验

应用第2节所述的方法,研究一个十字梁结构六维力传感测量系统的标定问题。六维力传感

器是一种能够同时感知空间任意力系的三维力分量和三维力矩分量的典型的多维传感器。由于它能够测量结构连接处的全力信息,所以广泛应用于风洞试验中试件边界力测量、飞机试验台测量、火箭发动机受力测量、汽车车轮受力测量、机器人腕力测量、宇宙空间站对接仿真以及其他有关的自动控制等系统中^[8-10]。在六维力传感测量系统中,力敏元件是以感知结构弹性变形为基础的应变式传感器,其结构外形如图5所示,这是一个整体制成的框架,框架中心连接到被测试验件上,作用在中心圆台上的力或者力矩通过4根主梁传到框架的四壁,框架的四壁各切两条长缝,使其成为一个浮动梁,浮动梁薄且高,在自身平面内刚度很大,在垂直于板平面的弯曲刚度及扭转刚度则很小,通过测量主梁受力变形产生的弹性应变就可知道作用在传感器上各分力的大小。弹性体材料为不锈钢(2Cr13),材料特性及几何尺寸参数见文献[11]。该传感器的结构设计承载能力为: $F_x=F_y=F_z=800\text{ N}$, $M_x=M_y=465\text{ N}\cdot\text{m}$, $M_z=450\text{ N}\cdot\text{m}$,弹性体上共粘贴32个应变片,组成8个惠斯通电桥输出,具体贴片位置如图6所示。




图5 十字梁结构传感器外形

Fig. 5 Sketch of cross beam sensor




图6 弹性体贴片位置及组桥示意图

Fig. 6 Strain gauges position and bridge diagram

3.1 标定试验

静力标定试验加载设备采用力控精度为 1% 的 500 kN 万能结构试验机. 传感器输入力向量为 $\mathbf{F} = [F_x, F_y, F_z, M_x, M_y, M_z]^T$, 输出电压信号向量为 $\mathbf{U} = [u_1, u_2, \dots, u_8]^T$. 根据标定原理, 设计了 6 次线性不相关的单载荷加载, 即 F_x, F_y 和 F_z 分别按等间隔步长 (100 N) 加载到 800 N, 然后卸载; M_x, M_y 分别按等间隔步长 (93 N·m) 依次加载至 465 N·m, 然后卸载; M_z 按等间隔步长 (90 N·m) 加载至 450 N·m 并卸载^[8]. 载荷由试验机按照设定程序自动施加, 在每个载荷步下同步测量记录实际载荷值以及六维力传感器的 8 个输出电压值, 共获得 78 组标定试验数据. 则传感器的输入输出特性的线性部分可以表示为 $\mathbf{F}_1 = \mathbf{M}\mathbf{U}$, $\mathbf{M}$ 为标定系数矩阵, 展开后表示为

$$\mathbf{M} = \begin{bmatrix} -133.25 & 327.66 & -96.68 & -42.81 & -54.64 & 63.24 & -44.74 & 25.13 \\ -410.79 & 572.04 & -734.58 & 528.01 & 131.70 & -138.92 & 100.01 & -128.41 \\ 155.93 & -141.09 & 130.49 & -127.06 & -255.72 & 31.86 & -254.66 & 26.64 \\ 423.70 & -376.25 & 337.67 & -333.22 & -455.72 & 400.71 & -434.34 & 500.45 \\ -749.51 & 711.32 & -672.31 & 685.98 & 388.99 & -324.86 & 245.04 & -326.02 \\ 233.94 & -75.55 & 210.38 & -55.64 & -94.38 & 104.37 & -100.96 & 90.12 \end{bmatrix} \quad (9)$$

将式(9)的标定系数矩阵代入式(8), 即可由传感器的输出电压测量值计算每个载荷步下所施加的载荷分量, 以 F_x 为例, 其单独加载标定结果如图 7 所示; 将最小二乘法拟合标定的结果和载荷的实测值进行比较, 检验标定结果的精度, 6 次加载按时间顺序组成序列, 与标准载荷的误差如图 8 所示. 从图 7 和图 8 可以看出, 对于每种单分量 (其他各分力为零) 加载工况, 用最小二乘拟合得到的标定系数矩阵标定, 其他各个分力与实际值 (应为 0) 间存在明显偏差. 这说明, 六维力传感器的各维之间存在非线性耦合, 依靠最小二乘法得到的标定矩阵仅能描述各维之间的线性耦合, 即使采用更多的样本数据来拟合标定矩阵, 也不能描述这种非线性耦合特性, 故难以达到理想的标定精度.

3.3 支持向量机复合式标定方法

六维力传感器维间非线性耦合的形式是难以描述的, 为了预测这部分非线性特性, 需要用到非参数化的方法. 根据前两节描述的支持向量机复合式标定方法, 将复合标定的思想应用到对六维力传感器的标定上. 根据式(4) $\mathbf{p} = \mathbf{M}\mathbf{U} + \boldsymbol{\varepsilon}(u)$, 将

$$\begin{bmatrix} F_x \\ F_y \\ F_z \\ M_x \\ M_y \\ M_z \end{bmatrix} = \begin{bmatrix} m_{11} & m_{12} & \cdots & m_{18} \\ m_{21} & m_{22} & \cdots & m_{28} \\ \vdots & \vdots & & \vdots \\ m_{61} & m_{62} & \cdots & m_{68} \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_8 \end{bmatrix} \quad (8)$$

根据前述的支持向量机复合标定方法, 由试验数据确定标定系数矩阵 $\mathbf{M}$ 的各个元素, 然后通过支持向量机的方法预测其误差, 最后将两者结合成支持向量机复合模型完成传感器的标定.

3.2 确定标定系数矩阵

依据获得的 78 组标定试验数据, 采用最小二乘法来拟合确定式(8)中的标定系数矩阵 $\mathbf{M}$, 计算结果为




图 7 单独加载 F_x 的标定矩阵预测结果

Fig. 7 Predicted results of single load F_x with coefficient matrix

3.2 节得到的六维力传感器的标定矩阵作为知识库模型 $\mathbf{M}\mathbf{U}$, 而维间非线性耦合误差 $\boldsymbol{\varepsilon}(u)$ 则由支持向量机进行建模预测, 以 78 组加载段样本数据作为支持向量机训练集, 输出电压信号 $\mathbf{U}$ 为训练集的输入部分, 维间非线性耦合误差为训练集的输出部分, 仍采用 ν -支持向量回归机进行建模, 通过交叉验证选择模型参数为 $C=117, \gamma=158$, 训




图8 最小二乘法标定与实际载荷误差

Fig. 8 Error between the predicted results with coefficient matrix and true values


图9 单独加载 F_x 的支持向量机复合标定结果

Fig. 9 Predicted results of single load F_x with SVM complex method

练得到支持向量机模型. 将训练得到的网络模型与标定矩阵结合, 对每种标定工况下的载荷分量进行计算, 以 F_x 为例, 其标定结果如图9所示. 将支持向量机复合模型标定的结果和载荷的实测值进行比较, 检验标定结果的精度, 6次加载按时间顺序组成序列, 与标准载荷的误差如图10所示.

从图9可以看出, 在单独施加力分量 F_x 时, 通过支持向量机复合标定方法标定的结果与实际情况吻合, 即分量 F_x 完全按照加载曲线, 而其他力分量非常接近于零. 其他力分量的标定结果与 F_x 的情况完全一致. 从图10也可以看出这一点, 即仅在 F_y, M_y 两个分量的一个加载步(此加载步为力和力矩载荷转化的一个加载步)中出现了较大的偏差(也分别仅有 1.9 N 和 1.8 N·m), 其余分量的误差接近于零.

表征多维力传感器的静态测试误差有两项指标: 表示测量精度的 I 类误差, I 类误差 = $\max(|\text{负载值} - \text{测量值}|) / \text{满量程值}$; 以及表示耦合程度的 II 类误差, 反映的是在该分量未施加力




图10 支持向量机复合标定误差

Fig. 10 Error between the predicted results with SVM complex method and true values

(或力矩)的情况下, 由于其他分量施加了力(或力矩)而引起在这一分量上出现的干扰, 其算法为 II 类误差 = $\max(|\text{其他方向测得值}|) / \text{该方向满量程值}$ [12].

表2 静态标定性能指标比较

Table 2 Errors of calibration

输出分量	满量程值	I 类误差/%		II 类误差/%	
		最小二乘拟合	支持向量复合标定	最小二乘拟合	支持向量复合标定
F_x/N	800	0.6	0.001	2.7	0.001
F_y/N	800	1.4	0.225	5.1	0.001
F_z/N	800	0.6	0.001	1.3	0.225
$M_x/(\text{N} \cdot \text{m})$	465	3.6	0.001	8.5	0.001
$M_y/(\text{N} \cdot \text{m})$	465	0.7	0.366	4.3	0.001
$M_z/(\text{N} \cdot \text{m})$	450	1.1	0.001	1.2	0.001

从图9、图10和表2的结果均可看出支持向量机复合标定的方法可有效补偿传感器维间非线性耦合误差,从而大大提高了标定精度.在同等数据样本的情况下,合理选择参数的支持向量机复合标定在标定精度上有明显的优势.

4 结 论

本文引入了支持向量机的思想,提出了多维传感器的支持向量机复合式标定的方法,给出了标定过程和具体步骤,进行了多维传感器标定的仿真,并针对六维力传感器样机,利用标定试验获得的样本数据,采用了支持向量机复合标定的方法完成了标定.评价标定方法优劣主要看标定的精度和方法的可操作性;仿真研究与标定试验的结果均表明,与传统的标定方法相比,支持向量机复合模型具有更高的泛化性能,因而只依赖少量的样本就能够有效地补偿传感器维间复杂非线性特性导致的标定误差,从而在不增加样本数据的情况下,显著提高标定精度;支持向量机复合标定方法得到的模型与神经网络方法得到的模型相比规模更小,形式简单,且稳定性高,使得模型可以方便地导出和使用;而且,支持向量机复合模型包含知识基模型,相比于黑箱模型,除了精度高,还可以反映维间的线性耦合程度,可以对六维力传感器的设计提供依据.

参考文献:

- [1] 郑红梅,刘正士,王勇. 机器人六维腕传感器标定方法和标定装置的研究[J]. 计量学报, 2005, 26(1): 43-45, 85.
ZHENG Hongmei, LIU Zhengshi, WANG Yong. Study on the method of dynamic characteristic calibration of the 6-axis wrist force sensor for robot[J]. Acta Metrologica Sinica, 2005, 26(1): 43-45, 85. (in Chinese)
- [2] 尹伟,李华星. 压力传感器静态校准模型研究[J]. 测控技术, 2006, 25(4): 20-25.
- YIN Wei, LI Huaxing. Research of static calibration models for pressure sensors [J]. Measurement & Control Technology, 2006, 25(4): 20-25. (in Chinese)
- [3] 姚建涛,侯雨雷,牛建业,等. 大量程预紧式六维力传感器及静态标定研究[J]. 仪器仪表学报, 2009, 30(6): 1233-1239.
YAO Jiantao, HOU Yulei, NIU Jianye, et al. Large range prestressed six-axis force sensor and study on static calibration[J]. Chinese Journal of Scientific Instrument, 2009, 30(6): 1233-1239. (in Chinese)
- [4] 张立明. 人工神经网络的模型及其应用[M]. 上海: 复旦大学出版社, 2003.
- [5] Cao M, Wang K W. A hybrid neural network approach for the development of friction component dynamic model[J]. Journal of Dynamic Systems, Measurement, and Control, 2004, 126(3): 144-153.
- [6] Dong Y F, Li Y M, Lai M, et al. Nonlinear structural response prediction based on support vector machines[J]. Journal of Sound and Vibration, 2008, 311(3-5): 886-897.
- [7] Vapnik V. Statistical learning theory[M]. New York: John Wiley, 1998.
- [8] 张崇峰. 空间对接六自由度半物理仿真的研究[J]. 航天控制, 1999(1): 70-74.
Zhang C F. Study on six-degree-of-freedom simulation for docking[J]. Aerospace Control, 1999(1): 70-74. (in Chinese)
- [9] Doebellin E O. Measurement system applications and design[M]. New York: McGraw Hill, 1985: 25-28.
- [10] Diddens D, Reynaerts D, Brussel H V. Design of a ring-shaped three-axis micro force/torque sensor[J]. Sensors and Actuators A: Physical, 1995, 46(1-3): 255-231.
- [11] 陈胜来. 基于神经网络的多分力测试系统杂交建模分析方法研究[D]. 西安: 西安交通大学, 2008.
CHEN Shenglai. A study of hybrid modeling for multi-axis force measuring system based on artificial neural network [D]. Xi'an: Xi'an Jiaotong University, 2008. (in Chinese)
- [12] 徐科军,李成. 多维腕力传感器静态解耦的研究[J]. 合肥工业大学学报, 1999, 22(2): 1-6.
XU Kejun, LI Cheng. Research on static decoupling for multi-dimensional wrist force sensor[J]. Journal of Hefei University of Technology, 1999, 22(2): 1-6. (in Chinese)