

## 基于高斯过程回归的光纤陀螺温度漂移补偿<sup>①</sup>

何志昆<sup>②</sup> 刘光斌 赵曦晶 刘 冬

(第二炮兵工程大学控制工程系 西安 710025)

**摘要** 基于实测数据分析了全温度全速率下的陀螺漂移特性,提出了一种基于高斯过程回归的补偿新方法。该方法通过超参数训练直接建立了温度、陀螺输出和载体角速率之间的映射关系,弥补了传统方法对零偏和标度因数分别进行建模导致引入两次补偿误差的不足,在提高补偿精度的同时,简化了补偿步骤。仿真结果表明,相较于最小二乘支持向量回归方法,由高斯过程回归方法训练得到的模型能够更加准确地描述温度漂移特性,具有较高的预测补偿精度和良好的泛化能力,预测均方根误差小于  $0.003(^{\circ})/s$ ,有效抑制了温度对光纤陀螺精度的影响。

**关键词:** 光纤陀螺(FOG), 高斯过程回归(GPR), 温度漂移, 非线性分析, 补偿模型, 最小二乘支持向量回归机(LS-SVR)

### 0 引言

惯性器件(陀螺仪和加速度计)测量误差是影响惯性导航系统精度的主要因素,为保证导航精度,必须减小惯性器件的测量误差。通过建立陀螺仪和加速度计的精确误差模型,在导航解算过程中加以动态补偿,可以有效提高导航精度<sup>[1,2]</sup>。作为一种新型的无转动部件的全固态惯性器件,光纤陀螺(fiber optic gyro, FOG)凭借其潜在的优势和应用前景而备受重视,已经成为新一代惯性制导测量中的主导器件,开始广泛应用于惯性导航及制导、姿态测量及姿态稳定、捷联寻北及车辆定位定向等诸多军用民用领域。为适应不同领域的应用,一般要求FOG具有较宽的工作温度范围,但是由于构成FOG的核心部件(如光纤线圈、光源、耦合器等)对温度较为敏感,当工作环境温度变化时,陀螺的输出信号中将包含热致非互易相位噪声<sup>[3-5]</sup>,从而导致其零偏漂移和标度因数的不稳定,制约了其应用领域。环境温度对FOG性能变化的影响主要包括噪声和漂移两方面<sup>[6]</sup>,其中后者用于评价陀螺输出信号的长期变化,能够进行补偿。本文主要研究了FOG温度漂移补偿方法:对某型开环FOG进行了全温度全速率试验;基于实测数据,分析讨论了FOG温度漂移

的非线性,并引入了一种新的方法——高斯过程回归(Gaussian process regression, GPR),建立了一种新的FOG温度漂移补偿模型,实例验证了其具有较高的补偿精度。

### 1 FOG 温度试验及其漂移非线性分析

#### 1.1 FOG 温度试验

为研究FOG的温度漂移特性并进行补偿,设计了相应的试验方案,对某型开环FOG进行全温度全速率试验。将FOG水平放置在带有温控箱的单轴速率转台上,输入轴指向上方。转台调平后,调整温控箱的温度,温度点分别选取为 $-30^{\circ}\text{C}$ , $-20^{\circ}\text{C}$ , $-10^{\circ}\text{C}$ , $-5^{\circ}\text{C}$ , $0^{\circ}\text{C}$ , $5^{\circ}\text{C}$ , $10^{\circ}\text{C}$ , $20^{\circ}\text{C}$ , $40^{\circ}\text{C}$ , $60^{\circ}\text{C}$ ;待温控箱温度稳定后,给转台施加角速率,在每一个温度点下,速率点分别选取为 $\pm 1(^{\circ})/s$ , $\pm 2(^{\circ})/s$ , $\pm 5(^{\circ})/s$ , $\pm 10(^{\circ})/s$ , $\pm 20(^{\circ})/s$ , $\pm 40(^{\circ})/s$ , $\pm 80(^{\circ})/s$ ;待陀螺输出稳定后,采集其输出数据,采样频率为1Hz,采集时间为2min,取采样数据的均值作为当前温度和速率下的输出。此外,在每一次速率测试之前和测试之后,均进行一次位置测试,采样频率和采样时间与速率测试相同。图1给出了FOG全温度全速率的试验输出曲线。X轴表示温度,Y

① 国家863计划(2010AA7010213)资助项目。

② 男,1984年生,博士生;研究方向:非线性滤波及组合导航;联系人,E-mail: hezhikun@sina.com  
(收稿日期:2012-08-29)

轴表示输入角速率, Z 轴表示相应的 FOG 输出电压。

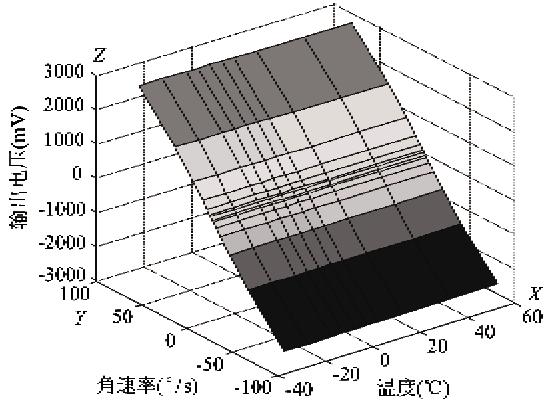


图 1 FOG 全温度全速率的输出曲线

## 1.2 FOG 温度漂移的非线性

环境温度的变化会影响到 FOG 主要器件的工作性能,导致 FOG 的主要性能参数发生变化,如零偏漂移及零偏稳定性变差,标度因数的线性度及对称性也会严重恶化。文献[3]指出,干涉型 FOG 仪,与时间相关的光纤环上的温度变化引起的非互易性会给 FOG 带来不可忽略的漂移并限制其应用,并推导给出了当两束干涉光分别沿着顺时针和逆时针方向传输通过长度为  $L$  的光纤环时,光纤环温度变化产生的热致非互易性相位延迟<sup>[7,8]</sup>为

$$\Delta\phi = \frac{\beta_0}{c_0} n \frac{\partial_z}{\partial_T} \int_0^{L/2} (\Delta T(z) - \Delta T(L-z)) (2z - L) dz \quad (1)$$

式中,  $\beta_0 = 2\pi/\lambda_0$  为光在真空中的传输常数,  $n$  为光纤折射率,  $c_0 = nc$  为光在波导中的光速,  $\Delta T(z)$  为光纤  $z$  点温度分布的变化量。

由上式可以看出,当环境温度发生变化时,FOG 内部光源波长、光纤折射率、光纤及线圈骨架的膨胀系数、线圈尺寸都将发生变化,从而导致 FOG 的漂移。实际上,由于各器件的误差对漂移的影响均为复杂的非线性方程,间接导致温度变化所造成的误差无法得到明确的函数关系<sup>[9]</sup>。

如前所述,温度的变化导致标度因数的对称度严重恶化,因此采用对正转反转输出相加以抵消地速影响的传统方法明显不再适用,论文在精确已知测试点纬度的前提下对输出进行精确地速补偿,然后将正向输入和负向输入两种情况分开考虑。图 2 给出了几个特定转速下陀螺输出随温度变化的情况。为了表征更加直观,图 2 以简单的一阶线性回归来示意输出变化趋势,其中  $k$  为一阶线性回归斜

率。上述一阶线性回归可造成最大回归误差为 4.8mV( $\omega = -80(^{\circ})/s$  时,按标度因数约为 38mV/ $(^{\circ})/s$ )计算,该误差为 0.13( $^{\circ}$ )/s,显然一阶线性回归还不能足够精确描述陀螺输出的变化趋势,而且从其斜率的变化可知,不同转速下,陀螺输出随温度的变化趋势(斜率)也不尽相同(主要是标度因数和零偏随温度发生变化造成的)。

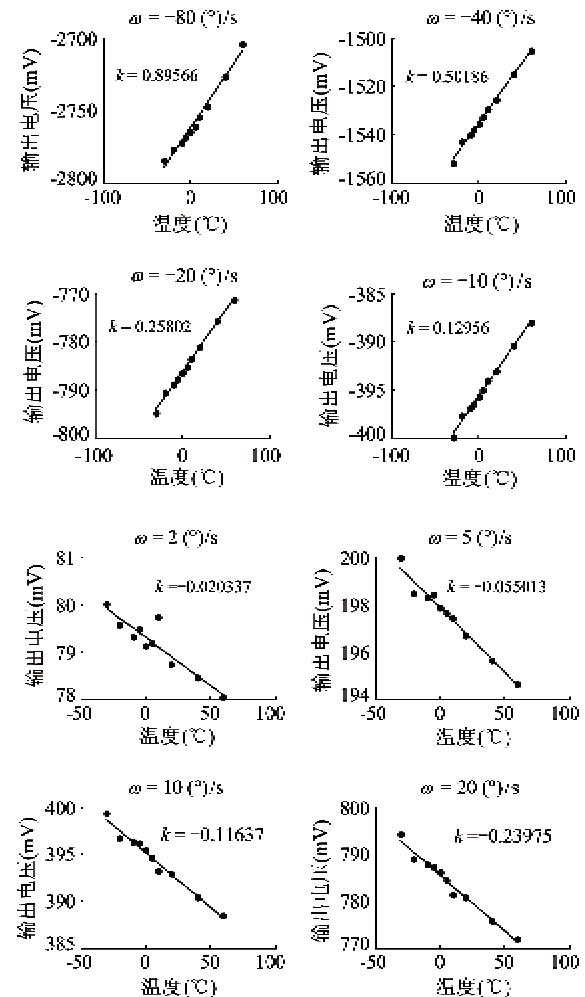


图 2 不同温度的陀螺速率输出

另外,从输出变化范围可以看出,温度变化对 FOG 的影响随着其转速的增大而增大(主要是由于标度因数随温度发生变化)。可以看出,FOG 温度漂移具有复杂的非线性。

## 1.3 补偿方法

对 FOG 温度漂移特性进行研究并对输出予以软件建模补偿已经成为提高其在全温度范围内适用性的重要手段之一。在建立 FOG 温度模型时,工程上常用的办法是采用(分段)线性拟合或多项式拟合等方法,分别对 FOG 的零偏和标度因数温度特性

进行建模、补偿,这种补偿方法难以准确描述其温度特性的非线性,同时引入两次补偿误差,导致补偿精度低<sup>[10]</sup>。

不少学者对此作了许多工作,伴随着新理论新方法的不断出现和发展,相继出现了人工神经网络(artificial neural network, ANN)<sup>[7]</sup>、支持向量回归机(support vector regression, SVR)<sup>[11]</sup>等机器学习方法应用于 FOG 的温度漂移建模,取得了许多有价值的研究成果。但是这些方法本身存在一些不完善之处,如基于经验风险最小化原则的 ANN 只能保证学习样本点的估计误差最小,泛化能力有限,且易陷入局部最优;基于统计学习理论的 SVR 是根据结构风险最小化原则自动学习目标模型的结构,具有较好的泛化性,从本质上克服了 ANN 研究中遇到的一些问题<sup>[12]</sup>,但是 SVR 存在核函数、核函数参数和损失函数难以确定等公开问题,且 SVR 的估计输出不具有概率意义。

GPR 是近年来发展起来的一种新的机器学习回归方法,它有着严格的统计学习理论基础,对处理高维数、小样本、非线性等复杂的问题具有很好的适应性,且泛化能力强。与 ANN、SVR 相比,还具有容易实现、非参数推断灵活、能超参数自适应获取等优点。此外,GPR 是一个具有概率意义的核学习机,可对预测输出做出概率解释。

GPR 在国外发展很快,取得了许多研究成果,已成为国际机器学习领域的研究热点<sup>[13]</sup>。近几年也逐步得到国内学者的重视,在许多领域得到了成功应用,并在导航领域开始了应用研究<sup>[14]</sup>。

## 2 高斯过程回归(GPR)<sup>[15-18]</sup>

### 2.1 GPR 预测

高斯过程是任意有限个随机变量均具有联合高斯分布的集合,它完全由均值函数和协方差函数确定:

$$\begin{aligned} m(\mathbf{x}) &= \mathbf{E}[f(\mathbf{x})] \\ k(\mathbf{x}, \mathbf{x}') &= \mathbf{E}[(f(\mathbf{x}) - m(\mathbf{x}))(f(\mathbf{x}') - m(\mathbf{x}'))] \end{aligned} \quad (2)$$

其中  $\mathbf{x}, \mathbf{x}' \in R^d$  为任意随机变量。故高斯过程可定义为  $f(\mathbf{x}) \sim GP(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}'))$ 。为了符号上的简洁,通常对数据作预处理,使其均值函数等于 0。

对于线性回归的情形,可以定义线性回归模型如下式所示:

$$f(\mathbf{x}) = \mathbf{x}^T \mathbf{w}, y = f(\mathbf{x}) + \varepsilon \quad (3)$$

其中  $\mathbf{x}$  为输入向量,  $\mathbf{w}$  为线性模型的权重向量,  $f$  为函数值,  $y$  为受加性噪声污染的观测值, 噪声  $\varepsilon \sim N(0, \sigma_n^2)$ ,  $\sigma_n^2$  为噪声的方差。对于更具一般性的非线性回归问题,可以运用“核技巧”定义非线性回归模型如下式所示:

$$f(\mathbf{x}) = \phi(\mathbf{x})^T \mathbf{w}, y = f(\mathbf{x}) + \varepsilon \quad (4)$$

令  $\mathbf{X} = [\mathbf{x}_1 \ \mathbf{x}_2 \cdots \mathbf{x}_n]$  表示  $n$  个  $d$  维输入矢量组成的  $d \times n$  维输入矩阵,  $y$  为  $n$  个输出标量  $y_i$  组成的输出矢量, 则在贝叶斯形式中, 可以分别得到观测值  $y$  的先验分布为

$$y \sim N(0, \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n) \quad (5)$$

以及观测值  $y$  和预测值  $f_*$  的联合先验分布为

$$\begin{bmatrix} \mathbf{y} \\ f_* \end{bmatrix} \sim N\left(0, \begin{bmatrix} \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n & \mathbf{K}(\mathbf{X}, \mathbf{x}_*) \\ \mathbf{K}(\mathbf{x}_*, \mathbf{X}) & k(\mathbf{x}_*, \mathbf{x}_*) \end{bmatrix}\right) \quad (6)$$

式中,  $\mathbf{K}(\mathbf{X}, \mathbf{X}) = \mathbf{K}_n = (\mathbf{k}_{ij})$  为  $n \times n$  阶对称正定的协方差矩阵, 矩阵元素  $\mathbf{k}_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$ , 度量  $\mathbf{x}_i$  和  $\mathbf{x}_j$  之间的相关性,  $\mathbf{K}(\mathbf{X}, \mathbf{x}_*) = \mathbf{K}(\mathbf{x}_*, \mathbf{X})^T$  为测试点  $\mathbf{x}_*$  与训练集的输入  $\mathbf{X}$  之间的  $n \times 1$  阶协方差矩阵,  $k(\mathbf{x}_*, \mathbf{x}_*)$  为测试点  $\mathbf{x}_*$  自身的协方差,  $\mathbf{I}_n$  为  $n$  维单位矩阵。

可以计算出预测值  $f_*$  的后验分布为

$$f_* | \mathbf{X}, \mathbf{y}, \mathbf{x}_* \sim N(\bar{f}_*, \text{cov}(f_*)) \quad (7)$$

其中

$$\begin{aligned} \bar{f}_* &\triangleq \mathbf{E}[f_* | \mathbf{X}, \mathbf{y}, \mathbf{x}_*] \\ &= \mathbf{K}(\mathbf{x}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n]^{-1} \mathbf{y} \end{aligned} \quad (8)$$

$$\begin{aligned} \text{cov}(f_*) &= k(\mathbf{x}_*, \mathbf{x}_*) - \mathbf{K}(\mathbf{x}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) \\ &\quad + \sigma_n^2 \mathbf{I}_n]^{-1} \mathbf{K}(\mathbf{X}, \mathbf{x}_*) \end{aligned} \quad (9)$$

则  $\hat{\mu}_* = \bar{f}_*$ ,  $\hat{\sigma}_{f_*}^2 = \text{cov}(f_*)$  即为测试点  $\mathbf{x}_*$  对应预测值  $f_*$  的估计均值和方差。

### 2.2 GPR 训练

GPR 可以选择不同的协方差函数,本文采用平方指数(squared exponential, SE)协方差函数

$$k(\mathbf{x}, \mathbf{x}') = \sigma_f^2 \exp(-\frac{1}{2}(\mathbf{x} - \mathbf{x}')^T \Lambda^{-2}(\mathbf{x} - \mathbf{x}')) \quad (10)$$

式中:  $\Lambda = \text{diag}(\mathbf{l}^2)$ ,  $\mathbf{l}$  为方差尺度,  $\sigma_f^2$  为信号方差。在 ANN 或 SVR 研究领域里, 上式有时也称为径向基(radial basis function, RBF)协方差函数。

GPR 的训练过程,就是超参数  $\boldsymbol{\theta} = \{\Lambda, \sigma_f^2, \sigma_n^2\}$  的优化过程。可通过极大似然法求得:先建立训练样本条件概率的负对数似然函数  $L(\boldsymbol{\theta}) = -\log p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta})$ , 再令其对超参数求偏导,最后采用共轭梯度

法、牛顿法等优化方法对偏导数做最小化得到超参数的最优解。其中,负对数似然函数  $L(\boldsymbol{\theta})$  及其关于超参数  $\boldsymbol{\theta}$  的偏导数的形式如下式所示:

$$\begin{aligned} L(\boldsymbol{\theta}) &= -\log p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}) \\ &= \frac{1}{2} \mathbf{y}^T \mathbf{C}^{-1} \mathbf{y} + \frac{1}{2} \log |\mathbf{C}| + \frac{n}{2} \log 2\pi \end{aligned} \quad (11)$$

$$\begin{aligned} \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} &= \frac{1}{2} \text{tr}\left(\mathbf{C}^{-1} \frac{\partial \mathbf{C}}{\partial \theta_i}\right) - \frac{1}{2} \mathbf{y}^T \mathbf{C}^{-1} \frac{\partial \mathbf{C}}{\partial \theta_i} \mathbf{C}^{-1} \mathbf{y} \\ &= \frac{1}{2} \text{tr}\left((\alpha \alpha^T - \mathbf{C}^{-1}) \frac{\partial \mathbf{C}}{\partial \theta_i}\right) \end{aligned} \quad (12)$$

其中  $\mathbf{C} = \mathbf{K}_n + \sigma_n^2 \mathbf{I}_n$ ,  $\alpha = (\mathbf{K} + \sigma_n^2 \mathbf{I}_n)^{-1} \mathbf{y} = \mathbf{C}^{-1} \mathbf{y}$ 。

获得最优超参数后,利用式(10)(11)就可以得到测试点  $\mathbf{x}_*$  对应的预测值  $\hat{\mu}_*$  及其方差  $\hat{\sigma}_{f_*}^2$ 。

### 3 光纤陀螺温度漂移补偿

对于陀螺使用者而言,更加关心的是如何能够从可准确观测(计算)物理量得到所需要的角速率,即准确获取如下映射关系:

$$\omega_i = f(y_i, T) \quad (13)$$

其中  $\omega_i$  为(载体)输入角速率,  $y_i$  为陀螺的敏感输出(本文为输出电压),  $T$  为温度。

本文从使用者角度出发,不对陀螺输出电压进行补偿校正,而是通过式(13)直接建立温度漂移补偿模型。基于 GPR 的 FOG 温度漂移补偿模型如图 3 所示。

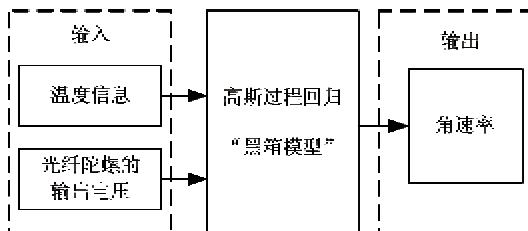


图 3 基于 GPR 的 FOG 温度漂移补偿模型

图 3 中,将温度信息和陀螺的输出电压作为 GPR 回归模型的输入,输入角速率作为输出。一旦训练达到要求,就能够得到一个准确描述 FOG 温度漂移特性的 GPR 模型,而无需对零偏和标度因数分别进行建模,在一定程度上简化了补偿步骤。

#### 3.1 基于高斯过程回归的温度漂移非线性建模

将 1.1 节温度试验中由 10 个温度点和 14 个速率点获取的共  $10 \times 14 = 140$  个构造形如((温度值, 输出电压), 输入角速率)的数据对,并分成两组:训练集和测试集。前者用于训练回归模型,后者

用于回归模型的预测补偿性能及泛化能力分析。本文选取 SE 协方差函数(见式(10)),因此 GPR 模型的超参数初值设为  $\ln l_1 = \ln l_2 = 0$ ,  $\ln \sigma_f = \ln \sigma_n = 0$ 。采用共轭梯度优化算法搜索最优超参数。训练完毕后,即可利用训练好的 GPR 模型对测试集进行预测。

为比较分析,在相同的训练集和测试集的前提下,文中采用最小二乘支持向量机(least square support vector regression, LS-SVR)<sup>[19]</sup>对漂移数据进行建模补偿,其中,协方差函数的选取同 GPR。

#### 3.2 模型评估

##### (1) 模型适用性评估——残差正态性检验

衡量一个模型是否合适,基本的一条就要看回归预测值减去实测值,即残差序列  $\{a_t\}$  是否服从均值为 0、方差为某一常数的正态分布,即白度检验。下文采用作图的方法对残差分布的正态性进行检验。

将 140 个数据对作为训练集对 GPR 模型进行训练,得到的残差 Q-Q 图如图 4 所示,可以看出数据点近似地形成一条直线,表明残差序列近似服从正态分布,体现出 GPR 模型能较好地拟合实际数据,即模型是适用的。

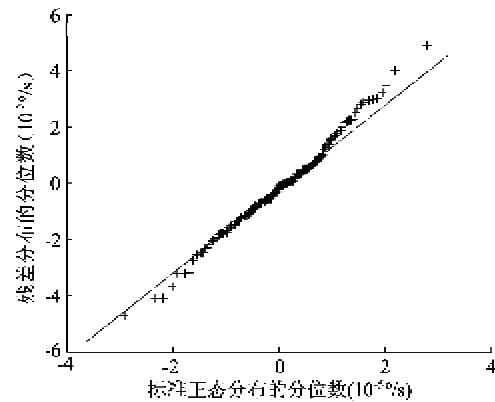
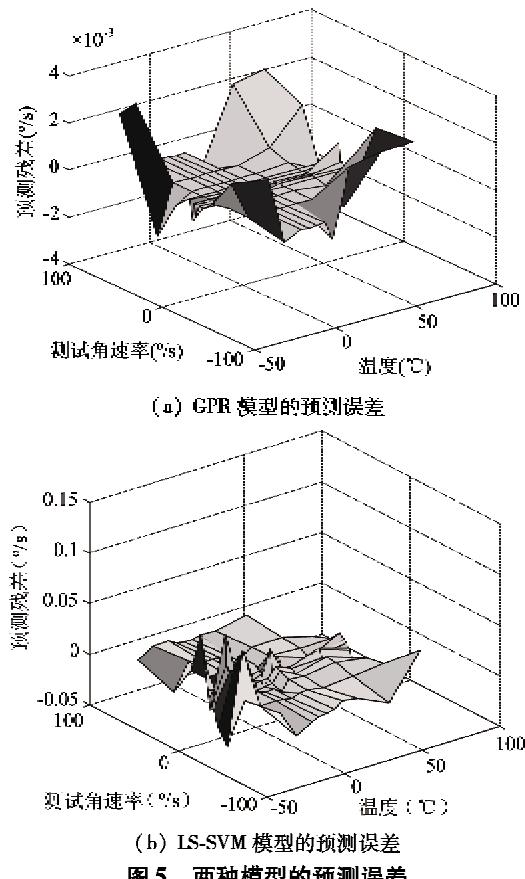


图 4 残差 Q-Q 图

##### (2) 模型预测性能评估

交叉验证法(cross-validation, CV)<sup>[20]</sup>常被用来进行模型预测性能的评估。文中采用留一法(leave-one-out, LOO),即从 140 个数据对中每次取出一个数据对作为测试集,余下数据对作为训练集,共进行 140 次训练与预测。分别采用 GPR 和 LS-SVR 方法进行训练和预测,得到的预测误差如图 5 所示。采用均方根误差(root mean square error, RMSE)对模型预测性能进行定量评估,两种方法得到的 RMSE 分别为  $7.03 \times 10^{-4}$  ( $^\circ$ /s) 和  $1.26 \times 10^{-2}$  ( $^\circ$ /s),显示出 GPR 模型与 LS-SVR 模型相比,在 FOG 温度漂移

补偿中具有较好的预测性, 预测补偿误差不超过  $0.003(^{\circ})/\text{s}$ 。



### (3) 模型泛化性能评估

泛化性能是指模型对新样本(尤其是与训练样本有较大差异的新样本)能否给出准确的预测。为了检验 GPR 模型的泛化性能, 分别选取一个温度点下的 14 个速率数据作为测试集, 余下数据作为训练集, 同样分别采用 GPR 和 LS-SVM 方法进行训练和预测, 得到的预测均方根误差如表 1 所示。

表 1 不同测试集的预测均方根误差

温度( $^{\circ}\text{C}$ )	均方根误差( $^{\circ}/\text{s}$ )	
	LS-SVR	GPR
-30 $^{\circ}\text{C}$	3.52 e-02	2.16 e-03
-20 $^{\circ}\text{C}$	2.90 e-02	9.28 e-04
-10 $^{\circ}\text{C}$	4.34 e-03	2.23 e-05
-5 $^{\circ}\text{C}$	6.91 e-03	1.66 e-05
0 $^{\circ}\text{C}$	4.84 e-03	9.87 e-06
5 $^{\circ}\text{C}$	4.48 e-03	1.46 e-04
10 $^{\circ}\text{C}$	1.13 e-02	5.71 e-05
20 $^{\circ}\text{C}$	3.82 e-03	1.78 e-04
40 $^{\circ}\text{C}$	6.57 e-03	9.87 e-04
60 $^{\circ}\text{C}$	2.22 e-02	1.67 e-03

由表 1 结果可以看出, 相较于 LS-SVM 方法, 由 GPR 方法得到的模型对于新样本(温度信息不同)具有更好的泛化性能, 泛化误差均方根不超过  $0.003(^{\circ})/\text{s}$ 。

此外, 从图 5 以及表 1 的结果可以看出, GPR 模型和 LS-SVM 模型在训练区域内的预测效果很好, 在区域边缘(或区域外)的预测效果较差一些(为了直观形象, 图 6 给出了 GPR 模型的预测误差图 5(a)的俯视图)。实际应用过程中, 可以通过合理地设置训练区域来进一步提高补偿精度。

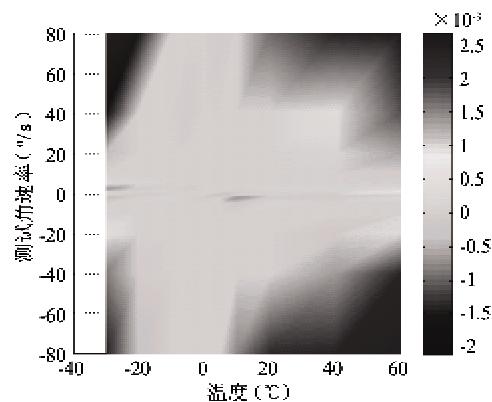


图 6 GPR 模型的预测误差

综上所述, 经过训练集训练建立的 GPR 模型能更加准确地描述 FOG 温度漂移特性并进行有效补偿。

## 4 结 论

本文基于全温度全速率的试验实测数据, 分析了 FOG 温度漂移特性。为了弥补传统方法对零偏和标度因数分别进行建模导致引入两次补偿误差的不足, 直接建立温度信息、陀螺输出与载体角速率之间的映射关系, 提出了一种基于 GPR 的温度漂移综合补偿新方法, 简化了补偿步骤。仿真结果表明, 与 LS-SVR 方法相比, GPR 方法建立的模型能更准确地描述 FOG 温度漂移特性, 具有更高的预测补偿精度和泛化能力, 其预测均方根误差不超过  $0.003(^{\circ})/\text{s}$ , 有效抑制了温度对 FOG 精度的影响。

## 参考文献

- [1] Savage P G. Strapdown inertial navigation integration algorithm design. Part 1. attitude algorithms. *Journal of Guidance, Control, and Dynamics*, 1998, 21(1):19-28
- [2] Savage P G. Strapdown inertial navigation integration algorithm design. Part 2. velocity and position algorithms.

- Journal of Guidance, Control, and Dynamics*, 1998, 21(2):208-221
- [3] Shupe D M. Termally induced non reciprocity in the fiber optic Interferometer. *Applied Optics*, 1980, 19(5): 654-655
- [4] Sudhakar D, Gregg K, Chellappan N. Strategic interferometric fiber-optic gyroscope for ballistic missile inertial guidance. In: AIAA Guidance, Navigation and Control Conference and Exhibit, Honolulu, USA, 2008. 1-8
- [5] 金靖, 宋凝芳, 李立京. 干涉型光纤陀螺温度漂移建模与实时补偿. *航空学报*, 2007, 28(6): 1449-1454
- [6] 金靖, 王峰, 张忠钢等. 基于多元线性回归模型的光纤陀螺温度误差建模. *宇航学报*, 2008, 29(6): 1912-1916
- [7] 冯丽爽, 南书志, 金靖. 光纤陀螺温度建模及补偿技术研究. *宇航学报*, 2006, 27(5): 939-941, 1049
- [8] 韩冰, 林玉荣, 邓正隆. 光纤陀螺温度漂移误差的建模与补偿综述. *中国惯性技术学报*, 2009, 17(2): 218-224
- [9] Yan F P, Lan H J, Jian S H. Investigation of the temperature compensated method for optic gyros. *Acta Optica Sinica*, 1999, 19(7): 968-974
- [10] 周海波, 刘建业, 熊智等. 基于BP神经网络的光纤陀螺仪温度建模研究. *光电工程*, 2006, 33(6): 135-138, 144
- [11] 蒋蔚, 伊国兴, 曾庆双. 基于PSVR的微机械陀螺温度漂移预测. *中国惯性技术学报*, 2009, 17(3): 360-365
- [12] Vapnik V N. *Statistical Learning Theory*. New York: John Wiley & Sons, 1998. 375-442
- [13] Jack M W, David J F, Aaron H. Gaussian process dynamical models for human motion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008, 30(2): 283-298
- [14] 李鹏, 米申民, 陈兴林. 自适应平方根无迹卡尔曼滤波算法. *控制理论与应用*, 2010, 27(2): 143-146
- [15] Rasmussen C E, Williams C K I. *Gaussian Processes for Machine Learning*. Cambridge: MIT Press, 2006. 7-30
- [16] Sofiane B B, Amine B. Gaussian process for nonstationary time series prediction. *Computational Statistics & Data Analysis*, 2004, 47: 705-712
- [17] Lawrence N D. Gaussian process latent variable models for visualization of high dimensional data. In: Proceedings of the International Conference on Advances in Neural Information Processing Systems 16, Vancouver, Canada, 2003. 329-336
- [18] Lawrence N D. Probabilistic non-linear principal component analysis with Gaussian process latent variable models. *Journal of Machine Learning Research*, 2005, 6: 1783-1816
- [19] 张涛, 徐晓苏. 基于LS-SVM的捷联大失准角初始对准技术. *高技术通讯*, 2012, 22(1): 88-93
- [20] Hastie T, Tibshirani R, Friedman J. *The elements of statistical learning*. 2<sup>nd</sup> ed. New York: Springer Press, 2008. 241-243

## Compensation for temperature drift of fiber optic gyro based on Gaussian process regression

He Zhikun, Liu Guangbin, Zhao Xijing, Liu Dong

(Department of Control Engineering, The Second Artillery Engineering University, Xi'an 710025)

### Abstract

To improve the adaptability of a fiber optic gyro (FOG) working in the full temperature range, its temperature drift characteristic is analyzed based on the full temperature and angular rate test data and its compensation method is studied. A new compensation approach based on Gaussian process regression is proposed to deal with the complex characteristic of temperature drift. It maps the temperature and output of FOG to the angular rate of carrier directly by the optimization of hyperparameters, so traditional methods' two compensation errors caused by separate modeling of zero bias and scale factor can be avoided. The compensation precision is improved and the compensation process is simplified. The simulation results show that the model built by the new approach, in comparison with least square support vector regression, can reflect the temperature drift characteristic of FOG more accurately, and can obtain the better generalization ability and higher compensation precision with the predicted root mean square error less than 0.003( $^{\circ}$ )/s. Furthermore, it can reduce the influence of temperature on FOG output precision.

**Key words:** fiber optic gyro (FOG), Gaussian process regression (GPR), temperature drift, nonlinearity analysis, compensation model, least square support vector regression (LS-SVR)