

一种 RVM 的 INS 参数长期稳定性预测与补偿方法

党宏涛^{1,3}, 伊国兴¹, 于湘涛², 杜祖良^{1,2}, 王常虹¹

(1. 哈尔滨工业大学 空间控制与惯性技术研究中心, 150001 哈尔滨;

2. 北京自动化控制设备研究所, 100074 北京; 3. 解放军 96117 部队, 271100 山东 莱芜)

摘要: 为提高惯导系统参数长期稳定性, 降低人工标定成本, 增强惯导系统使用效能, 提出一种基于相关向量机的惯导系统参数长期稳定性预测和补偿方法, 选择均值和标准差作为参数稳定性的性能指标. 而对于均值随时间变化具有明显规律的参数, 采用 RVM 方法对存储时间较长的参数稳定性均值进行回归建模, 根据模型对存储时间较短的参数稳定性进行性能预测和标定参数补偿. 最后对惯导系统中重要参数加速度计标度因数长期稳定性进行建模预测和参数补偿, 补偿后结果显示, 间隔时间约 6 个月的参数稳定性均值性能提高了 50.90%, 验证了所提方法具有很好的实际应用价值, 且表明使用该方法能够代替人工标定, 以增强惯导系统使用效能.

关键词: 相关向量机; 惯导系统; 标定周期; 长期稳定性; 预测补偿

中图分类号: V241.6

文献标志码: A

文章编号: 0367-6234(2014)09-0015-04

RVM-based prediction and compensation method for the long-term stability of INS system parameters

DANG Hongtao^{1,3}, YI Guoxing¹, YU Xiangtao², DU Zuliang^{1,2}, WANG Changhong¹

(1. Space Control and Inertial Technology Research Center, Harbin Institute of Technology, 150001 Harbin, China;

2. Beijing Institute of Automatic Control Equipment, 100074 Beijing, China; 3. 96117 Troops, 271100 Shandong Laiwu, China)

Abstract: To improve the long-term stability performance, reduce the manual calibration costs and enhance the use efficiency of inertial navigation systems, we propose a prediction and compensation method for the long-term stability of inertial navigation system parameter based on correlation vector machine, in which we choose the mean and standard deviation as the performance indicators. For the mean parameter with a significant change with time in the law, we establish regression modeling for longer storage stability parameter by RVM method, and carry out the performance prediction and calibration parameters compensation for the parameters stability of the shorter storage. The paper presents the modeling forecasting and parameter compensation for the long-term stability of the accelerometer scale factor of the important parameters in the inertial navigation system, the parameter stability mean performance for an interval time of 6 months has improved by 50.90%. This result implies that this method can replace the manual calibration and the use efficiency of inertial navigation systems, and verifies the effectiveness of the proposed method.

Keywords: relevance vector machine; inertial navigation system; calibration cycle; long-term stability; predictive compensation

惯性导航系统(inertial navigation system, INS)标定参数长期稳定性是衡量产品综合性能的重要指标. 为了保证 INS 综合性能满足要求, 需要间隔

一定时间对影响 INS 综合性能的各项参数进行稳定性标定. 对于军方用户来说, 提高参数长期稳定性性能意味着战时具有更大主动性和生存能力^[1].

通过对惯导系统产品机理^[2-3]和标定方法^[4]的研究都能够有效提高参数稳定性性能, 但通过对批量历次标定参数长期稳定性预测和补偿方法研究来提高 INS 参数稳定性性能, 在国内尚无研究. 近年

收稿日期: 2013-07-15.

基金项目: 国家重点基础研究发展规划资助项目(61388010404).

作者简介: 党宏涛(1976—), 男, 博士研究生;

王常虹(1961—), 男, 教授, 博士生导师.

通信作者: 伊国兴, ygx@hit.edu.cn.

来,基于支持向量机(SVM)^[5]的统计分析方法和基于稀疏贝叶斯^[6]的统计分析方法成为机器学习领域的研究热点^[7-8].支持向量机采用 VC 维理论和结构风险最小化原则,对于小样本情况下的模型具有很好的泛化能力,但由于 SVM 所需核函数的数量会随着训练集增大而显著增加,同时预测也缺乏必要的概率信息^[9];基于稀疏贝叶斯的相关向量机(RVM)是一种与 SVM 函数形式相同的稀疏概率模型,与 SVM 相比它不存在以上缺点,在实际预测性能相当的情况下,解的稀疏性明显高于 SVM^[10].

由于 INS 历次标定参数随时间变化所积累数据较少,对稳定性进行估计得到均值性能具有一定的不确定性,因此本文尝试着用先进智能算法解决 INS 参数长期稳定性预测与补偿遇到的实际工程问题.

1 RVM 建模方法

RVM 比较适用于函数回归和分类,它把基于高斯过程的贝叶斯推理方法应用到支持向量机中.

1.1 RVM 基本理论

给定输入向量 $\mathbf{x} = \{x_n \mid n = 1, 2, \cdots, N\}$ 和相应的输出向量 $\mathbf{t} = \{t_n \mid n = 1, 2, \cdots, N\}$,通过应用训练数据和先验知识设计 RVM 回归模型,令

$$t_n = y(x_n, \mathbf{w}) + \varepsilon.$$

式中: t_n 是目标值; $\mathbf{w} = (w_0, w_1, \cdots, w_N)$ 是可调参数权值; $\varepsilon = \{\varepsilon_n \mid n = 1, 2, \cdots, N\}$ 是独立分布的零均值高斯噪声,其方差为 σ^2 ; 未知函数 y 可以表示为

$$y(\mathbf{x}, \mathbf{w}) = \sum_{i=1}^N w_i \psi_i(\mathbf{x}) + \varepsilon_n.$$

式中 $\psi_i(\mathbf{x}) = K(\mathbf{x}, \mathbf{x}_i)$ 为核函数.

假定 t_n 相互独立,则已知训练集的似然估计可写为

$$p(\mathbf{t}/\mathbf{w}, \sigma^2) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left\{-\frac{1}{2\sigma^2} \|\mathbf{t} - \Phi\mathbf{w}\|^2\right\}.$$

采用稀疏贝叶斯原理对 $\mathbf{w}$ 进行零均值高斯先验分布:

$$p(\mathbf{w}/\boldsymbol{\alpha}) = \prod_{i=0}^N \mathcal{N}(w_i/0, \alpha_i^{-1}) = \prod_{i=0}^N ((\alpha_i/\sqrt{2\pi}) \exp(-\alpha_i w_i^2/2)).$$

式中: $\boldsymbol{\alpha}$ 为 $N+1$ 维超参数向量,每 1 个权重 w_i 对应 1 个超参数 α_i ,从而控制先验分布对各参数的影响,以确保相关向量模型的稀疏性.

根据贝叶斯原理,对所有未知参数有如下后

验公式:

$$p(\mathbf{w}/\mathbf{t}, \boldsymbol{\alpha}, \sigma^2) = \frac{p(\mathbf{t}/\mathbf{w}, \sigma^2)p(\mathbf{w}/\boldsymbol{\alpha})}{p(\mathbf{t}/\boldsymbol{\alpha}, \sigma^2)} = (2\pi)^{\frac{-(N+1)}{2}} |\boldsymbol{\Sigma}|^{-\frac{1}{2}} \exp\{-0.5(\mathbf{w} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{w} - \boldsymbol{\mu})\}.$$

式中: $\boldsymbol{\Sigma}$ 为后验协方差矩阵, $\boldsymbol{\Sigma} = (\sigma^{-2} \Phi^T \Phi + \mathbf{A})^{-1}$; $\mathbf{A}$ 为对称矩阵, $\mathbf{A} = \text{diag}(\alpha_0, \alpha_1, \cdots, \alpha_N)$; $\boldsymbol{\mu}$ 为均值向量, $\boldsymbol{\mu} = \sigma^{-2} \sum \Phi^T \mathbf{t}$; Φ 为 $N \times (N+1)$ 维矩阵,

$$\Phi = (\boldsymbol{\varphi}(x_1), \boldsymbol{\varphi}(x_2), \cdots, \boldsymbol{\varphi}(x_N))^T, \boldsymbol{\varphi}(x_N) = (1, K(x_n, x_1), K(x_n, x_2), \cdots, K(x_n, x_N))^T.$$

对于 $\boldsymbol{\alpha}$ 和 σ^2 ,使用迭代公式进行估计:

$$\alpha_i^{\text{new}} = \gamma_i / \mu_i^2, \quad \gamma_i = 1 - \alpha_i N_{ii}, (\sigma^2)^{\text{new}} = \|\mathbf{t} - \Phi\boldsymbol{\mu}\|^2 / (N - \sum \gamma_i).$$

式中: γ_i 为衡量 $\boldsymbol{\alpha}$ 的中间变量; μ_i 为第 i 个后验平均权; N_{ii} 为后验权协方差矩阵的第 i 个对角元素; N 为样本数据个数.

若给定一个输入值 x_* ,则相应的输出值概率分布为

$$p(t_*/t, \boldsymbol{\alpha}_{MP}, \sigma_{MP}^2) = \int p(t_*/\mathbf{w}, \sigma_{MP}^2) p(\mathbf{w}/t, \boldsymbol{\alpha}_{MP}, \sigma_{MP}^2) d\mathbf{w}.$$

上式服从高斯分布,且

$$p(t_*/t, \boldsymbol{\alpha}_{MP}, \sigma_{MP}^2) = \mathcal{N}(t_*/y_*, \sigma_*^2).$$

式中 $\boldsymbol{\alpha}_{MP}$ 、 σ_{MP}^2 为经过迭代用于预测的最优值. 预测方差 $\sigma_*^2 = \sigma_{MP}^2 + \boldsymbol{\phi}(x_*)^T \sum \boldsymbol{\phi}(x_*)$, 预测均值 $y_* = \boldsymbol{\mu}^T \boldsymbol{\phi}(x_*)$, y_* 为 t_* 的预测值.

1.2 RVM 核函数的确定

RVM 常用的几种核函数有 RBF 核函数、线性核函数、多项式核函数等.其中, RBF 核函数具有较好的学习能力,适用于高维、低维、小样本、大样本等多种情况^[11].因此,本文选用 RBF 函数作为 RVM 的核函数,其数学表达式为

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2 / \delta^2).$$

式中: $\mathbf{x}$ 为目标输入向量; $\mathbf{x}_i$ 为训练样本中第 i 维输入向量; δ^2 为核函数的宽度.

1.3 蚁群优化算法

蚁群优化算法(ant colony optimization, ACO)是 20 世纪 90 年代提出的一种新型模拟自然界生物系统的智能算法,具有良好的并行分布性、自组织性、正反馈特性,从理论上保证了算法能够在较短的时间里找到全局最优解.在采用径向基函数作为 RVM 核函数时需要参数 δ^2 进行优化,以保证 RVM 模型具有较高的拟合度,用蚁群优化算法的 RVM 计算步骤如下:

1) 参数初始化. 设有 m 个蚂蚁,第 i 个蚂蚁的

初始位置 $S_i = \delta_i, i = 1, 2, \dots, m$.

2) 信息素初始化.对 m 个蚂蚁所在位置的目标值进行计算,根据目标值的满意程度来确定其所在位置信息素的大小: $\Delta t(i) = \alpha^{E(i)}$,初始信息素定为 $T_0(1) = \Delta t(1), E(i)$ 为第 i 个蚂蚁所在位置对目标值的满意度, α 为已设定的值,一般取 $\alpha = 3$.

3) 信息素的挥发和更新.

建立挥发因子: $\rho = \ln((K - i)/K), i = 1, 2, \dots, K - 1, K$ 为蚁群总的迭代次数;

更新信息素: $T(i) = (1 - \rho)T(i - 1) + \Delta t(i)$.

4) 通过信息素的大小,确定蚂蚁下一步转移的概率: $p(i) = e^{T_0(best) - T_0(i)} / e^{T_0(best)}$,其中 $T_0(best)$ 是信息素最大的蚂蚁.

5) 蚂蚁位置的更新:

$$S_i^k = S_{i-1}^k + \text{sgn}((S_{\text{gbest}} - S_{i-1}^k)) * p(i) * L.$$

6) 根据寻找到的最优解 $S_{\text{gbest}} = \delta_*$,进行 RVM 预测建模.

2 INS 参数长期稳定性预测与补偿

INS 标定参数长期稳定性包括陀螺常值漂移、陀螺力矩器系数、陀螺与 G 有关项、航向效应、加速度计零偏、加速度计标度因数等多项参数,通过对历次标定数据进行整理,发现加速度计标度因数变化趋势最为明显,因此本文选择加速度计标度因数进行参数长期稳定性预测和补偿.

2.1 参数长期稳定性数据整理

标定参数稳定性是指以第一次标定数据为基准,后续标定的数据减去第一次标定数据,其时间间隔为两次标定的时间差,INS 稳定性包含产品编号、稳定性数据、稳定性时间间隔,经过对批次产品标定参数进行异常数据的剔除和修订,得到稳定性样本为 $S\{(x^p, t^p) \mid p = 1, 2, \dots, K\}$, $t_i^p = f(x_i^p)$ 表示第 p 个产品某项参数长期稳定性在时间间隔 x_i^p 时所对应的数值.

2.2 参数长期稳定性预测与补偿流程

不同批次的 INS 产品,当系统结构、生产工艺、标定设备、标定方法,贮存环境等因素相同时,INS 参数随时间变化的具有类似的趋势.在实际应用中,首先需要对存贮时间长和标定次数多的参数稳定性进行趋势性判断,对于稳定性均值性能趋势变化明显的参数,进行 RVM 预测,根据预测模型,对存贮时间短的参数进行当前时间的稳定性预测,并对预测值进行补偿,将补偿后的 INS 快速装配到武器系统,避免了对 INS 进行耗时耗力的人工标定.基于 RVM 的 INS 参数稳定性预测

与补偿流程图如图 1 所示.




图 1 参数长期稳定性预测与补偿流程

3 方法验证

加速度计是 INS 的重要部件,其标度因数长期稳定性对 INS 综合性能有重要影响,采用基于 RVM 的方法对其参数长期稳定性进行建模、预测和补偿.

3.1 标度因数长期稳定性预测模型

选择两个批次的 INS 加速度标度因数长期稳定性进行整理,第 X9 批次为 24 台 INS,共计 72 组加速度计标度因数,第 X3 批次为 39 台 INS,共计 117 组加速度计标度因数,如图 2 所示.




图 2 两个批次产品标度因数长期稳定性

图 2 每条曲线表示每块加速度计标度因数,星点表示稳定性随时间间隔的变化数据.对每个时间段上的标度因数稳定性,采用平均值和标准差对总体性能进行评价,均值随时间变化表示了参数系统误差随时间的变化趋势,具有可补偿性,标准差随时间变化表示了参数随机误差随时间的变化趋势,具有不可补偿性.选择图 2(a),对参数稳定性随时间变化进行 RVM 预测建模,为了便

于计算,将图2(a)按照9个时间间隔点整理,得到的RVM预测模型如图3所示。




图3 第X9批次标度因数稳定性RVM预测模型

从图3可以看出,标度因数长期稳定性具有时间明显变化的趋势,在采用蚁群优化算法对参数 δ 进行优化的情况下,当 $\delta = 0.3537$ 时,得到RVM预测模型均方误差为0.0262,模型标准差为0.1621。

3.2 标度因数长期稳定性预测补偿模型及验证

选择存贮时间较短的图2(b)第X3批次标度因数进行RVM预测和补偿验证。

根据RVM模型,建立参数长期稳定性RVM预测补偿模型,设定最后两次标定时间间隔 $\Delta x = x_n - x_{n-1}$ 的稳定性变化量 Δt^* :

$$\Delta t^* = \mu^T \phi(x_n) - \mu^T \phi(x_{n-1}).$$

令

$$\Delta t = t_n - t_{n-1}, \quad \Delta t' = \Delta t - \Delta t^*.$$

式中: Δt^* 为预测补偿值; Δt 为实际参数长期稳定性; $\Delta t'$ 为RVM预测补偿后的参数长期稳定性。

对 Δt 和 $\Delta t'$ 进行验证对比,结果如图4所示。




图4 第X3批次标度因数稳定性补偿效果对比

从图4可知,117组加速度计标度因数两次标定时间间隔约为6个月(180d),未补偿时,标度因数参数稳定性平均值为 1.918×10^{-5} ,经过预测补偿后,其参数稳定性平均值为 9.4192×10^{-6} 。

4 结 语

为了提高INS参数长期稳定性性能,增强INS使用效能,针对INS中部分参数长期稳定性具有明显变化的趋势,提出了基于RVM的参数

长期稳定性预测与补偿方法。通过对某型INS加速度计标度因数长期稳定性进行预测和补偿,结果表明经过补偿后参数长期稳定性均值性能提高了50.90%。表明基于RVM的参数长期稳定性预测与补偿方法具有一定的工程价值,结合实际开展进一步的应用研究对提高INS系统的精度、延长标定周期具有重要意义。

参考文献

- [1] 张洪立,许奔. SiC/Al技术延长惯性平台标定周期的理论研究[J]. 中国惯性技术学报,2003,11(5): 16-18.
- [2] SHI Zhen, YANG Jie, YUE Peng, et al. A new calibration and compensation method for installation errors of accelerometers in Gyroscope Free Strap-down Inertial Navigation System [C]//2010 IEEE International Conference on Information and Automation (ICIA). Piscataway: IEEE,2010:924-929.
- [3] 林玉荣,邓正隆. 激光陀螺捷联惯导系统中惯性器件误差的系统级标定[J]. 哈尔滨工业大学学报,2001,33(1): 112-115.
- [4] 曹渊,张士峰,杨华波,等. 惯导平台误差快速自标定方法研究[J]. 宇航学报,2011,32(6): 1281-1287.
- [5] VAPNIK V. N. Statistical learning theory [M]. New York: John Wiley, 1998:17-25.
- [6] YUAN Jin, BO Liefeng, WANG Kesheng, et al. Adaptive spherical Gaussian kernel in sparse Bayesian learning framework for nonlinear regression[J]. Expert Systems with Applications. 2009,36(2): 3982-3989.
- [7] 张宇航,张晔. SVM和RVM对高光谱图像分类的应用潜能分析[J]. 哈尔滨工业大学学报,2012,44(3): 34-39.
- [8] 申争光,朱凤宇,王祁. 基于PFP-WRVM的多功能传感器状态自确认研究[J]. 仪器仪表学报,2012,33(9): 1986-1994.
- [9] SILVA C, RIBEIRO B. Two-level hierarchical hybrid SVM-RVM classification model [C]//5th International Conference on Machine Learning and Applications. Orlando, FL: ICMLA,2006:89-94.
- [10] WANG Haiying, ZHENG Huiru. A bayesian approach to improving decision making in support vector machine and its application in bioinformatics [C]//Fifth International Conference on Natural Computation. Tianjin: ICNC,2009(2), 89-93.
- [11] DI You, HAMSICI O C, MARTINEZ A M. Kernel optimization in discriminant analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2011,33(3): 631-638.

(编辑 张宏)