

激光与光电子学进展

基于 Online-SVR 模型的光纤陀螺零漂实时补偿

毛宁, 许江宁, 何泓洋*, 吴苗

海军工程大学电气工程学院, 湖北 武汉 430033

摘要 光纤陀螺(FOG)的零漂补偿是提高其工作精度的主要方法之一。为了实现 FOG 零漂的实时在线补偿, 利用基于增量学习的在线支持向量机回归(Online-SVR)方法建立 FOG 零漂实时补偿方案, 并提出了一种基于滑动平均的温度变化率实时获取方法, 可以实现温度变化率的稳定获取以满足在线补偿的要求。通过分析和预处理 FOG 在 $-15\sim 50\text{ }^{\circ}\text{C}$ 范围内的实测数据, 分别进行径向基神经网络、支持向量机回归以及基于增量学习的在线支持向量机回归建模, 并对原始零漂和三种模型补偿后的剩余零漂进行 Allan 方差分析。结果表明: 在线支持向量机回归模型实现在线补偿的同时, 具有较其他两种模型更好的补偿精度和稳定性, 适用于 FOG 零漂数据的在线补偿。

关键词 光纤光学; 光纤陀螺; 零漂; 滑动平均; 在线支持向量机回归; 实时补偿

中图分类号 U666.1

文献标志码 A

doi: 10.3788/LOP202259.0106002

Real-Time Compensation of Fiber Optic Gyroscope Zero-Drift Based on Online-SVR Model

Mao Ning, Xu Jiangning, He Hongyang*, Wu Miao

College of Electrical Engineering, Naval University of Engineering, Wuhan, Hubei 430033, China

Abstract The zero-drift compensation of fiber optic gyroscope (FOG) is one of the main methods to improve the working accuracy of FOG. To achieve FOG zero-drift real-time online compensation, an online support vector machine regression (Online-SVR) method based on incremental learning is used to establish the FOG zero-drift real-time compensation scheme. In addition, a real-time temperature change rate acquisition method based on moving average is proposed, which can achieve stable temperature change rate acquisition to meet the requirements of online compensation. The radial basis function neural network, support vector machine regression, and Online-SVR are established by analyzing and preprocessing the measured data of FOG in the range of $-15\text{ }^{\circ}\text{C}\sim 50\text{ }^{\circ}\text{C}$. At full temperature, Allan variance is used to analyze the raw and residual zero-drift after compensation of the three models. The results show that the Online-SVR model not only realizes online compensation, but also has better compensation accuracy and stability than the other two models, making it more suitable for online compensation of FOG zero-drift data.

Key words fiber optics; fiber optic gyroscope; zero-drift; moving average; online support vector machine regression; real-time compensation

1 引言

光纤陀螺(FOG)是一种基于 Sagnac 效应的光

纤传感器, 用来测量运载体相对惯性空间的转动。由于其优势明显, 并且精度达到了很高的水平, 目前已经广泛应用于军事和航天等领域。研究表明,

收稿日期: 2021-02-07; 修回日期: 2021-04-01; 录用日期: 2021-04-13

基金项目: 国家自然科学基金(41804076)、湖北省自然科学基金(2018CFB544)

通信作者: *xgdhehongyang@163.com

FOG 的零漂误差可以分为常值漂移和随机漂移^[1]。常值漂移可以通过陀螺测试和标定实验建立准确的数学模型,采用多次求和取平均的方法加以补偿。随机漂移是一个随机非线性过程,无法建立准确的数学模型,而一些优化算法和时间序列预测方法等能够较好逼近非线性问题^[2-4],近些年受到人们越来越多的关注。

国内外相关研究大多基于测试数据进行零漂误差的建模与补偿。文献[5]将自回归滑动平均模型应用到 FOG 随机漂移误差的滤除,实测数据证明,滤波前后 FOG 主要误差源减小到了 50%。但该方法需要对陀螺信号进行平稳、正态和零均值处理,缺乏实时性。文献[6]采用了一种基于优化预测数据的误差反向传播(BP)神经网络算法,可以有效降低 FOG 数据中存在的随机白噪声对模型补偿精度的影响。但神经网络的建立与学习过程属于非确定性多项式难题(NP 问题),一般很难找到合适的网络结构。文献[7]建立了一种非平稳零漂误差的 ARIMA 模型,该模型可以对零漂误差进行实时卡尔曼滤波估计,取得了较好的效果。

本文首先从支持向量机回归(SVR)原理出发,分析了在线支持向量机回归(Online-SVR)模型的建立过程;然后根据 FOG 的零偏误差特性,建立了基于 Online-SVR 算法的在线补偿模型,并利用 FOG 实测数据进行验证;最后利用 Allan 方差分析法,通过对比补偿前后陀螺数据的几种主要误差参数,验证了所提模型的有效性。

2 Online-SVR 模型的建立

2.1 ϵ -SVR 模型

SVR 是支持向量机(SVM)在回归问题上的应用,但两种方法的输出数据在取值上有所不同^[8]。SVM 分类问题的输出数据只能有两个数值,但回归问题的输出数据可以为任意实数,求解回归问题就是通过一个非线性映射 Φ 将输入数据映射到高维特征空间,然后在特征空间进行线性回归^[9]。因此,回归问题就是根据数据集 $G = \{(x_i, y_i)\}_{i=1}^l$,寻找回归函数,

$$f(x, \Delta) = (\omega, x) + b, \quad (1)$$

式中: (ω, x) 为 ω 和 x 的内积; b 为系数; Δ 为参数集合。

一般来说,回归函数 $f(x, \Delta)$ 可以用极小化经验风险泛函 $R_{emp}(f)$ 得到,但所得解是基于样本近似误

差的极小化,并不是实际风险的极小化,所以可能会导致比较差的泛化能力。根据统计学习理论,极小化经验风险泛函 $R_{emp}(f)$ 一致收敛于极小化实际风险 $R(f)$, 即

$$P \left\{ \sup_{f \in F} [R(f) - R_{emp}(f)] \geq \epsilon \right\} \leq 4N_1 \left(\frac{\epsilon}{16}, F, 2l \right) \exp \left(- \frac{\epsilon^2 l}{32} \right), \quad (2)$$

式中: ϵ 为任一正实数; l 为样本的数目; N_1 为函数类 F 的覆盖样本数,是一种在尺度 $\epsilon (\epsilon > 0)$ 下表示 F 丰富性的度量。

对任意的 $f \in F$, 令置信风险 $\epsilon_f(f)$ 为

$$\epsilon_f(f) = R(f) - R_{emp}(f). \quad (3)$$

从(3)式可以得到,极小化 $R(f)$ 意味着极小化 $R_{emp}(f) + \epsilon_f(f)$, 通过这种方法可以找到学习机 f^* , 即结构风险最小化(SRM)原理。

在实际应用中,SVR 是通过以下优化问题来寻找最优解的,即

$$\min \frac{1}{2} \|x\|^2 + C \sum_{h=1}^n (\xi_h + \xi_h^*) \quad \text{s.t.} \quad R_{emp}(f) = 0, \quad (4)$$

式中: $\|x\|$ 表示求解 x 的欧几里得范数; C 为惩罚系数; ξ_h 和 ξ_h^* 为松弛变量。

SVR 方法就是通过寻找一个最优的分类面, 从而使得所有训练样本离该分类面的误差达到最小值, 如图 1 所示。




图 1 SVR 基本原理图

Fig. 1 Basic schematic diagram of SVR

2.2 基于增量学习的 Online-SVR 模型

2.2.1 Online-SVR 算法原理

Online-SVR 算法属于时间序列分析, 是一种在线回归建模方法, 能够实现模型的在线动态更

新^[10-11]。增量 Online-SVR 模型与传统 SVR 模型的主要区别在于数据提供的方式^[12]。Online-SVR 模型中,数据是以有序的方式逐渐生成的,与传统的 SVR 方法相比,Online-SVR 方法在每一次迭代中所需的计算机开销并没有增加。

假设初始数据规模为 l , 对于 Hilbert 空间 H 中的任意正交基 $\rho_1, \rho_2, \dots, \rho_k$, 如果 $\theta \in H$, 则 $\sum_{r=1}^k \cos^2(\rho_r, \theta) = 1$, 其中 $\cos(\mathbf{x}, \mathbf{y})$ 指向量 \mathbf{x} 与 \mathbf{y} 夹角的余弦函数, 且有 $\cos(\mathbf{x}, \mathbf{y}) = \mathbf{x}^T \mathbf{y} \div (\|\mathbf{x}\| \times \|\mathbf{y}\|)$ 。存在一个向量序列 $\{\alpha_1, \alpha_2, \dots, \alpha_k\}$ 首先被构造, 其中 $\alpha_k = \Phi(x_i) y_j - \Phi(x_j) y_i, k = 1, 2, \dots, l(l-1)/2$, 然后再构造一个正交向量序列 $\{\beta_1, \beta_2, \dots, \beta_d\}$, 且

$$\beta_i = \frac{\alpha_i - \sum_{j=1}^d \beta_j (\beta_j^T \alpha_i)}{\left\| \alpha_i - \sum_{j=1}^d \beta_j (\beta_j^T \alpha_i) \right\|} \quad (5)$$

$d = \text{rank}\{\alpha_1, \alpha_2, \dots, \alpha_k\}$ 可以通过施密特正交化来得到。由于 $\{\mathbf{w}, \beta_1, \dots, \beta_d\}$ 为空间 H 中的一个正交基, 且每一个 $\Phi(x_i)$ 均属于 H , 则有

$$\sum_{j=1}^d \cos^2[\beta_j, \Phi(x_i)] + \cos^2[\mathbf{w}, \Phi(x_i)] = 1. \quad (6)$$

因此,

$$\|\mathbf{w}\| = \frac{y_i}{\|\mathbf{x}\| \sqrt{1 - \sum_{j=1}^d \cos^2[\beta_j, \Phi(x_i)]}} \quad (7)$$

所有的计算都可以转化成核函数的形式, 最优的核函数参数可以通过最小化 $\|\mathbf{w}\|$ 得到。当新的样本进入时, 即第 $(l+1)$ 个样本, 就需要去判断其是否适合当前的模型。如果符合, 如 $\alpha_{l+1} = \sum_{p=1}^d \beta_p \alpha_{l+1}^T \beta_p$, 则模型不变, 否则将会选择第 $l+1$ 个样本下的最优模型。为了计算方便, 依次计算 $A(d+1, i, j), B(d+1, i, j), \gamma_{d+1}, C(d+1, i, j), \beta_{d+1}$, 则

$$C(l, i, j) = B(l+i) y_j - B(l+j) y_i, \quad (8)$$

$$A(l, i, j) = K(x_l, x_i) y_i - K(x_l, x_j) y_i, \quad (9)$$

$$B(l+i) = \beta_i^T \Phi(x_i), \quad (10)$$

$$\gamma_j = \beta_j^T \Phi(x_i) = B(j, i^*), \quad (11)$$

式中: i^* 为 $\{1, 2, \dots, l\}$ 中的任意标记。

在此基础上, 想要获得最优模型, 只需要计算选择最优核时对应的最小化优化问题的开销。每

一次迭代中, 整个的计算开销与传统 SVM 训练相比没有增加。

2.2.2 Online-SVR 算法流程

Step1: (初始化)

Step1.1: 假定初始训练集 G 有 l 个样本。

Step1.2: 使用不同的核函数, $K_{er}(\sum) = \{K_1(\sum), K_2(\sum), \dots, K_p(\sum)\}$, 其中 $K_i(\sum)$ 为具有连续调节核参数 \sum 的第 i 个类型的核函数。

Step2: (最优核函数选取)

Step2.1: 对于每一个 $K_{\sum} = K(\sum) \in K_{er}(\sum)$, 求解最优化问题 $\Lambda^* = \arg \min_{\Lambda \in \sum} \{F(K_{\Lambda})\}$, 其中 $F(K) =$

$$\|\mathbf{w}\|^2 = \frac{y_i^2}{K(x_i, x_i) - \sum_{j=1}^d \gamma_j^2}.$$

Step2.2: 最优核为 $K^*(\sum^*) = K_{o^*}(\Lambda^*)$ 且 $o^* = \arg \min_{1 \leq i \leq p} [K_i(\Lambda^*)]$ 。

Step3: (在线学习循环)

3 FOG 零漂误差的 Online-SVR 在线补偿

3.1 温度变化率实时获取

FOG 零漂误差主要受温度、温度变化率等多种因素的影响, 具有很强的非线性特征^[13-14]。不同于离线模型, 要实现 FOG 零漂误差的在线补偿, 首先需要解决温度变化率的实时稳定获取问题。温度变化是一种时间序列问题, t 时刻的温度只与 t 时刻及 t 时刻之前的环境因素有关系。基于这一特点, 建立了一种基于滑动平均的温度变化率实时获取方法, 如图 2 所示。

构建一个长度为 K 的滑动窗口, 首先输出一段长度为 K 的温度数据, 则 $K/2$ 时刻的温度 T_1 为前 K 个温度数据的平均值。由此可得任意时刻 t 的温度变化率表达式为

$$\dot{T}(t) = \left[\frac{\sum_{t_1=t-K/2+1}^{t+K/2+1} T(t_1)}{K} - \frac{\sum_{t_2=t-K/2}^{t+K/2} T(t_2)}{K} \right] \times f, \quad (12)$$

式中: $T(t)$ 为 t 时刻的温度; $\dot{T}(t)$ 为 t 时刻的温度变化率; f 为温度数据输出频率。

选择合适的滑动平均窗口长度 K 的大小, 可以有效降低由温度传感器测量和数据传输过程带来

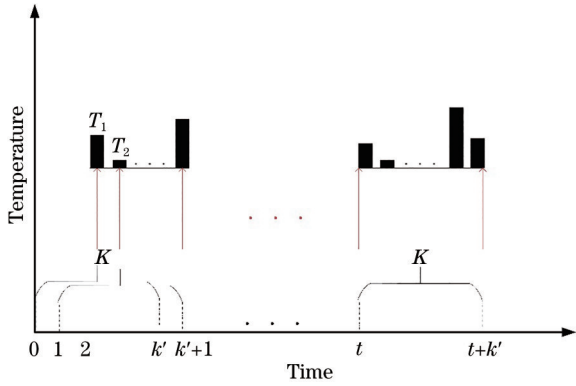


图 2 温度变化率实时获取原理

Fig. 2 Principle of real-time acquisition of temperature change rate

的噪声污染,同时可以克服温度测量频率较高时温度输出值在一定范围内相同,从而造成温度变化率为零的问题。

3.2 零漂误差在线补偿

将温度、温度变化率以及脉冲相关项作为 Online-SVR 模型的输入,FOG 零漂误差作为输出进行实时补偿。

根据 2.2.2 节的算法流程,首先获取一个样本量为 l 的初始训练集 G ,利用传统 SVR 方法得到一个初始模型 M_0 。当新的样本 $l+1$ 到达时,判断其是否适合当前的模型,如果符合则模型不变,否则将会选择 $l+1$ 个样本下的最优模型。在线补偿流程如图 3 所示。

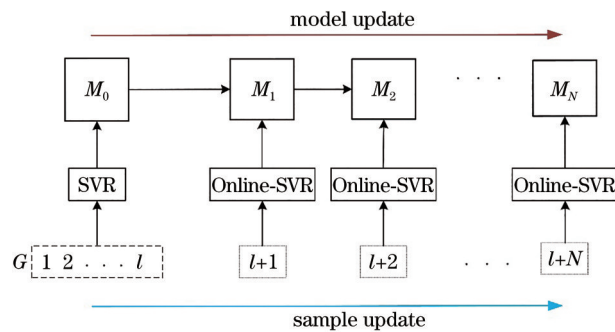


图 3 FOG 零偏在线补偿

Fig. 3 Online compensation of FOG zero-bias

4 FOG 实测数据验证

4.1 数据采集与预处理

在实验室的条件下,将某型光纤陀螺安装在温度控制实验水平转台上,采集静态条件下的陀螺输出。调整温控箱温度为 $-15\text{ }^\circ\text{C}$,降温 3 h 后开始通电实验,设定目标温度为 $50\text{ }^\circ\text{C}$ 。实验过程中系统采

样频率 $f=200\text{ Hz}$,采样时间约 5 h,并利用 PC 实现数据采集的可视化。

离线温度变化率 $\dot{T}(n_1)$ 的表达式为

$$\dot{T}(n_1) = \frac{T(n_1) - T(n_1 - 1)}{t}, \quad (13)$$

式中: n_1 为采样点。对温度数据和陀螺输出进行 1 min 滑动平均,得到平滑后的 FOG 原始输出、温度变化率以及温度随时间的变化,如图 4 所示。




图 4 FOG 原始输出、温度变化率和温度随时间的变化

Fig. 4 Original FOG output, temperature change rate, and temperature varying with time

4.2 FOG 零漂误差在线补偿

取滑动平均窗口长度 $K=12000$,每次移动长度为 1,根据 (12) 式计算实时的温度变化率 $\dot{T}(t)$ 。搭建 Online-SVR 模型进行实时补偿,并与传统 SVR 模型、径向基函数(RBF)神经网络模型的补偿效果进行对比分析,实验结果如图 5~7 所示。

另外,使用补偿前后的零漂均值和标准差来比较模型的补偿效果,利用平均绝对误差(MAE)和均方根误差(RMSE)对比三种模型补偿的稳定性和效果,如表 1 所示。补偿用时(从计算温度变化率到输出补偿结果为一个数据点的补偿用时,补偿所有数据点的时间为总补偿用时)如表 2 所示,总数据点为 15000 个。

MAE 和 RMSE 越小,表明模型补偿的效果越好,计算表达式分别为

$$E_{\text{RMS}}(X, h) = \sqrt{\frac{1}{m} \sum_{s=1}^m [h(x^{(s)}) - y^{(s)}]^2}, \quad (14)$$

$$E_{\text{MA}}(X, h) = \frac{1}{m} \sum_{s=1}^m |h(x^{(s)}) - y^{(s)}|, \quad (15)$$

式中: X 为样本数据集; h 为预测函数; $h(x^{(s)})$ 为第 s 个样本的预测值; m 为样本总量。从表 1 和表 2 可以看出,Online-SVR 模型实现在线补偿的同时,具有比 RBF 神经网络和传统 SVR 模型更好的补偿精度和

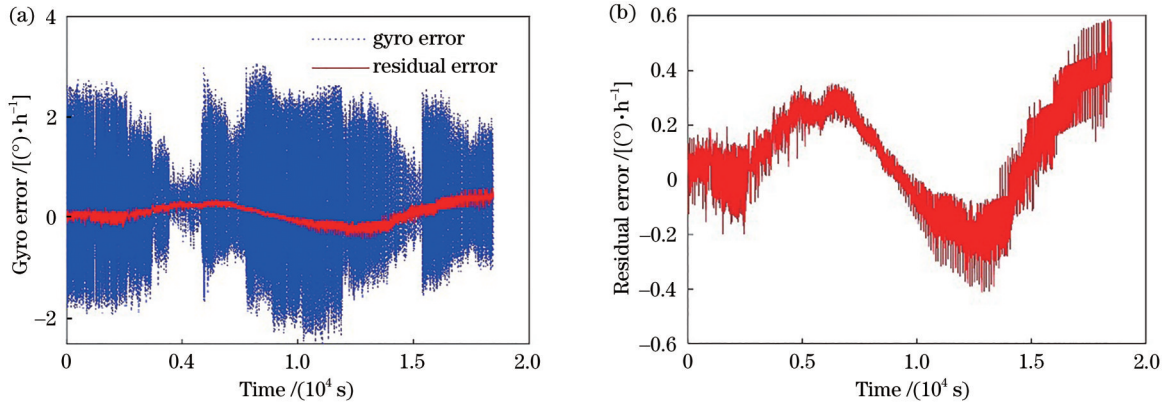


图 5 RBF 神经网络补偿效果。(a)陀螺零漂补偿曲线;(b)剩余误差

Fig. 5 Compensation effect of RBF neural networks. (a) Zero-drift compensation curve of gyro; (b) residual error

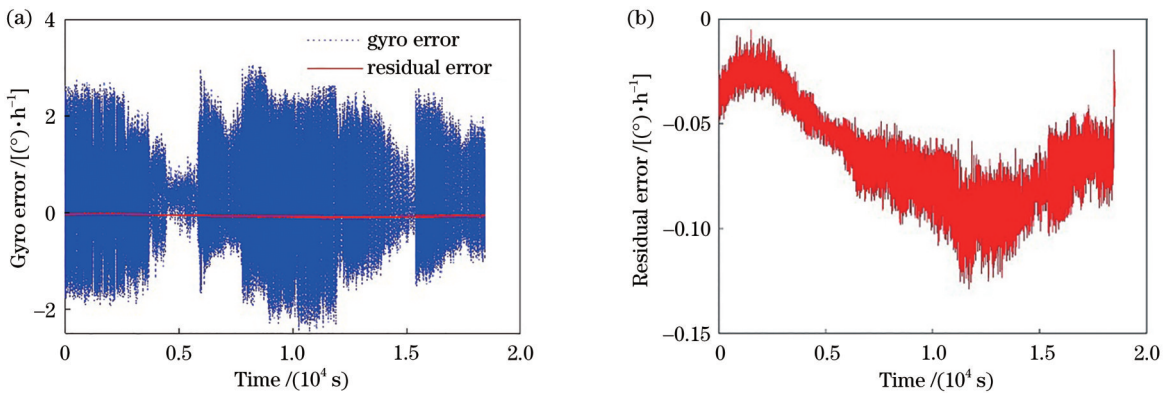


图 6 SVR 补偿效果。(a)陀螺零漂补偿曲线;(b)剩余误差

Fig. 6 Compensation effect of SVR. (a) Zero-drift compensation curve of gyro; (b) residual error

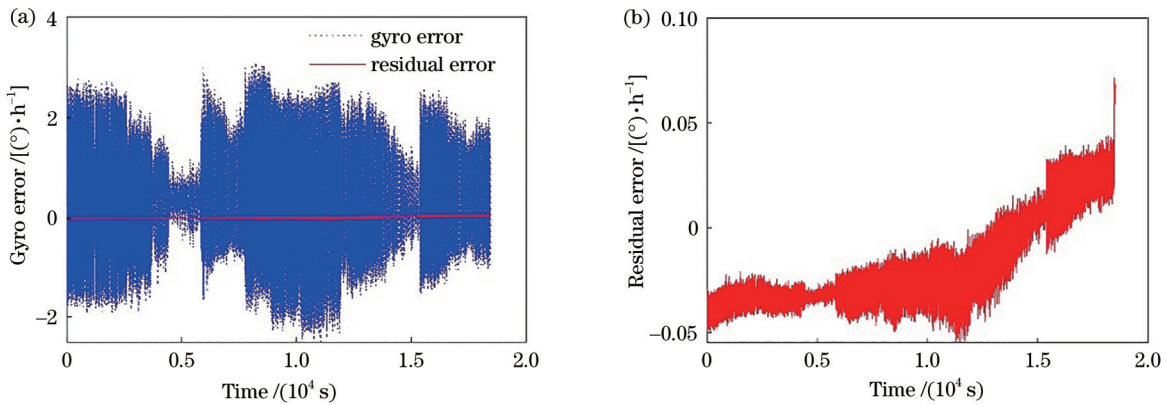


图 7 Online-SVR 补偿效果。(a)陀螺零漂补偿曲线;(b)剩余误差

Fig. 7 Compensation effect of Online-SVR. (a) Zero-drift compensation curve of gyro; (b) residual error

表 1 陀螺零漂数据补偿前后统计量比较

Table 1 Comparison of statistical results before and after the compensation for FOG zero-drift data unit: $(^{\circ}) \cdot h^{-1}$

Scheme	Average	Standard deviation	MAE	RMSE
Before compensation	0.3082	1.1204		
RBF neural network	0.0897	0.1888	0.1744	0.2091
SVR	-0.0643	0.0235	0.0643	0.0685
Online-SVR	-0.0173	0.0217	0.0253	0.0278

表 2 补偿用时

Table 2 Compensation time

unit: s

Scheme	Time of all compensation points	Average time per compensation point
RBF neural network	58.27	3.9×10^{-3}
SVR	15.80	1.1×10^{-3}
Online-SVR	6.19	4.13×10^{-4}

稳定性,且运算效率高,满足补偿的实时性要求。

对原始和不同模型补偿后 FOG 零漂误差进行 Allan 方差分析,如表 3 所示,通过对比模型补偿前

后 FOG 的角度随机游走、零偏不稳定性和角速率随机游走这三种噪声的大小可以得到,Online-SVR 模型具有最优的实时补偿效果。

表 3 补偿前后噪声源误差系数比较

Table 3 Comparison of error coefficients of noise before and after compensation

Scheme	Noise in angular random walk /	Noise in bias instability /	Noise in rate random walk /
	$[(^{\circ}) \cdot \text{h}^{-1/2}]$	$[(^{\circ}) \cdot \text{h}^{-1}]$	$[(^{\circ}) \cdot \text{h}^{-3/2}]$
Before compensation	9.33×10^{-4}	1.57×10^{-2}	4.49×10^{-2}
RBF neural network	1.61×10^{-3}	4.46×10^{-3}	4.41×10^{-2}
SVR	1.83×10^{-4}	2.90×10^{-3}	1.71×10^{-2}
Online-SVR	2.21×10^{-4}	1.81×10^{-3}	1.57×10^{-2}

5 结 论

对某型 FOG 全温下的零漂实测数据进行分析 and 预处理,提出了一种基于滑动平均的温度变化率实时获取方法和基于增量学习的 Online-SVR 模型,分别用 RBF 神经网络模型、SVR 模型和 Online-SVR 模型对 FOG 零漂进行实时在线补偿。结果表明:RBF 神经网络模型计算量较少,但对于 FOG 零漂这类非线性程度很高的数据,补偿效果一般;SVR 模型补偿精度稍好,但是运算复杂,且稳定性较差;Online-SVR 模型实现在线补偿的同时,具有更好的补偿精度和稳定性,适用于 FOG 零漂数据的在线补偿。

参 考 文 献

- [1] Li X, Wang L X, Shen Q. Prediction of the random error of a laser gyroscope using the modified GM(1, 1) model[J]. Acta Optica Sinica, 2020, 40(12): 1204001.
李想, 汪立新, 沈强. 基于改进 GM(1, 1)模型的激光陀螺仪随机误差预测[J]. 光学学报, 2020, 40(12): 1204001.
- [2] Wang N, Er M J, Han M. Generalized single-hidden layer feedforward networks for regression problems [J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26(6): 1161-1176.
- [3] Yan H, Yang Y H, Yang F L. Response model and compensation technology of thermal diffusion delay in fiber optic gyro coil[J]. Chinese Journal of Lasers, 2019, 46(1): 0106003.
闫晗, 杨远洪, 杨福铃. 光纤陀螺环热扩散延迟响应模型及补偿技术研究[J]. 中国激光, 2019, 46(1): 0106003.
- [4] Chen X Y, Wang W. Extracting and compensating for FOG vibration error based on improved empirical mode decomposition with masking signal[J]. Applied Optics, 2017, 56(13): 3848-3856.
- [5] Sun J, Xu X S, Liu Y T, et al. FOG random drift signal denoising based on the improved AR model and modified sage-husa adaptive Kalman filter[J]. Sensors, 2016, 16(7): E1073.
- [6] Guo S L, Xu J N, Li F, et al. Modeling and compensation algorithm of FOG temperature drift with optimized BP neural network[J]. Journal of Chinese Inertial Technology, 2016, 24(1): 93-97.
郭士萃, 许江宁, 李峰, 等. 优化 BP 神经网络的光纤陀螺温度漂移建模与补偿[J]. 中国惯性技术学报, 2016, 24(1): 93-97.
- [7] Wang Z, Li J C. Research on the real-time compensation of the fiber optic gyroscope random drift in airborne vector gravimetry[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(2): 144-150.
王峥, 李建成. 航空矢量重力测量中光纤陀螺随机漂移误差实时补偿方法[J]. 测绘学报, 2017, 46(2): 144-150.
- [8] Zhou Z H. Machine learning[M]. Beijing: Tsinghua University Press, 2016: 121-137.

- 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 121-137.
- [9] Wang W J, Meng C J. Support vector machine modeling and application[M]. Beijing: Science Press, 2014.
- 王文剑, 门昌骞. 支持向量机建模及应用[M]. 北京: 科学出版社, 2014.
- [10] Mei F, Pan Y, Zhu K D, et al. A hybrid online forecasting model for ultrashort-term photovoltaic power generation[J]. Sustainability, 2018, 10(3): 820.
- [11] Liu J, Zio E. An adaptive online learning approach for support vector regression: online-SVR-FID[J]. Mechanical Systems and Signal Processing, 2016, 76/77: 796-809.
- [12] Esposito G, Martin M. Bellman residuals minimization using online support vector machines[J]. Applied Intelligence, 2017, 47(3): 670-704.
- [13] Liu Y Y, Yang Y B, Feng W S, et al. Self-assessment technique for fiber optic gyroscope test environment based on Fourier transform[J]. Acta Optica Sinica, 2019, 39(4): 0406002.
- 刘元元, 杨永斌, 冯文帅, 等. 基于傅里叶变换的光纤陀螺测试环境自评估技术[J]. 光学学报, 2019, 39(4): 0406002.
- [14] Wang W, Chen X Y. Multiscale modeling of fiber optic gyroscope temperature drift based on improved ensemble empirical mode decomposition[J]. Applied Optics, 2018, 57(28): 8443-8450.