

doi: 10.7690/bgzdh.2024.02.015

# ELM-AdaBoost 模型在光纤陀螺温度误差补偿中的应用

王 瑞, 郑百东, 李 飞, 刘 伟, 戴洪德

(海军航空大学航空基础学院, 山东 烟台 264001)

**摘要:** 针对光纤陀螺零偏与温度之间复杂的非线性关系, 引入极限学习机(extreme learning machines, ELM)模型补偿光纤陀螺的零偏温度误差; 针对单个 ELM 在预测准确性和稳定性不足及其对奇异样本敏感的问题, 引入自适应增强算法(adaptive boosting, AdaBoost)建立 ELM-AdaBoost 预测模型改善光纤陀螺性能, 分析光纤陀螺的温度误差机理及模型参数对预测精度的影响, 给出 ELM 算法隐含层神经元个数及 AdaBoost 算法迭代次数的确定方法。仿真结果表明: 基于 ELM-AdaBoost 预测模型的补偿效果优于多元线性回归模型和单个 ELM 神经网络模型, 并具有良好的泛化性能和温度适用性, 补偿后陀螺零偏均方根误差降低 93%以上, 显著改善了光纤陀螺零偏稳定性能。

**关键词:** 光纤陀螺; 温度零偏误差; ELM-AdaBoost 预测模型; 模型参数; 零偏稳定性

中图分类号: TJ765.2<sup>+31</sup>; V241.5<sup>+33</sup> 文献标志码: A

## Application of ELM-AdaBoost Model in Temperature Error Compensation of Fiber Optic Gyroscope

Wang Rui, Zheng Baidong, Li Fei, Liu Wei, Dai Hongde

(School of Aviation Foundation, Naval Aviation University, Yantai 264001, China)

**Abstract:** For the complex nonlinear relationship between zero bias and temperature of fiber optic gyro (FOG), extreme learning machines (ELM) model is introduced to compensate the zero bias temperature error of FOG. Aiming at problems of insufficient prediction accuracy and stability of a single ELM and its sensitivity to singular samples, the adaptive boosting (AdaBoost) algorithm is introduced to establish an ELM-AdaBoost prediction model to improve the FOG performance. The temperature error mechanism of fiber optic gyroscope and the influence of model parameters on the prediction accuracy are analyzed, and the determination methods of the number of neurons in the hidden layer of ELM algorithm and the number of iterations of AdaBoost algorithm are given. The simulation results show that. The compensation effect based on ELM-AdaBoost prediction model is better than the multiple linear regression model and single ELM neural network model, and has good generalization performance and temperature applicability, and the root mean square error of gyro zero bias is reduced by more than 93% after compensation, which significantly improves the stability performance of fiber optic gyro zero bias.

**Keywords:** fiber optic gyro; temperature bias error; ELM-AdaBoost prediction model; model parameters; bias stability

## 0 引言

光纤陀螺仪因其可靠性高、重量轻、动态范围大、易于集成等优点, 已被广泛应用于军事和民用领域。光纤陀螺仪的基本原理是通过检测光纤环中 Sagnac 效应引起的相位差, 进而推算出载体旋转角速度。想要获得准确的角速度信息, 必须完全识别和抑制所有其他的非互易效应<sup>[1-2]</sup>。由于构成光纤陀螺的核心部件对温度非常敏感, 温度的变化会引起光纤环折射率和应力的改变, 导致光纤陀螺零偏随温度变化, 严重制约着光纤陀螺的精度和应用; 因此, 需要采取一定的措施来改善光纤陀螺的热致非互易性效应<sup>[3]</sup>。

在工程上通常采用 2 种方法来降低温度变化对

光纤陀螺输出的影响: 1) 利用温控设备缩小温度变化范围; 2) 通过寻找陀螺输出零偏误差与温度的关系建立辨析模型, 来补偿温度变化带来的输出误差。建立温度模型补偿零偏误差相对于硬件的温度控制方法具有成本低、灵活性高、适用性强等优点, 随着人工智能技术的快速发展, 通过算法补偿光纤陀螺温度误差受到广泛关注, 具有非常重要的实际应用价值。

工程上常用的方法是建立温度与陀螺输出零偏误差之间的线性模型、支持向量机(support vector machine, SVM)<sup>[4-5]</sup>、BP(back propagation)神经网络等模型<sup>[6]</sup>, 但这些模型存在优化参数多、学习时间长和易陷入局部最优解等缺点, 难以准确地描述各温度因素与光纤陀螺输出零偏误差之间的关系。

收稿日期: 2023-10-10; 修回日期: 2023-11-15

基金项目: 山东省自然科学基金(ZR2017MF036); 山东省高等学校青年创新团队项目(2020KJN003); 国防科技项目基金项目(F062102009)  
第一作者: 王 瑞(1983—), 男, 河南人, 博士。

极限学习机(ELM)是一种单隐层前馈神经网络算法,相较于传统BP神经网络具有优化参数少、运算速度快的特点,已被广泛应用于故障检测<sup>[7]</sup>、风速预测<sup>[8]</sup>等工程实际领域,但因其输入权重和隐含层偏置的随机初始化,使得ELM预测结果常常不稳定。文献[9]证明了集成建模是提高单一模型稳定性和准确性的有效方式。

笔者将单个ELM作为弱预测器,运用自适应增强算法(AdaBoost)集成策略,集成多个ELM网络的输出得到强预测模型,运用于光纤陀螺的温度误差补偿中,最后通过实验验证了本文中方法的有效性。

## 1 光纤陀螺温度误差机理分析

光纤陀螺的重要组成部件如光纤环、Y波导、光电检测器等对温度较为敏感,温度场的变化会使其偏离正常工作状态,从而引入温度误差。对光纤陀螺来说,其温度误差主要来自2方面:1)由于光纤折射率热涨落产生的相位噪声,该噪声与光纤的长度和绝对温度的平方成正比<sup>[10]</sup>;2)被称为Shupe效应的温度零偏误差,主要来源于纤芯折射率的变化与光纤材料的膨胀<sup>[11]</sup>。文献[12]推导出了在光纤环中沿相反方向传播的干涉光,由于热致非互易性产生的相位延迟为:

$$\Delta\phi = \beta_0 (\partial n / \partial T + n\alpha) / c_q \int_0^{L/2} [(\dot{T}(l, t) - \dot{T}(L-l, t)) (L-2l)] dl. \quad (1)$$

式中: $\beta_0=2\pi/\lambda_0$ 为光在真空中的传播常数; $c_q=c_0/n$ 为光在光纤中的光速; $n$ 为光纤的折射率; $\partial n / \partial T$ 为光纤折射率的温度系数; $\alpha$ 为石英的热膨胀系数; $L$ 为光纤环的长度; $\dot{T}(l, t)$ 为温度在 $l$ 处温度变化速率。

通过式(1)分析可以看出,改善光纤陀螺温度零偏误差最明显的方法是寻找折射率温度系数较小的光纤材料,其次为优化光纤线圈绕制技术,使得与线圈中心距离相等的光纤部分彼此相邻。目前主要从合理设计和改善陀螺结构、改善光纤环绕制方式、采用合适的温控装置、通过热力学分析和实验研究辨识动静态光纤陀螺温度模型4方面,补偿光纤陀螺的温度零偏误差。

## 2 ELM-AdaBoost 预测模型

### 2.1 极限学习机

极限学习机是由黄广斌教授提出的单隐层前馈

神经网络算法,其核心在于隐含层参数随机生成,初始设置参数均独立于训练数据,极大降低了网络训练时间消耗,该算法在学习训练过程中,不需要对输入的偏置和权重进行调整,只需设置神经元个数和隐含层函数,便可获得唯一最优解<sup>[13]</sup>。

典型单隐层前馈神经网络如图1所示,该网络结构可分为输入层、隐含层以及输出层,3层之间采用全连接。

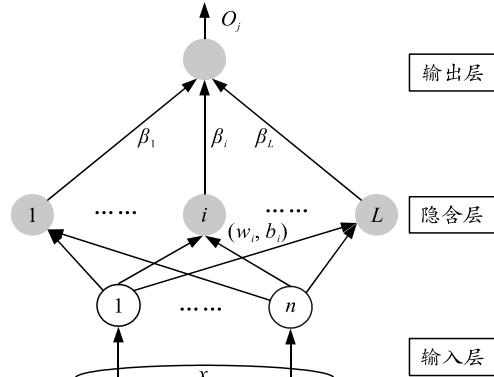


图1 典型的单隐层前馈神经网络结构

对于单隐层神经网络 $N$ 个任意样本 $(X_i, t_i)$ ,其中: $X_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ , $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$ ,含有 $L$ 个隐含层节点的神经网络输出为:

$$\sum_{i=1}^L \beta_i f(W \times X_j + b_i) = o_j, \quad i=1, \dots, N. \quad (2)$$

式中: $f(x)$ 为激活函数; $W_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 为输入权重; $\beta_i$ 为输出权重; $b_i$ 为第 $i$ 个隐含层单元的偏置; $W \times X_j$ 为 $W$ 和 $X_j$ 的内积。

### 2.2 ELM-AdaBoost 预测模型

AdaBoost 算法是一种重要的集成学习技术,能够将预测精度低的弱学习器增强为预测精度高的强学习器,在直接构造强学习器困难的情况下,为学习算法的设计提供了一种新思路和新方法。该算法的核心是在同一训练集上训练出不同的学习器,通过改变权值的分配,将所有的训练器集合起来形成强学习器。它不需要知道弱学习器的精度下限,因此非常适合应用于实际问题<sup>[14]</sup>。

将单个的ELM神经网络作为弱学习器,ELM-AdaBoost算法流程如下:

给定一个训练数据集 $T=\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ ,其中 $x, y \in R^n$ 。

1) 初始化训练数据的权值分布。每一个训练样本最开始都被赋予相同的权值: $W_1(i) = 1/N$ , $i = 1, 2, \dots, N$ 。

2) 进行多轮迭代, 用  $m=1, 2, 3, \dots, M$  表示迭代的次数。

① 训练弱学习器  $s$ , 得到弱学习预测函数  $h_m(x): x \rightarrow y$ 。

② 对于满足  $|h_m(x_i) - y_i| > \varepsilon$  的样本计算:

$$e_m = \sum_{i=1}^N W_m(X_i)。 \quad (3)$$

由上式可知, 弱预测函数在训练数据集上的误差  $e_m$  就是未达到训练精度要求的数据权值和。

③ 计算  $h_m(x)$  的系数:  $\alpha_m$  表示  $h_m(x)$  在最终学习器的重要程度(目的: 得到基分类器在最终学习器中的权重):

$$\alpha_m = \frac{1}{2} \ln \frac{1 - e_m}{e_m}。 \quad (4)$$

由上式可知,  $e_m \leq 1/2$  时,  $\alpha_m \geq 0$  且  $\alpha_m$  随着  $e_m$  的减小而增大, 意味着误差越小的弱学习器在最终学习器中的作用越大。

④ 更新训练数据集的权值分布, 得到样本新的权值分布, 用于下一轮迭代:

$$W_{m+1}(i) = (w_{m+1,1}, w_{m+1,2}, \dots, w_{m+1,i}, \dots, w_{m+1,N}); \\ w_{m+1,i} = \frac{w_{mi}}{Z_m} \exp(-\alpha_m y_i h_m(x_i)), \quad i = 1, 2, \dots, N。 \quad (5)$$

使得在弱学习器  $h_m(x)$  未达到训练精度的数据权值增大, 而被正确分类样本的权值减小, 通过这样的方式, AdaBoost 方法能“重点关注”或聚焦于“那些较难预测的样本上”。其中  $Z_m$  是规范化因子, 使得  $h_m(x)$  成为一个概率分布:

$$Z_m = \sum_{i=1}^N w_{mi} \exp(-\alpha_m y_i h_m(x_i))。 \quad (6)$$

3) 组合各个弱学习器。

$$H(x_i) = \sum_{m=1}^M \alpha_m f(h_m(x_i), \alpha_m)。 \quad (7)$$

即得到满足精度要求的强学习器  $H(x_i)$ 。

### 3 模型结构参数确定

#### 3.1 单个 ELM 结构的确定

对于单个 ELM 来讲, 隐含层神经元个数越多, 网络的输出精度越高。然而, 神经元个数越多, 网络输出层的重叠性增加, 导致无法产生不同的响应曲线, 预测模型的精度反而下降。为确定神经元的个数, 选取 10 次 ELM 算法得到的拟合均方根误差 (root mean square error, RMSE) 的平均值作为评价指标。模型的输入为温度、温度速率、温度与温度

速率的乘积项。预测误差结果如图 2 所示, 预测均方根误差表示为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}。 \quad (8)$$

式中:  $y_i$  为陀螺实际输出值;  $\hat{y}_i$  为模型预测值。

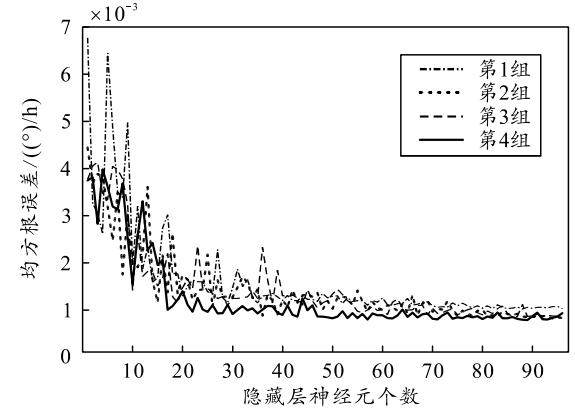


图 2 单个 ELM 预测误差与神经元个数的关系

从上图中可以看出, 隐含层神经元个数为 30 时, 既能保证单个 ELM 的预测精度, 同时还能保证弱学习器输出的多样性。

#### 3.2 AdaBoost 迭代次数的确定

在集成模型中, 既要确定单个神经元的结构, 也要确定集成的弱学习器的个数, 即 AdaBoost 算法的迭代次数  $L$ <sup>[15]</sup>。选取迭代次数在 1~100 之间变化, 每个  $L$  值计算 5 次, 取平均值作为最终的强学习器误差, 通过观察测试样本中的均方根误差随迭代次数的变化来确定最佳的  $L$  值。

AdaBoost 集成学习误差随迭代次数的变化如图 3 所示。选择最小均方根误差对应的迭代次数作为 ELM-AdaBoost 算法集成的 ELM 个数, 避免出现过学习。从图中可以看出, 随着迭代次数的增加预测误差缓慢减小, 并且在迭代次数过多时, 出现误差不稳定现象, 据此笔者选取迭代次数为 60。

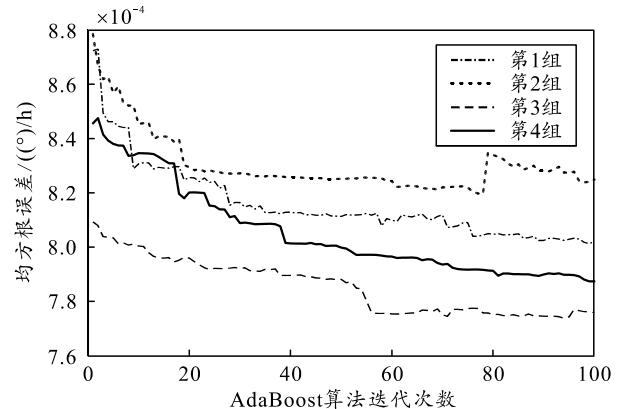


图 3 预测误差与 AdaBoost 迭代次数的关系

## 4 实验设计及结果分析

本次实验以某型惯性组件的光纤陀螺为研究对象，将其安装在带有温控箱的水平转台上，转台保持静止状态，为消除陀螺的标度因数对温度零偏误差的影响，将陀螺输入参考轴置于水平面内，并使参考轴与东向之间夹角为零，即可满足条件  $\phi_s = 0$ 。采用热循环的试验方式，陀螺启动后，调节温控箱，不断升温降温，每隔 1 s，输出一组温度( $T$ )和陀螺漂移数据( $D$ )，实验测量-10~50 °C 温度区间变化时的零漂，温度变化速率为 0.2~1 °C/min。实测 3 组光纤陀螺温度及漂移数据如图 4—6 所示，其中第 1 组作为测试集，第 2、3 组作为验证集，将温度值的一次项、温度变化速率的一次项、温度与温度变化速率的乘积项作为 ELM-AdaBoost 预测模型的输入。

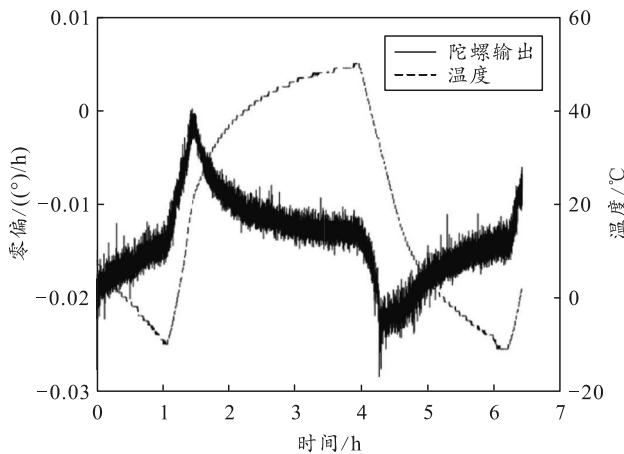


图 4 第 1 组陀螺零漂输出数据随温度变化曲线

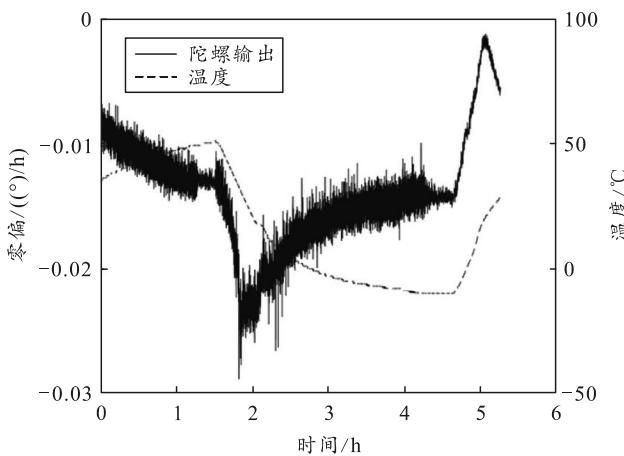


图 5 第 2 组陀螺零漂输出数据随温度变化曲线

对采集到的 3 组光纤陀螺温度漂移误差数据，分别建立多元线性回归模型、ELM 神经网络模型、ELM-AdaBoost 预测模型对其进行补偿，其中 ELM 隐含层神经元的个数为 30，激活函数  $f(\cdot)$  选择

Sigmoidal 曲线函数，学习系数定为 0.001，AdaBoost 迭代次数为 60。模型的预测输出为：

$$\hat{y} = \sum_{m=1}^{60} \omega_m \left( \sum_{i=1}^{30} \beta_i f(W_i \times X_j + b_i) \right) \quad (9)$$

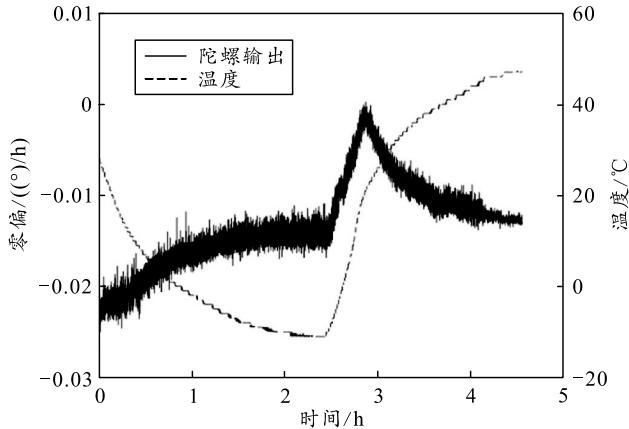


图 6 第 3 组陀螺零漂输出数据随温度变化曲线

利用训练样本，训练得到模型的权值  $\beta_i$ 、 $\omega_m$ 、 $W_i$  和偏置  $b_i$ 。首先对训练样本数据进行补偿，补偿效果如图 7 和 8 所示。

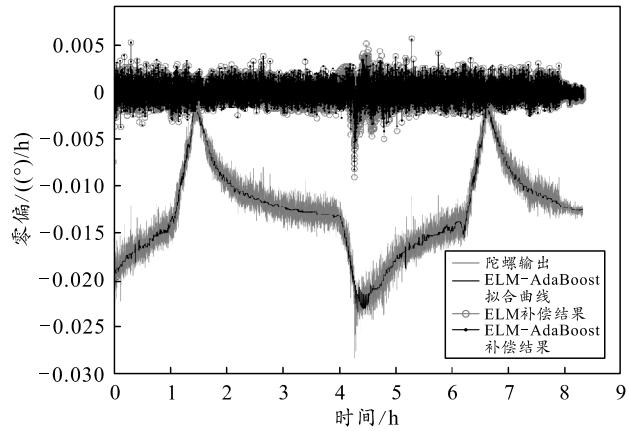


图 7 第 1 组陀螺数据补偿前后输出曲线

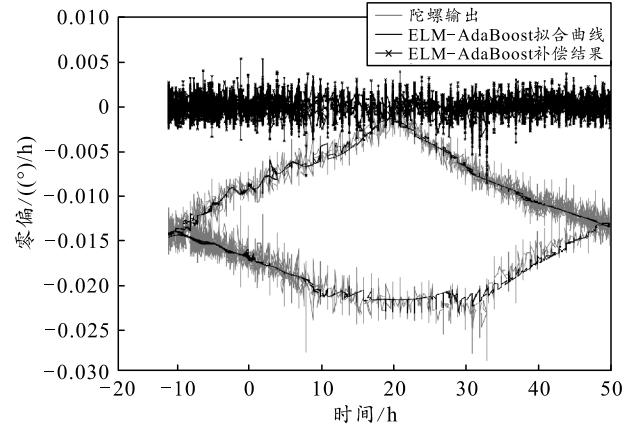


图 8 第 1 组陀螺数据补偿前后输出误差与温度项之间的关系曲线

以补偿前后陀螺数据总体均值 (ensemble average,

ENA)、RMSE、误差平方和 (sum of the squared errors, SSE)、极差 (range, R) 以及零偏稳定性 (biasstability, BS) 为指标衡量补偿效果, 补偿指标如表 1 所示。

表 1 测试组各模型补偿后性能指标对比

模型	ENA/(°)/h	RMSE/(°)/h	SSE/(°)/h	R/(°)/h	BS/(°)/h
陀螺输出	-0.012 8	0.013 6	5.545 3	0.028 7	1.654 1
多元线性回归模型	-1.775 1e-06	0.002 1	0.132 4	0.019 4	0.756 4
ELM 模型	4.162 5e-09	9.698 7e-04	0.024 1	0.014 7	0.322 8
ELM-AdaBoost 模型	7.454 5e-11	8.073 8e-04	0.019 5	0.013 4	0.290 7

在-10~50 °C 温度范围内, 补偿前均方根误差为 0.013 6 (°)/h, 误差平方和为 5.545 3 (°)/h<sup>2</sup>, 零偏稳定性为 1.654 1 (°)/h, 补偿后均方根误差为 8.073 8e-04 (°)/h, 减小 94.1%, 误差平方和为 0.019 5 (°)/h<sup>2</sup>, 减小 2~3 个数量级, 零偏稳定性 0.290 7 (°)/h, 减小 82.4%, 陀螺零偏数据总体均值趋近于 0。

相较于传统的多元线性回归模型, 本方法的均方根误差减小 61.5%, 误差平方和减小 85.2%, 零偏稳定性减小 61.5%, 零偏均值减小了 4~5 个数量级。说明本方法可大幅降低漂移均值, 补偿效果从各方面显著优于多元线性回归模型。

相较于单个 ELM 预测模型, 本方法的均方根误差减小 16.7%, 误差平方和减小 19.1%, 零偏稳定性减小 9.9%, 零偏均值减小了 2 个数量级, 说明本方法的确提升了单个 ELM 模型的预测准确性和稳定性。

为进一步检验模型效果, 将所建立的 ELM-AdaBoost 预测模型应用于验证集。使用测试集得到的模型, 补偿验证集光纤陀螺温度零偏误差, 补偿效果如图 9 和 10 所示。

2 组测试数据应用 ELM-AdaBoost 预测模型方法补偿后的性能指标如表 2 所示。补偿后 2 组陀螺零偏均方根误差降低 93.6%、94.4%, 误差平方和降低 2~3 个数量级, 零偏稳定性降低 78.6%、83.1%。2 组补偿后的陀螺温度漂移误差在零点附近波动。验证组与测试组温度变化规律不同, 但使用测试组得到的模型补偿后, 验证组仍能得到良好的补偿效果, 说明笔者提出的 ELM-AdaBoost 预测模型温度误差补偿方法具有良好温度适用性。

表 2 验证组 ELM-AdaBoost 模型补偿前后性能指标对比

指标	补偿前		补偿后	
	第 2 组	第 3 组	第 2 组	第 3 组
ENA/(°)/h	-0.014 0	-0.013 3	8.797 9e-05	1.721 2e-05
RMSE/(°)/h	0.014 7	0.014 1	9.404 5e-04	7.896 9e-04
SSE/(°)/h <sup>2</sup>	4.087 5	3.263 1	0.016 8	0.010 2
R/(°)/h	0.027 6	0.025 4	0.012 4	0.008 4
BS/(°)/h	1.577 8	1.685 5	0.337 1	0.284 2

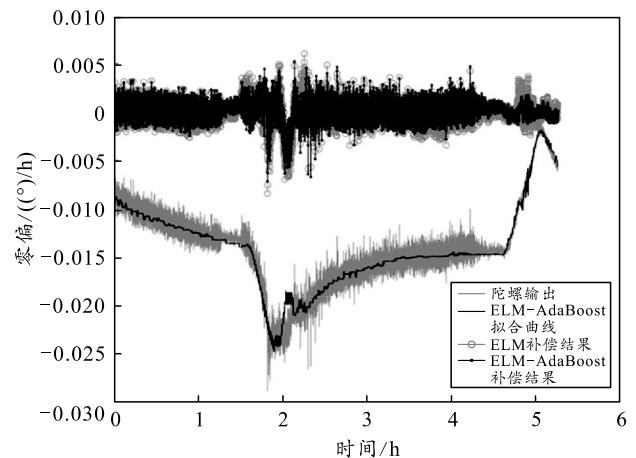


图 9 第 2 组陀螺补偿前后输出曲线

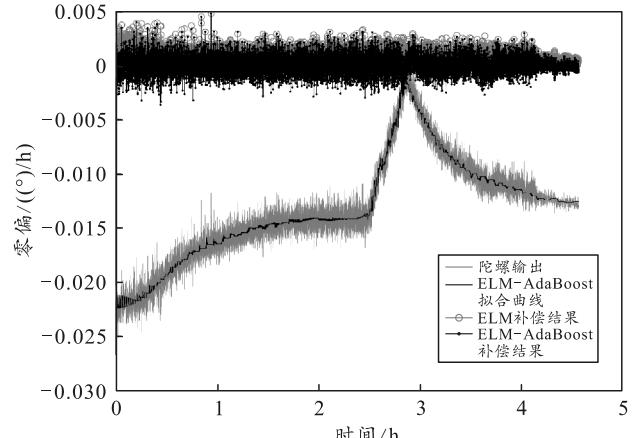


图 10 第 3 组陀螺补偿前后输出曲线

## 5 结论

笔者提出基于 ELM-AdaBoost 预测模型的光纤陀螺温度误差补偿方法, 并与多元线性回归模型、ELM 神经网络模型进行对比分析, 得出以下结论:

1) 集成神经网络学习算法中, 选择合适数量的隐含层神经元和弱学习器个数, 可在保证集成精度的情况下, 减小模型的复杂度, 提升模型运算速度, 笔者给出了参数的选取方法。

2) 单个 ELM 模型温度误差补偿精度从各方面显著优于多元线性回归模型, 说明陀螺零偏误差与温度相关项之间具有复杂的非线性关系, 多元线性

模型拟合精度有限。

3) ELM-AdaBoost 预测模型补偿相较于单个 ELM 预测模型各方面均有提升, 尤其是零偏均值方面效果最为明显, 说明该方法的确提升了单个 ELM 模型的预测准确性和稳定性。

通过多组实测测试组数据仿真验证, 充分说明了 ELM-AdaBoost 预测模型具有良好的温度适用性和泛化性能, 具有重要的工程实用价值。

## 参考文献:

- [1] 苑立波, 童维军, 江山, 等. 我国光纤传感技术发展路线图[J]. 光学学报, 2022, 42(1): 9–42.
- [2] 靳凯迪, 柴洪洲, 宿楚涵, 等. 顾及有色噪声的光纤陀螺随机噪声自适应滤波方法[J]. 测绘学报, 2022, 51(1): 80–86.
- [3] OSUNLUK B, OGUT S, OZBAY E. Thermally induced bias error due to strain inhomogeneity through the fiber optic gyroscope coil[J]. Applied optics, 2020, 59(33): 10416–10421.
- [4] 毛宁, 许江宁, 何泓洋, 等. 基于 Online-SVR 模型的光纤陀螺零漂实时补偿[J]. 激光与光电子学进展, 2022, 59(1): 118–124.
- [5] CAO Y, XU W Y, LIN B, et al. A method for temperature error compensation in fiber-optic gyroscope based on machine learning[J]. Optik, 2022, 256: 168765.
- [6] 李光耀, 侯宏录, 杜鹃, 等. 采用小波降噪和神经网络的 FOG 温度漂移补偿方法[J]. 光电工程, 2019, 46(9): 58–66.
- [7] XIN Y H, MING F H, XIAO H Y. A Novel Fault Diagnosis Method for TE Process Based on Optimal Extreme Learning Machine[J]. Applied Sciences, 2022, 12(7): 3388–3400.
- [8] LIAN L, KAN H. Ultra-short-term wind speed prediction based on variational mode decomposition and optimized extreme learning machine[J]. Wind Engineering, 2021, 46(2): 556–571.
- [9] LI W, MICHAEL H. Coastal Wetland Mapping Using Ensemble Learning Algorithms: A Comparative Study of Bagging, Boosting and Stacking Techniques[J]. Remote Sensing, 2020, 12(10): 1683–1700.
- [10] WANG Z, WANG G C, WANG Z C, et al. Incoherence suppression method of optical noises in a resonant fiber optic gyro based on the circularly polarized light propagation mechanism in a resonator[J]. Optics letters, 2021, 46(13): 3191–3194.
- [11] 杜石鹏. 基于有限元思想的光纤陀螺温度特性研究[D]. 哈尔滨: 哈尔滨工程大学, 2017.
- [12] SHUPE D M. Thermally induced nonreciprocity in the fiber-optic interferometer[J]. Applied Optics, 1980, 19(5): 654–655.
- [13] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1–3): 489–501.
- [14] MIRZA M B, MIAN M A, EL S M. AdaBoost-based artificial neural network learning[J]. Neurocomputing, 2017, 248: 120–126.
- [15] 李兵, 刘明亮, 杨平. EWT 与 GS-SVM 在断路器机械故障诊断中的应用 [J]. 哈尔滨工程大学学报, 2018(8): 1–9.

(上接第 47 页)

- [4] SCHMIDTR O. Multiple emitter location and signal parameter spectral estimation[J]. IEEE Transactions on Antennas and Propagation, 1986, 34(3): 276–280.
- [5] FROSTO L. Analgorithm for linearly constrained adaptive array process[J]. IEEE, 1972, 60(8): 926–935.
- [6] 宗耀. 共形阵列天线的波束赋形设计与研究[D]. 西安: 西北工业大学, 2007: 27.
- [7] IGNACIO B, PEDRO J, MANUEL M, et al.

Implementation In FPGAS of Jacobi Method To Solve The Eigenvalue And Eigenvector Problem[C]/or Field Programmable Logic and Applications. Madrid: IEEE, 2006: 1–4.

- [8] CHANG L, YEH C C. Performance of DMI and eigenspace based beamformers[J]. IEEE Transactions on Antennas and Propagation, 1992, 40(11): 1336–1347.
- [9] 张小飞, 李建峰, 徐大吉, 等. 阵列信号处理及 Mat lab 实现[M]. 北京: 电子工业出版社, 2015: 82–85.