

基于融合 AVMD 与改进灰狼优化 ELM 光纤陀螺温度补偿技术

仇海涛, 赵浩阳*

(北京信息科技大学 高动态导航技术北京市重点实验室, 北京 100101)

摘要: 为抑制环境温度引起的光纤陀螺零偏漂移与精度退化, 提出一种融合自适应变分模态分解(AVMD)和改进灰狼算法优化极限学习机(IGWO-ELM)的温度误差补偿策略。该算法首先以最小化平均包络熵为准则, 利用 AVMD 自适应确定变分模态分解的最优模态数 K 和惩罚因子 α , 将温度信号分解为趋势项、波动项和噪声项, 同时采用相同的分解参数对陀螺输出信号进行分解, 实现信号的多尺度分离。然后, 通过采集光纤陀螺在 $-40^{\circ}\text{C} \sim +60^{\circ}\text{C}$ 范围内的温度与输出数据, 分别对温度的趋势项和波动项建立 IGWO-ELM 子模型, 用以预测陀螺输出中对应的分量; 对噪声项则采用小波阈值去噪技术抑制高频干扰。最后, 将三个分量的预测结果重构, 得到最终的补偿输出。实验结果表明, 该方法能有效分离温度变化中的多尺度特征, 显著抑制零偏漂移, 使补偿后陀螺的精度和稳定性均得到大幅提升。

关键词: 光纤陀螺; 零偏漂移; 自适应变分模态分解; 改进灰狼算法; 极限学习机

中图分类号: TP183; TN911.7 **文章编号:** 1001-5868(2026)04-0630-08

Temperature Compensation Technology for Fiber-Optic Gyroscope Based on AVMD and Improved Grey Wolf Optimization ELM

QIU Haitao, ZHAO Haoyang

(Beijing Key Laboratory of High Dynamic Navigation Technology, Beijing Information Science and
Technology University, Beijing 100101, CHN)

Abstract: To address the bias drift and reduced accuracy caused by environmental temperature fluctuations in fiber-optic gyroscopes, this study proposes a temperature error compensation method based on adaptive variational mode decomposition (AVMD) and an improved grey wolf optimizer-extreme learning machine (IGWO-ELM). First, the AVMD algorithm is introduced to adaptively determine the optimal mode number and penalty factor of variational mode decomposition by minimizing the average envelope entropy, thereby adaptively decomposing the temperature signal into trend, fluctuation, and noise components. Simultaneously, the same decomposition parameters are used to decompose the gyroscope output signal, achieving multiscale signal separation. By acquiring temperature and output data of the fiber-optic gyroscopes from -40°C to $+60^{\circ}\text{C}$, IGWO-ELM submodels are established for the trend and fluctuation components of temperature to predict the corresponding components in the gyroscope output. For the noise component, wavelet threshold denoising technology is employed to suppress high-frequency interference. Finally, the prediction

收稿日期: 2026-03-16.

基金项目: 北京市自然科学基金(4222052).

* 通信作者: 赵浩阳

results of the three components are reconstructed to obtain the final compensated output. Experimental results demonstrate the effectiveness of this method in separating multiscale features under temperature variations, thereby significantly suppressing bias drift and enhancing the accuracy and stability of the compensated gyroscope.

Key words: fiber-optic gyroscope; zero-bias drift; adaptive variational mode decomposition; improved grey-wolf algorithm; extreme learning machine

0 引言

光纤陀螺作为高精度惯性传感核心器件,其输出精度直接决定惯性导航系统的性能上限^[1]。然而,在实际工程应用中,环境温度变化会引起光纤折射率、几何尺寸等物理参数的改变,进而诱发 Shupe 效应,引入非互易相位误差,导致零偏漂移呈复杂非线性演化^[2-4]。因此,研究有效的温度误差分析与补偿技术,对于提升光纤陀螺的环境适应性、满足高精度导航需求具有重要的工程应用价值与理论指导意义。

早期研究多采用多项式拟合法建立温度与零偏之间的回归模型进行补偿^[5],但该方法难以准确刻画非线性关系,补偿精度有限。传统 BP 神经网络虽具备非线性逼近能力^[6],却存在收敛速度慢、易陷入局部极小值、过拟合风险高等问题^[7]。支持向量回归(Support Vector Regression, SVR)通过核函数映射处理非线性^[8],但其性能对核参数敏感,且在大样本下计算负担重。极限学习机(Extreme Learning Machine, ELM)作为单隐层前馈网络^[9],通过随机初始化输入权重与偏置、解析求解输出权重^[10],具有训练速度快、泛化能力强的优点。然而,上述方法通常直接以原始温度序列为输入、原始输出为目标进行拟合,忽略了温度信号的多尺度特性和时序相关性,难以充分挖掘其内在演化规律,导致模型泛化能力受限。

针对现有方法的不足,本文提出一种融合自适应变分模态分解(Adaptive Variational Mode Decomposition, AVMD)与改进灰狼算法优化极限学习机(Improved Grey Wolf Optimization-Extreme Learning Machine, IGWO-ELM)的组合补偿策略。首先,采用 AVMD 通过最小化包络熵自动确定最优模态数和惩罚因子,将温度信号自适应分解为趋势项、波动项和噪声项,实现多尺度特征的有效分离。其次,针对趋势与波动分量,分别采用 IGWO-ELM 建立子预测模型。IGWO 通过非线性收敛因子和

精英反向学习策略,增强了全局寻优能力,提升了 ELM 的拟合精度。在对噪声分量进行小波阈值去噪^[11]后,重构各分量预测结果,实现温度误差的精准补偿。

1 光纤陀螺温度误差机理

Sagnac 效应构成了光纤陀螺的理论基石,在旋转的封闭光路中,两束光干涉后的相位差与旋转封闭光路的角速度成正比,该关系满足:

$$\Delta\varphi_s \approx \frac{8\pi^2 r^2}{\lambda c} \omega = \frac{4\pi r l}{\lambda c} \omega \quad (1)$$

式中, r 为光纤环半径, l 为光纤环周长, c 为真空中的光速, λ 代表光波的平均波长, ω 代表旋转闭合光路的角速度。

在光纤环路中,源自同一光源的顺时针(CW)与逆时针(CCW)光束,除中点外在任意位置都会经历不同的传播时间^[12]。当光纤环路处于温度变化时,光纤各位置的折射率也会随温度的变化而实时改变。因此,这两个反向传播的光波会产生非互易相位差,即 Shupe 误差。由于光纤内部温度场和温度梯度场分布不均匀,光纤各点随时间变化的温度函数可表示为 $\frac{dT(z, t)}{dt}$, 则总 Shupe 误差可表示为:

$$\Delta\varphi_E = \frac{2\pi n}{\lambda_0 c} \frac{\partial n}{\partial t} \int_0^L \frac{dT(z, t)}{dt} (L - 2z) dz \quad (2)$$

式中, n 是光纤的折射率; λ_0 是光在真空中的波长; $\frac{\partial n}{\partial t}$ 是折射率随时间的变化率; L 是光纤的总长度, 而 $(L - 2z)$ 是权重因子,反映了温度变化对光纤不同位置相位延迟的贡献差异; Shupe 效应最终体现为对光纤陀螺零偏的直接影响。由式(2)可知,陀螺的零偏误差与温度梯度场密切相关,其本质是对光纤环上各点温度变化率进行加权积分的结果。这意味着,环境温度的整体变化趋势以及温度梯度的复杂动态波动共同塑造了零偏误差的形态。进一步分析表明,温度信号中的趋势项主要反映了环

境温度的总体升降过程,其缓慢变化对应光纤陀螺的慢变零偏漂移,是引起零偏长期漂移的主导因素;温度波动项则刻画了温度场中的局部起伏特征,与温度梯度的瞬时变化密切相关,对应陀螺输出的快变零偏漂移,表现为中短期波动性误差;而噪声项主要来源于系统固有干扰与测量噪声的叠加,对应随机零偏误差,具有高频、非平稳的特点。上述三者及时频域上相互耦合,共同决定了光纤陀螺在变温环境下的输出特性。

2 光纤陀螺温度补偿模型

2.1 自适应变分模态分解

变分模态分解(Variational Mode Decomposition, VMD)是一种完全非递归的信号分解方法^[13],其核心思想是通过构造并求解变分问题来实现信号的自适应分解。假设原始信号 $f(t)$ 可以被分解为 k 个有限带宽的模态分量 $u_k(t)$,每个模态分量紧密围绕其中心频率 ω_k 。VMD通过求解以下约束变分问题来实现分解^[14]:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (3)$$

式中, $\{u_k\}$ 代表分解后得到的 k 个模态分量; $\{\omega_k\}$ 是每个模态对应的中心频率; $\delta(t)$ 是狄拉克函数; $\frac{j}{\pi t}$ 是希尔伯特变换的脉冲响应; $-j\omega_k t$ 是频率混合算子。为了求解上述约束变分问题,VMD引入二次惩罚项和拉格朗日乘子将其转化为无约束问题。通过交替更新模态、中心频率和拉格朗日乘子,算法最终收敛到最优解,完成信号的自适应分解。

而VMD的分解效果严重依赖于两个关键参数的预设:模态数 K 和惩罚因子 α 。 K 值过小会导致模态欠分解,不同频率成分混叠在同一模态中;而 K 值过大则会产生虚假模态或模态分裂。 α 控制着模态的带宽: α 越小,模态带宽越大,频率分辨率降低; α 越大,模态带宽越小,但可能过度限制会导致信息丢失。在实际应用中,面对未知信号,手动调参不仅耗时,而且难以保证最优性,这限制了VMD的自动化应用。

为解决手动调参的局限,AVMD通过引入优化准则,实现对 $[K, \alpha]$ 参数组合的自动寻优。AVMD将参数选择问题转化为一个优化问题,以平均包络熵作为评价分解质量的目标函数,在预设的参数空

间中进行网格搜索。平均包络熵的数学定义如下:

$$E_{\text{envelope}} = - \sum_{i=1}^N p_i \ln p_i \quad (4)$$

$$p_i = \frac{a(i)}{\sum_{j=1}^N a(j)} \quad (5)$$

式中, $a(i)$ 是信号经希尔伯特变换后得到的瞬时幅值包络, N 为信号的总采样点数。包络熵衡量的是信号包络的稀疏性:当信号包含清晰的调幅特征时,包络呈现稀疏的脉冲状,包络熵较小;当信号为随机噪声时,包络趋于均匀分布,包络熵较大。因此,最小化各IMF分量的平均包络熵等价于寻找使分解结果最具稀疏性和结构性的参数组合,从而在无需先验知识的情况下实现自适应最优分解。

2.2 基于IGWO-ELM的误差建模与补偿

极限学习机是一种单隐层前馈神经网络的快速学习算法,其核心思想在于随机初始化输入层到隐层的权重和偏置,仅通过计算确定隐层到输出层的权重,获得全局最优解。对于 N 个任意不同的训练样本 x_i ,具有 L 个隐层节点且激活函数为 $g(\cdot)$ 的ELM模型可以表示为:

$$H = \begin{bmatrix} g(\omega_1 \cdot x_1 + b_1) & \cdots & g(\omega_L \cdot x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(\omega_1 \cdot x_N + b_1) & \cdots & g(\omega_L \cdot x_N + b_L) \end{bmatrix} \quad (6)$$

$$Y = H\beta \quad (7)$$

式中, ω_j 为连接第 j 个隐层节点与输入节点的权重, b_k 为第 k 个隐层节点的偏置, H 为隐层的输出矩阵, β 为输出权重。随后将网络训练转化为求解线性矩阵方程即式(7)的最小二乘问题,通过广义逆直接计算输出权重,获得解析解。

灰狼优化算法是一种模拟灰狼种群社会等级结构与群体捕食行为的智能优化算法。在算法中,将最优解定义为 α 狼,次优解为 β 狼,第三优解为 δ 狼,其余候选解为 ω 狼。在捕食过程中,狼群在 α, β, δ 的带领下完成对猎物的包围和攻击。位置更新机制通过以公式(8)~(10)描述,即:

$$\begin{cases} D_\alpha = |C_1 \cdot X_\alpha(t) - X(t)| \\ D_\beta = |C_2 \cdot X_\beta(t) - X(t)| \\ D_\delta = |C_3 \cdot X_\delta(t) - X(t)| \end{cases} \quad (8)$$

$$\begin{cases} X_1 = X_\alpha(t) - A_1 \cdot D_\alpha \\ X_2 = X_\beta(t) - A_2 \cdot D_\beta \\ X_3 = X_\delta(t) - A_3 \cdot D_\delta \end{cases} \quad (9)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (10)$$

式中, t 表示当前迭代次数, $X(t)$ 为灰狼当前位置, $X_\alpha(t), X_\beta(t), X_\delta(t)$ 分别为 α, β, δ 狼的位置, 系数向量 $A = 2a \cdot r_1 - a$ 和 $C = 2 \cdot r_2$ 控制算法的勘探与开发能力, a 为收敛因子随迭代从 2 线性递减至 0, r_1 和 r_2 为 $[0, 1]$ 区间内的随机向量。通过该机制, 所有 ω 狼不断向 α, β, δ 狼靠近, 最终收敛到全局最优解。

为进一步提升算法的寻优性能, 在标准灰狼优化算法的基础上引入两点改进策略, 提出改进的灰狼优化算法。首先, 采用非线性收敛因子替代原有的线性递减策略, 使算法在前期保持较强的全局探索能力, 后期增强局部开发精度, 其数学表达式为:

$$a = \frac{2}{1 + e^{\lambda[10(t/T - 0.5)]}} \quad (11)$$

式中, $\lambda = 2$ 为控制因子, t 为当前迭代次数, T 为最大迭代次数。该函数呈现 S 型变化趋势, 在迭代初期 a 值较大且衰减缓慢, 有利于广泛搜索; 中期 a 值快速下降, 平衡探索与开发; 后期 a 趋近于 0, 增强局部精细搜索能力。其次, 引入精英反向学习策略, 每隔 5 代对当前最优的 α, β, δ 个体生成反向解, 即:

$$\begin{cases} \hat{X}_\alpha = -X_\alpha \\ \hat{X}_\beta = -X_\beta \\ \hat{X}_\delta = -X_\delta \end{cases} \quad (12)$$

若反向解的适应度优于原解, 则进行替换。该策略通过同时搜索当前解及其反向解, 有效扩大搜索空间, 帮助算法跳出局部最优, 提高全局收敛能力。

基于上述理论分析, 所提出的光纤陀螺温度误差补偿方法的实现流程如图 1 所示。其中, “温度、输出分解为趋势项、波动项、噪声项” 矩形框表示对温度信号与陀螺输出信号分别进行 AVMD 分解, 并按照频率与物理意义划分为三个分量。该环节后, 趋势项与波动项分别流入对应的 IGWO-ELM 建模分支, 噪声项流入小波阈值去噪分支, 形成并行处理结构。后续所有分支的输出在补偿环节汇聚, 通过分量预测结果的叠加实现最终的误差补偿。

本文所构建的 IGWO-ELM 模型中各关键参数的设置如表 1 所示。其中, IGWO 算法的种群数量与最大迭代次数决定了全局寻优的广度与深度, 反向学习间隔用于控制精英反向策略的触发频率;

ELM 的输入权重、偏置、正则化系数及隐层节点比例则由 IGWO 在给定范围内自适应寻优, 以实现模型拟合精度与泛化能力的最佳平衡。




图 1 融合 AVMD 与 IGWO-ELM 温度补偿流程图

表 1 IGWO-ELM 模型参数设置

类别	参数名	值/范围
IGWO	种群数量	20
	最大迭代次数	30
	反向学习间隔	5
ELM	输入权重	$[0, 2]$
	偏置	$[0, 2]$
	正则化系数	$[0.01, 100]$
	隐层节点比例	$[0.1, 0.6]$

3 实验设计与结果分析

3.1 光纤陀螺数据采集及数据预处理

为获取光纤陀螺在温度变化下的输出信号, 以光纤陀螺为对象, 开展了温度实验。实验过程如下: 温箱在 25°C 下保温两小时以使陀螺输出稳定, 随后在 $-40^\circ\text{C} \sim +60^\circ\text{C}$ 范围内进行升降温实验, 全程通过专用数据采集软件连续采集陀螺输出数据, 采样频率为 1 Hz 。基于上述实验流程, 获取了某型号光纤陀螺在该温度条件下的温度变化及相应输

出数据。将得到的数据进行100 s平滑处理,并通过AVMD将温度信号分解为若干本征模态函数分量。根据各分量的中心频率与物理意义,将频率最低、反映信号整体变化趋势的分量归为趋势项,对应环境温度的宏观升降过程;将频率居中、呈现局部波动特征的分量归为波动项,反映温度梯度变化引起的动态扰动;将频率最高、呈现随机振荡特征的分量归为噪声项,代表系统固有干扰与测量噪声。得到图2中原始温度信号与各温度分量曲线图。




图2 温度信号及AVMD分解曲线图

从图中可以看出,原始温度信号经AVMD分解后,被有效分离为具有明确物理意义的趋势项分量、波动项分量与噪声项分量。这一分解过程不仅揭示了温度信号的多尺度结构,也为后续误差建模提供了更精细的输入特征。由于光纤陀螺的输出误差与温度变化密切相关,且二者在时频域上具有潜在的耦合关系,对陀螺输出信号采用与温度信号相同的分解参数进行VMD处理,能够保持信号分量之间的对应性,便于后续构建分量级的预测模型。图3即为输出信号及其各分量曲线图,其中趋势项分量反映了输出中由温度主导的缓慢漂移,波动项分量体现了温度梯度引发的动态变化,噪声项分量则对应输出中的高频随机成分。





图3 输出信号及AVMD分解曲线图

3.2 光纤陀螺温度补偿结果分析

按照上述流程图,首先对温度与输出信号进行AVMD分解,然后利用IGWO-ELM模型对趋势项、波动项分别进行预测输出,对噪声项进行小波去噪输出,随后将预测的输出结果进行重构,得到陀螺输出的最终预测值。图4展示了各分量预测结果及重构总输出与实际输出的对比。






图4 IGWO-ELM+小波去噪输出预测图

从图中可以看出,各分量的预测值与实际输出具有良好的一致性,重构后的总输出曲线与原始输出高度吻合,充分验证了本文方法在多尺度建模与噪声抑制方面的有效性。为进一步评估所提模型的预测性能,将其与多项式模型、ELM 模型及 GWO-ELM 模型进行对比。图 5 给出了各模型对陀螺输出的拟合结果,直观反映出不同方法在逼近能力上的差异。




图5 各模型输出预测对比图

从图中可以看出,多项式模型的拟合曲线虽能大致跟随输出整体趋势,但在峰值与谷值区域偏离明显,拟合误差较大,说明线性或低阶多项式难以有效刻画温度引起的非线性漂移特性。ELM 模型相比多项式模型有了明显改善,能够较好地拟合输出的主体变化,但在局部波动剧烈处仍存在一定程度的欠拟合现象。GWO-ELM 模型通过引入灰狼算法优化 ELM 的输入权重和隐层偏置,进一步提升了拟合精度,其预测曲线与真实输出更为接近,尤其在输出变化较为平缓的区域表现出良好的跟踪能力。而本文提出的 AVMD+IGWO-ELM 模型在整体趋势跟随和局部波动拟合方面均表现最优,不仅在输出平稳段保持高精度拟合,而且在输出变化剧烈区域仍能准确捕捉其动态特征,显示出在处理非线性、非平稳信号方面的显著优势。

在机器学习回归任务中,通常采用预测值与真实值之间的偏差来衡量模型性能。本研究选取均方根误差(RMSE)和平均绝对误差(MAE)作为评价指标,从定量角度对各模型的预测精度进行客观评估,表 2 列出了四种模型的评估结果。可以看出,

多项式模型的 RMSE 和 MAE 均为最大,拟合精度最低;ELM 模型较多项式有所提升,误差值明显下降;GWO-ELM 模型通过参数优化进一步降低了预测偏差;而本文提出的 AVMD+IGWO-ELM 模型取得了最小的 RMSE 和 MAE,分别为 0.1420×10^{-2} 和 0.0992×10^{-2} ,显著优于其他对比模型。这一结果与图 5 所示的拟合效果相吻合,从定量角度进一步验证了本文方法在拟合精度上的优势。

表 2 各预测模型的 RMSE 与 MAE

模型	RMSE/($\times 10^{-2}$)	MAE/($\times 10^{-2}$)
多项式	0.598 0	0.440 8
ELM	0.431 0	0.276 3
GWO-ELM	0.333 1	0.196 1
AVMD+IGWO-ELM	0.142 0	0.099 2

在获得各模型的输出预测值后,将其作为误差补偿项对原始陀螺输出进行修正,得到补偿后的零偏曲线。通过对比不同模型补偿后的零偏稳定性,可以更直观评估各方法在实际应用中的补偿效果。图 6 展示了补偿前及各模型补偿后的零偏曲线对比情况。




图6 各模型零偏对比图

从图中可以看出,补偿前的原始零偏曲线波动幅度较大,在整个温度变化过程中呈现出明显的漂移现象。尤其在升温与降温阶段,零偏随温度变化剧烈波动,最大值接近 $0.053^{\circ}/h$,反映出温度对陀螺输出的显著影响。经多项式模型补偿后,零偏曲线的整体波动幅度有所减小,但在温度变化剧烈的区域仍存在较为明显的残余波动,补偿效果有限。ELM 模型补偿后的零偏曲线较多项式模型更为平稳,多数时段内的波动幅度得到有效抑制,但在局部区域仍可见小幅起伏。GWO-ELM 模型进一步改善了补偿效果,零偏曲线整体趋于平稳,波动幅度进一步收窄,仅在少数温度转折点附近存在轻微波动。而本文提出的 AVMD+IGWO-ELM 模型补偿后的零偏曲线最为平缓,全程波动幅度极小,无明显漂移现象,曲线基本围绕零值附近小幅波

动,展现出最佳的补偿效果。

为进一步定量评估各模型的补偿效果,本文采用零偏稳定性 B_s 作为评价指标,同时引入补偿效果 I_B 来衡量各补偿模型相较于补偿前的性能提升幅度。

$$B_s = \sqrt{\frac{1}{k} \sum_{i=1}^k (S_i - \bar{S})^2} \quad (13)$$

$$I_B = \frac{B'_s - B_s}{B_s} \times 100\% \quad (14)$$

式中, S_i 为 100 s 平滑后第 i 个数据点的输出, $\bar{S}$ 为全过程陀螺平均输出,其中 $k = (n/100) + 1$ 表示平滑后光纤陀螺输出中的数据点总数, B_s 代表补偿前 FOG 的零偏稳定性, B'_s 代表补偿后 FOG 的零偏稳定性。表 3 列出了补偿前及各模型补偿后的零偏稳定性及相应的补偿效果。

表 3 光纤陀螺补偿模型的零偏稳定性及补偿效果

模型	$B_s/[^{\circ}/h]$	$I_B/\%$
补偿前	0.020 869	—
多项式	0.005 985	71.32
ELM	0.004 314	79.33
GWO-ELM	0.003 334	84.02
AVMD+IGWO-ELM	0.001 421	93.19

从表中可以看出,补偿前陀螺的零偏稳定性为 0.020 869 $^{\circ}/h$,经不同模型补偿后均获得不同程度的改善。其中,多项式模型补偿后的零偏稳定性降至 0.005 985 $^{\circ}/h$,补偿效果为 71.32%,表明其能够在一定程度上抑制温度引起的零偏漂移,但改善幅度相对有限。ELM 模型补偿效果进一步提升,零偏稳定性降至 0.004 314 $^{\circ}/h$,补偿效果达到 79.33%,显示出神经网络模型在非线性拟合方面的优势。GWO-ELM 模型通过灰狼算法优化 ELM 参数,补偿后的零偏稳定性为 0.003 334 $^{\circ}/h$,补偿效果提升至 84.02%,验证了参数优化对模型性能的增强作用。而本文提出的 AVMD+IGWO-ELM 模型取得了最佳的补偿效果,零偏稳定性降至 0.001 421 $^{\circ}/h$,补偿效果高达 93.19%,显著优于其他对比模型。这一结果表明,通过 AVMD 实现信号的多尺度分解,结合 IGWO-ELM 的分量级精确建模,能够有效剥离温度影响并抑制零偏漂移,大幅提升光纤陀螺在全温范围内的输出稳定性。

4 结论

本文针对光纤陀螺在变温环境下面临的零偏

漂移问题,提出了一种融合自适应变分模态分解与改进灰狼算法优化极限学习机的温度误差补偿方法。该方法通过 AVMD 以最小化平均包络熵为目标,自适应确定 VMD 的最优分解参数,有效实现温度与陀螺输出信号的多尺度特征分离,克服了传统 VMD 手动调参的局限性;引入了非线性收敛因子与精英反向学习策略对灰狼算法进行改进,增强了全局寻优能力,使 IGWO-ELM 模型在分量级预测中具有更高的拟合精度。在 $-40^{\circ}C \sim +60^{\circ}C$ 宽温域内,该方法将光纤陀螺零偏稳定性提升至 0.001 421 $^{\circ}/h$,补偿效果达 93.19%,显著优于多项式、ELM、GWO-ELM 等传统模型。此外,该方法基于信号自身特征进行自适应分解与建模,不依赖具体器件结构,具备较强的泛化能力。

参考文献:

- [1] 史文策,许江宁,林恩凡.陀螺仪的发展与展望[J].导航定位学报,2021,9(3):8-12.
Shi Wence, Xu Jiangning, Lin Enfan. Development and prospect of gyroscope [J]. Journal of Navigation and Positioning, 2021, 9(3): 8-12.
- [2] 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.
Yuan Libo, Tong Weijun, Jiang Shan, et al. Road map of fiber optic sensor technology in China [J]. Acta Optica Sinica, 2022, 42(1): 9-42.
- [3] Liu H, Luo W, Lu J. High precision fiber-optic gyroscope resolution test method based on low precision turntable [J]. IEEE Sensors Journal, 2020, 20(15): 8656-8662.
- [4] Lofts C M. Investigation of the effects of temporal thermal gradients in fiber optic gyroscope sensing coils [J]. Optical Engineering, 1995, 34(10): 2856.
- [5] 杨智杰,陈国光,朱宜家,等.干涉式光纤陀螺光纤环互易性温变漂移补偿方法[J].导航与控制,2017,16(6):39-44.
Yang Zhijie, Chen Guoguang, Zhu Yijia, et al. Reciprocal temperature bias drift compensation method for fiber coil of interferometry fiber optical gyroscope [J]. Navigation and Control, 2017, 16(6): 39-44.
- [6] 邹晨曦,石震,刘迪,等.基于BP神经网络模型的光纤陀螺全站仪温度补偿算法[J].测绘学报,2025,54(6):1021-1030.
Zou Chenxi, Shi Zhen, Liu Di, et al. Fiber optic gyroscope total station temperature compensation algorithm based on BP neural network model [J]. Acta Geodaetica et Cartographica Sinica, 2025, 54(6): 1021-1030.
- [7] 张志利,刘瑾,周召发,等.基于ISCSO-BP神经网络模型的光纤陀螺温度补偿技术研究[J].系统仿真学报,2025,37(11):2904-2917.

- Zhang Zhili, Liu Jin, Zhou Zhaofa, et al. Research on temperature compensation technology of fiber optic gyroscope based on ISCSO-BP neural network model [J]. Journal of System Simulation, 2025, 37(11): 2904-2917.
- [8] 黄春福, 李 安, 覃方君, 等. 基于 PSO-SVR 的光纤陀螺温度误差建模与实时补偿 [J]. 光子学报, 2019, 48(12): 1206002.
- Huang Chunfu, Li An, Qin Fangjun, et al. Temperature error modeling and real-time compensation of fiber optic gyroscope based on PSO-SVR [J]. Acta Photonica Sinica, 2019, 48(12): 1206002.
- [9] Li M, Wibowo S, Guo W. Nonlinear curve fitting using extreme learning machines and radial basis function networks [J]. Computing in Science & Engineering, 2019, 21(5): 6-15.
- [10] 王 瑞, 郑百东, 李 飞, 等. ELM-AdaBoost 模型在光纤陀螺温度误差补偿中的应用 [J]. 兵工自动化, 2024, 43(2): 63-68.
- Wang Rui, Zheng Baidong, Li Fei, et al. Application of ELM-AdaBoost model in temperature error compensation of fiber optic gyroscope [J]. Ordnance Industry Automation, 2024, 43(2): 63-68.
- [11] 李光耀, 侯宏录, 杜 鹏, 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.
- Li Guangyao, Hou Honglu, Du Juan, et al. FOG temperature drift compensation method based on wavelet denoising and neural network [J]. Opto-Electronic Engineering, 2019, 46(9): 58-66.
- [12] Post E J. Sagnac effect [J]. Reviews of Modern Physics, 1967, 39(2): 475-493.
- [13] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [14] 薛怀恒, 买买提热依木·阿布力孜, 吴许坤, 等. 基于参数优化 WOA-VMD-MCKD 在强背景噪声下的轴承故障诊断 [J]. 科学技术与工程, 2026, 26(2): 607-622.
- Xue Huaiheng, Abulizi Maimaitireyimu, Wu Xukun, et al. Bearing fault diagnosis in strong background noise based on parameter optimization WOA-VMD-MCKD [J]. Science Technology and Engineering, 2026, 26(2): 607-622.

作者简介:

仇海涛(1974—),男,山东省临沂市人,博士,副研究员,主要研究方向为导航与制导;

赵浩阳(2001—),男,河北省辛集市人,硕士研究生,主要研究方向为光纤陀螺温度补偿。