

基于极限学习机的地磁模型误差预测方法*

郭红阳¹ 张涛¹ 韩鹏²
陈晨¹ 赵治华¹

1(河南工业大学机电工程学院 郑州 450001)

2(中国科学院国家空间科学中心 北京 100190)

摘要 高精度地磁场模型是近地卫星自主导航的重要基础, 但地磁模型因观测误差、球谐系数截断误差及更新缓慢等原因制约了导航精度的提高. 为了解决这个问题, 基于正则化极限学习机提出一种地磁模型误差预测方法, 采用减法均值器对正则化系数 C 进行最优估计, 减少了参数调试中的主观性和随机性, 提高了学习的效率和预测的精度, 另外该方法可以有效提高地磁观测序列中存在异常值时误差估计精度; 与滤波算法进行融合, 提出一种模型误差补偿的地磁导航方法, 并利用在轨卫星真实的地磁测量数据进行了仿真验证. 结果表明, 所提出方法的预测精度优于常用的几种神经网络预测方法, 导航精度达到了 1.26 km, 表明所提出的误差预测模型可以有效地改善地磁导航性能.

关键词 极限学习机, 正则化, 减法均值器, 地磁滤波

中图分类号 P353, V249.3

Error Prediction Method of Geomagnetic Model Based on Extreme Learning Machine

GUO Hongyang¹ ZHANG Tao¹ HAN Peng²
CHEN Chen¹ ZHAO Zhihua¹

1(School of Mechanical and Electrical Engineering, Henan University of Technology, Zhengzhou 450001)

2(National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

Abstract The high-precision geomagnetic field model is an important foundation for autonomous navigation of near earth satellites, but the improvement of navigation accuracy is constrained by observation errors, spherical harmonic truncation errors, and slow updates of the geomagnetic model. To solve this problem, this paper proposes a geomagnetic model error prediction method based on regularized extreme learning machine. The optimal estimation of the regularization coefficient C is achieved by using a subtraction mean algorithm, which reduces subjectivity and randomness in parameter tuning, improves

* 河南省科技厅自然科学基金项目资助 (242102221043)

2024-08-30 收到原稿, 2025-05-07 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

learning efficiency and prediction accuracy. In addition, this method can effectively improve the error estimation accuracy when outliers exist in geomagnetic observation sequences. Then, a geomagnetic navigation method with model error compensation was proposed by integrating it with filtering algorithms, and simulation verification was conducted using real geomagnetic measurement data from in orbit satellites. The results show that the prediction accuracy of the method proposed in this paper is superior to several commonly used neural network prediction methods, and the navigation accuracy reaches 1.26 km, indicating that the proposed error prediction model can effectively improve the performance of geomagnetic navigation.

Key words Extreme learning machine, Regularization, Subtraction mean algorithm, Geomagnetic filter

0 引言

卫星精准定轨是保证卫星完成自身特定任务的关键. 传统低轨卫星的轨道确定主要通过地面测控站与卫星之间的信息传输来实现, 但随着在轨卫星数量的不断增加, 地面测控站需要管理的卫星数量增多, 任务调度和资源分配的复杂性也随之增加, 导致负担加重. 随着全球卫星导航系统 (Global Navigation Satellite System, GNSS) 的发展, 例如北斗、GPS 等系统, 很多中低轨道卫星采用 GNSS 技术实现高精度的自主轨道确定, 减少了对地面测控站的依赖. 然而这种方式的实现以卫星对 GNSS 信号的有效接收为基础, 该信号容易受到干扰, 严重情况甚至会导致导航失效. 地磁场作为地球固有的物理属性之一, 为航空、航天以及航海领域提供了一种天然的、固有的导航基准系统. 在理论层面, 地磁场矢量数据中蕴含着丰富的空间位置信息, 通过解析这些矢量信息, 能够唯一确定空间任意点的位置, 这一特性构成了地磁导航技术的坚实理论基础. 地磁导航技术具有自主性强、抗干扰能力强以及不依赖外部信号源等特点, 在信息安全和军事应用中具有更高的可靠性, 并且可以满足近地轨道的各种低成本卫星的自主导航需求, 成为自主导航领域中极具潜力的重要研究方向.

目前对地磁导航的研究集中在改进滤波方法和优化磁强计性能等方面, Chen 等^[1]运用一种新的模糊调节的无迹卡尔曼滤波方法来设计模糊调节器以更准确估计磁偏; Kiani 等^[2]提出了一种新的平方根立方正交卡尔曼滤波定轨方法; Li 等^[3]在传统椭圆拟合校准法的基础上, 提出了一种单步校准和对准三轴磁强计的新方法; Xiang 等^[4]基于递推最小二乘法, 可让三轴磁强计在无外部参考基准下实现误差自动

校准. 这些方法在一定程度上改善了地磁导航性能, 但由于地磁模型的误差大、模型系数更新慢等问题没有得到解决, 因此很难实现高精度地磁导航的目的.

近些年神经网络技术得到了快速发展, 一些学者开始利用这些技术对地磁矢量匹配导航和地磁物理场预测进行研究. Bai 等^[5]基于深度强化学习 (DRL) 的远距离地磁导航机制, 设计了一种地磁梯度引导的 TD 3 算法来学习长距离任务的最优导航解, 以保持稳定高效的导航进程; Chen 等^[6]提出了一种基于概率神经网络 (PNN) 的矢量模式识别匹配方法来实现地磁导航, 利用神经网络的非线性分类能力, 实现了高精度的地磁矢量匹配; Wintoft 等^[7]使用太阳风数据作为输入, 使用三种不同的递归神经网络 (RNN) 架构预测地磁扰动指数 (Dst); He 等^[8]提出了一个基于长短期记忆神经网络的耀斑预测模型, 预报未来 48 h 内是否发生 M 级别以上的耀斑事件; Siciliano 等^[9]比较分析了长短时记忆网络 (Long Short-term Memory Networks, LSTM) 和卷积神经网络 (CNN) 模型对环电流指数 (SYN- H) 的预测效果, SYN- H 是地球表面中低纬度地区轴对称磁场扰动的代表; Tasistro-Hart 等^[10]提出了一种产生不确定性估计的神经网络架构, 可以对扰动风暴时间指数的外部分量 (E_{st}) 产生可靠的概率预测. 上述研究为地磁模型精度的预测和改善提供了方向和借鉴.

在常用的一些神经网络算法中, 例如反向传播神经网络 (Back Propagation, BP) 采用一种局部搜索的权值优化方法, 容易陷于局部最优, 算法的收敛速度慢; LSTM 算法结构复杂, 不能并行运算, 学习时间长, 同时由于星上地磁测量高空复杂环境的影响, 容易出现测量干扰, 针对这些问题, 提出一种改进的正则化极限学习机预测方法^[11,12]. 相对于传统的正则

化极限学习机 (Regularized Extreme Learning Machine, RELM), 该方法不需要花费大量时间来手动确定最佳的正则化系数 C , 而是利用减法平均优化器^[13] (Subtraction-Average-Based Optimizer, SABO), 对系数 C 进行迭代更新, 从而获得最优估计值. 另外, 正则化项的存在, 使得该方法能够有效应对测量过程中的异常值或者干扰值, 提高了预测方法的鲁棒性. 最后将预测方法与滤波器进行融合, 提出一种地磁模型误差补偿的导航方法, 并结合真实卫星的实测数据, 进行了仿真验证和分析.

1 已有模型存在的主要问题

国际地磁参考场模型^[14], 其本质上是基于高斯球谐函数, 构建了一种将地理信息 (经度、纬度、高度、时间) 与地磁场相映射的数学模型. 此方法的优势在于能够提供一个全局视角, 清晰描绘出地球磁场的宏观分布, 但不可避免地忽视了对局部磁异常信息变化的反应. 同时, 地磁模型系数的更新通常以五年为期, 尽管当前的国际地磁参考场模型已具备全面描绘地磁场分布的能力, 但由于地磁场本身所固有的复杂空间结构和随时间不断变化的特性, 这样的更新频率仍然难以满足全球范围内磁场模型高精度和实时性的要求. 图 1 给出了 2020 年 1 月和 2024 年 1 月 Swarm 卫星在地磁平静期内地磁模型误差矢量的对比, 以及地磁滤波导航位置精度对比. 表 1 中的 B_x , B_y , B_z 分

别表示三个方向的地磁矢量; P_{error} 表示地磁导航的位置误差精度. 从图表中可以明显看出, 在新的地磁模型系数发布的初期, 磁场模型精度较高. 随着时间的不断推移, 地磁模型的误差开始增大, 从图 1 可以看出, 最大误差达到 400 nT, 这也是制约地磁导航精度提高的重要原因.

2 融合预测模型的地磁导航方法

为减小地磁模型误差对导航精度的影响, 提出了一种改进的正则化极限学习机与扩展卡尔曼滤波相融合的导航方法 (SABO/RELM Extended Kalman Filter, SABO/RELMEKF). 该方法首先利用 SABO/RELM 预测模型对输入的地磁数据集进行训练, 并对未来一段时间的地磁模型误差进行预测, 最后为滤波导航提供地磁模型补偿信息, 提高导航的精度. 图 2 为 SABO/RELMEKF 导航方法的系统模型框架.

整个系统框架可以分为三个核心子系统, 即传感器信息量测子系统、SABO/RELM 模型预测子系统以及 EKF 子系统, 其共同构成一个高效且紧密的系统框架. 信息量测子系统作为整个框架的基础, 不仅为预测子系统提供了必要的模型训练样本数据, 确保预测模型能够学习到地磁场变化的复杂规律, 同时, 也为最终的 EKF 子系统提供量测数据, 并作为状态修正信息, 为后续导航的信息优化作准备. 预测子系




图 1 2020 年和 2024 年误差数据信息对比. (a) 三个分量的地磁模型误差, (b) 位置误差滤波过程

Fig. 1 Comparison of error data information in 2020 and 2024. (a) Error diagram of geomagnetic model with three components, (b) position error filtering process diagram

表 1 2020 年和 2024 年地磁模型误差对比
Table 1 Comparison of geomagnetic field errors in 2020 and 2024

日期	B_x		B_y		B_z		P_{error}
	均值/nT	标准差	均值/nT	标准差	均值/nT	标准差	误差/km
2020年1月	68.72	46.90	-0.83	24.01	-5.29	39.81	7.16
2024年1月	82.91	58.17	-2.28	51.56	-6.30	45.52	10.47




图 2 SABO/RELMEKF 导航方法的系统模型框架

Fig. 2 System model framework of SABO/RELMEKF navigation method

统则利用 SABO/RELM 误差预测模型通过输入层接收包括日期、地方时、经纬度等多维度信息 (图 2 中的神经网络输入 x), 并经过隐藏层的处理 (由图 2 中神经网络权值 W 、阈值 b 以及隐藏层输出 h 表征), 最终得到 B_x , B_y , B_z 三个地磁矢量方向 (B_x , B_y , B_z 分别为在地理坐标系中的北向、东向以及地心方向的地磁矢量) 上的地磁模型误差预测值 (图 2 中的神经网络输出 y), 将这些预测信息作为补偿数据, 传递给 EKF 子系统, 以提高地磁模型的准确性. EKF 子系统作为整个框架的目标核心, 接收来自信息量测子系统和预测子系统的双重输入 (量测数据和误差预测值), 依据系统状态方程和量测方程同时执行时间更新和量测更新两大任务, 充分利用接收的误差预测值作为关键修正量, 通过迭代计算不断优化卫星轨道的确定结果, 不仅提高了导航信息的实时性和准确性, 还确保了卫星在复杂环境中的稳定运行.

3 滤波模型建立

3.1 系统状态方程

在地球固连坐标系框架下, 基于卫星轨道动力学方程, 构建描绘卫星导航信息估计的系统状态方程,

其中状态量由位置和速度共同构成, 有

$$\mathbf{X}(k) = \Phi(k, k-1) \mathbf{X}(k-1) + \mathbf{w}(k-1). \quad (1)$$

式中, 状态量为 $\mathbf{X} = [x, y, z, v_x, v_y, v_z]^T$, x, y, z 为位置分量, v_x, v_y, v_z 为速度分量; k 表示采样时间; 状态转移矩阵 Φ 描绘了系统状态在时间序列中从 $k-1$ 时刻到下一时刻 k 的变化关系, 推导过程可参考文献 [15]; $\mathbf{w}$ 为系统噪声, 满足统计特征 $E[\mathbf{w}(k)] = 0$, $E[\mathbf{w}(k) \mathbf{w}(l)] = \mathbf{Q}_k \cdot \delta_{kl}$. 其中, δ_{kl} 是 Kronecker- δ 函数, 即如果 $k = l$, 则 $\delta_{kl} = 1$, 如果 $k \neq l$, 则 $\delta_{kl} = 0$.

3.2 量测方程

地球的主磁场是由外核中液态金属的缓慢流动而产生. 这一过程可以用标量磁势 U 来描述, 满足拉普拉斯方程, 其球谐函数可以表示为

$$U(r, \theta, \lambda) = a \sum_{n=1}^N \sum_{m=0}^n \left(\frac{a}{r}\right)^{n+1} (g_n^m \cos m\lambda + h_n^m \sin m\lambda) \bar{P}_n^m(\cos \theta). \quad (2)$$

其中, r 为地心距, θ 为地心余纬, λ 为地心经度, $a = 6371.2$ km 表示地球的平均半径, N 为球谐级数的最大截断阶数; g_n^m 和 h_n^m 为地磁模型的高斯球谐系

数,即由国际地磁与航空物理联合会 (IAGA) 通过综合地面、海洋、航空以及卫星等多种来源的磁测数据,运用最小二乘法计算出的参数. 目前最新版本的国际地磁参考模型,即 IGRF-13,每隔五年会根据最新的磁测数据进行一次更新,确保模型能够模拟地球磁场的动态变化. $\bar{P}_n^m(\cos \theta)$ 为 n 阶 m 次的归一化关联 Legendre 多项式,可在文献 [16] 中导出.

主磁场中的地磁场矢量 $\mathbf{B}$ 可表示为标量磁势 U 的负梯度,即

$$\mathbf{B} = -\nabla U. \quad (3)$$

设磁场的观测值 $\mathbf{Z}$ 表示地磁场强度的矢量,即 $\mathbf{Z} = [B_x, B_y, B_z]^T$, 则可得测量方程为

$$\mathbf{Z}(k) = \mathbf{H}(k) \mathbf{X}(k) + \mathbf{v}(k). \quad (4)$$

其中, $\mathbf{H}(k)$ 为观测矩阵,描绘了系统内部状态量和外部可观测量之间的紧密关联,其详细推导可参见文献 [17]; $\mathbf{v}(k)$ 为随机干扰噪声的测量值,是磁力计在操作过程中因内部精度限制及外部环境波动所积累误差的综合,在统计过程中常被视为高斯白噪声,方便后续的分析与滤波处理. 期望和协方差均满足 $E[\mathbf{v}(k)] = 0$, $E[\mathbf{v}(k) \mathbf{v}(l)] = \mathbf{R}_k \cdot \delta_{kl}$.

4 预测模型建立

4.1 正则化极限学习机

极限学习机 (Extreme Learning Machine, ELM) 是一种高效的前馈神经网络架构,仅有一层隐藏节点. 其特点在于输入层至隐藏层的权值和阈值固定,无需调整;隐藏层至输出层的权值则通过单次方程求解,而非传统的迭代优化. 相比 BP 神经网络,ELM 展现出更高的学习效率和更强的泛化能力. 但在地磁导航实际应用过程中,量测数据会因为高空复杂的物理环境以及磁测过程中的干扰影响存在异常值,对传统 ELM 预测的效果产生不利影响. 为避免实际模型预测过程中可能存在的异常数据值对预测精度的影响,在传统的极限学习机的基础上,加入正则化项,构建了一种具有更强抗干扰能力的正则化的极限学习预测模型 (RELM),通过调节模型的复杂度,提高抗干扰能力,对含有异常值或者异常值的量测数据具有较好的鲁棒性.

传统 ELM 模型的输出 $f_n(x)$ 以及损失函数 L 可

表示如下:

$$f_n(x) = \sum_{i=1}^n \beta_i h_i(x) = \mathbf{h}\boldsymbol{\beta}, \quad (5)$$

$$L = \frac{1}{2} \sum_{i=1}^n (f_n(x_i) - y_i)^2 = \frac{1}{2} \|\mathbf{h}\boldsymbol{\beta} - \mathbf{T}\|_2^2. \quad (6)$$

式中, n 为隐藏层单元个数, y 表示 ELM 模型的输出值,加入正则化项后的模型目标函数为

$$\min \frac{1}{2} (\|\mathbf{h}\boldsymbol{\beta} - \mathbf{T}\|_2^2 + C \|\boldsymbol{\beta}\|_2^2). \quad (7)$$

其中, $C \|\boldsymbol{\beta}\|_2^2$ 为 L2 范数正则化项或惩罚项,通过正则化系数 C 进行平衡,倾向于选择更简单的解决方案,提高模型对于异常值的抗干扰能力. 这一过程实质上是通过最大化边缘分离类的距离来实现的^[18],即让模型在分类任务中保持足够的间隔,提高对新样本的正确分类率.

再结合拉格朗日函数最优条件得到的解为

$$\tilde{\boldsymbol{\beta}} = \mathbf{h}^T (\mathbf{h}\mathbf{h}^T + \mathbf{I}C)^{-1} \cdot \mathbf{T}. \quad (8)$$

其中, $\mathbf{I}$ 为单位矩阵, $\tilde{\boldsymbol{\beta}}$ 为正则化权值矩阵, $\mathbf{h}$ 为隐藏层输出矩阵, $\mathbf{T} = [T_{\text{train}_1}, T_{\text{train}_2}, \dots, T_{\text{train}_M}]^T$ 为真实值矩阵. 然而,在应用中该方法对最优正则化系数 C 的确定是相对较麻烦的,对此下文将构建一种优化算法,解决在前期工作中确定最优正则化系数 C 效率低下的问题.

4.2 减法平均优化算法

减法平均优化器 (SABO) 是一种基于数学原理,通过计算个体间的减法平均值来迭代更新个体在空间中的位置,根据收敛条件,获得最优个体的算法,收敛速度快. 上述 RELM 算法中的正则化系数是一个固定值,在前期工作中选择合适的正则化系数是随机且耗时的. 为了提高前期参数设置的效率,本文提出了一种改进的正则化极限学习机 (SABO/RELM),在不设置 C 值的前提下,利用 SABO 算法来优化常量系数 C ,依据目标函数最小值条件,估计出最合适的 C 值.

初始化一系列 C 值,即

$$C_i = l + r_i \cdot (h - l), \quad i = 1, 2, \dots, N. \quad (9)$$

其中, r 为 $[0,1]$ 之间的一个随机值; h 和 l 分别是一个常数,分别规范了正则化系数 C 的最大值和最小值界限; N 为算法设置的粒子数量,设置的值越大,越容易找到最优值,设置的值越小,收敛效率越高.

个体粒子搜索的减法如下:

$$C_{i,j} = C_{i,1} + (C_{j,1} - I \cdot C_{i,1}) \cdot \text{sign}(f_i - f_j),$$

$$i = 1, 2, \dots, N, j = 1, 2, \dots, N. \quad (10)$$

其中, I 为 $[1,2]$ 之间生成的一个随机数, sign 为符号函数, f 为个体粒子的目标函数值.

最优粒子的更新过程如下:

$$C_i^{\text{new}} = C_i + \tilde{r}_i \cdot \frac{1}{N} \sum_{j=1}^N C_{i,j}; \quad i = 1, 2, \dots, N. \quad (11)$$

$$\begin{cases} C_i^{\text{new}} = \max(C_i^{\text{new}}, l); \\ C_i^{\text{new}} = \min(C_i^{\text{new}}, h). \end{cases} \quad (12)$$

$$C_i = \begin{cases} C_i^{\text{new}}, & f_i^{\text{new}} < f_i; \\ C_i, & f_i^{\text{new}} > f_i. \end{cases} \quad (13)$$

其中, C_i^{new} 为通过减法平均计算得到的新的系数值, 通过式 (12) 判断计算产生的新的 C 值大小是否超过最大值或最小值的界限, 若超出界限就取最大边界值赋予新产生的 C 值, 最后依据目标函数值的大小, 来选择更新新的系数值或者保留初始的系数值, 完成最优粒子的更新.

5 SABO/RELM 地磁模型

为验证本文方法对地磁模型误差预测的有效性, 选取 Swarm 卫星 2023 年 12 月 21—29 日的地磁实测数据作为训练集 (占全部样本的 90%), 2024 年 2 月 29 日的地磁实测信息作为测试集. 所有地磁实测数据均来自欧空局网站^{*}开放的地磁信息, 实测数据采样频率为 1 Hz.

5.1 误差预测仿真分析

地球主磁场模型矢量要素强度不仅受空间位置的影响, 还受时间因素 (例如儒略日) 影响, 这里引入圆周投影法来转换时间和空间信息. 输入由日期投影、地方时投影、经纬度的圆周投影构成, 输出为 B_x , B_y , B_z 三个方向的地磁模型误差^[19].

仿真参数设置: 输入节点数为 6, 隐藏节点数为 250, 输出节点数为 3, 传递函数为 Sigmoid, 训练算法为 Levenberg-Marquadt Algorithm. 仿真结果如图 3(a)~(c) 所示, 其分别表示三个方向 B_x , B_y , B_z 地磁模型实际误差的变化曲线 (蓝色) 以及 SABO/RELM 方法预测的地磁模型误差曲线 (红色).




图 3 SABO/RELM 模型误差预测与地磁模型实际误差的对比

Fig. 3 Comparison between the predicted value and the actual value of SABO/RELM model

表 2 中列出了图 3 数据的统计结果. 其中第 2 列和第 3 列给出地磁模型实际误差的均值和标准差; 将预测的地磁模型误差补偿到地磁模型实际误差中, 第 4 列和第 5 列分别为修正后模型误差的均值和标准差. 从表 2 中的结果可以看出, B_x 方向地磁模型实际误差的均值和标准差为 -77.61 nT 和 46.90, 预测并修正后 B_x 方向地磁模型误差的均值和标准差为 -2.4 nT 和 28.11, 统计误差的均值和标准差分别改善

* <http://swarm-diss.co.esa.int>

表 2 地磁模型实际误差与修正后的地磁模型误差对比
Table 2 Statistical comparison of actual model error and prediction error

地磁矢量	地磁模型实际误差		修正后模型误差		优化比例	
	均值/nT	标准差	均值/nT	标准差	均值/(%)	标准差/(%)
B_x	-77.61	46.90	-2.40	28.11	96.91	40.06
B_y	2.64	35.56	1.03	28.56	60.98	19.69
B_z	7.49	39.06	-1.01	17.56	86.52	55.04

了 96.91% 和 40.06%; B_y 方向地磁模型实际误差的均值和标准差为 2.64 nT 和 35.56, 预测并修正后 B_y 方向地磁模型误差的均值和标准差为 1.03 nT 和 28.56, 统计误差的均值和标准差分别改善了 60.98% 和 19.69%; B_z 方向地磁模型实际误差的均值和标准差为 7.49 nT 和 39.06, 预测并修正后 B_x 方向地磁模型误差的均值和标准差为 -1.01 nT 和 17.56, 统计误差的均值和标准差分别改善了 86.52% 和 55.04%。上述对比数据表明, 本方法能够对地磁模型实际误差进行有效预测。

对表 2 中的结果进一步分析可知, 东向 B_y 矢量的预测效果低于 B_x 和 B_z 方向, 一个原因是 B_y 方向的梯度变化较小^[17]。通过对 B_y 方向地磁模型实际误差较大的区域进行分析, 见图 4 蓝色曲线上的红色标注, B_y 方向地磁模型实际误差较大的区域多位于南北极高纬度地区, 而这些区域在地球主磁场 IGRF 建模过程中, 卫星磁测数据覆盖密度较低且极区地磁变化场活跃, 因此在南北极高纬度区域地磁模型 IGRF 实际误差较大的现象比较显著, 这是导致东向 B_y (经度方向) 地磁模型误差预测效果低于 B_x 和 B_z 方向的另一个原因。

图 5 给出地磁模型总磁场强度 F 实际误差与模型预测误差的对比。通过相同时间间隔在测试集的输入值中加入一系列随机的异常值, 测试 SABO/RELM 对量测信息中异常值的抗干扰能力。从表 3 中的误差统计数据可以看出, 通过 SABO 算法优化后的 RELM, 使得预测误差结果更趋近于无异常值干扰时的预测结果。图 4 的仿真结果表明, 本文提出的方法可以有效降低异常值对模型预测精度的影响, 模型抗干扰能力得到了有效提高。

5.2 导航方法

滤波器参数设置如下。

- (1) 系统采样频率为 1 Hz。




图 4 B_y 方向地磁模型实际误差波动较大区域统计
Fig. 4 Statistical analysis of areas with significant fluctuations in actual errors of the B_y direction geomagnetic model

- (2) 卫星在地球固定坐标系下标定位置的初始值为 (4009.0036, 2047.4604, -5197.3722) km, 初始标定速度值为 (-5.197372, -2.420667, -4.986669) km·s⁻¹, 设置每个方向的初始位置误差范围为 25 km, 初始速度误差范围为 0.1 km·s⁻¹。

- (3) 系统误差协方差矩阵 $\mathbf{Q} = \text{diag}([10^{-9}, 10^{-9}, 10^{-9}, 10^{-10}, 10^{-10}, 10^{-10}])$ 。

- (4) 误差协方差矩阵 $\mathbf{P}_0$ 初始值设为单位矩阵。

- (5) 测量噪声的协方差矩阵 $\mathbf{R} = \mathbf{I}_{3 \times 3} \times 100^2$ 。

- (6) 地磁场模型采用国际地磁参考场模型 IGRF2020。

将 BP 和 LSTM 以及本文提出的 SABO/RELM 预测模型与滤波器结合进行仿真, 导航结果如图 6 所示。对导航结果进行统计, 结果列于表 4。由导航结果可知, 常规 EKF 地磁导航方法的位置误差和速度误差分别为 11.54 km 和 12.21 m·s⁻¹; BP 神经网络模型与 EKF 融合的地磁导航方法的位置误差和速度误差




图 5 总磁场强度 F 标量误差对比. (a) ELM 的预测效果 (含异常值), (b) SABO/RELM 的预测效果 (含异常值)
Fig. 5 Comparison of total magnetic field intensity F scalar error. (a) ELM (including outliers), (b) SABO/RELM (including outliers)

表 3 神经网络预测结果的误差统计
Table 3 Error statistics of neural network prediction results

方法	B_x		B_y		B_z	
	均值/nT	标准差	均值/nT	标准差	均值/nT	标准差
ELM (不含异常值)	-80.01	40.91	3.68	23.34	6.48	40.45
ELM (含异常值)	-80.28	52.26	4.19	53.42	6.40	57.04
RELM (含异常值)	-79.61	37.94	3.56	18.77	6.78	36.82
SABO/RELM (含异常值)	-79.70	40.59	3.67	21.83	6.75	39.31




图 6 位置估计误差
Fig. 6 Position estimation error

分别为 5.17 km 和 $5.70 \text{ m}\cdot\text{s}^{-1}$; LSTM 神经网络模型与 EKF 融合的地磁导航方法的位置误差和速度误差分别为 3.75 km 和 $4.08 \text{ m}\cdot\text{s}^{-1}$; 本文所提出的 SABO/RELM 方法融合 EKF 的位置误差和速度误差分别

表 4 地磁导航方法的误差统计
Table 4 Comparison of error statistics of multiple filter navigation

导航方法	位置误差/km	速度误差/ $(\text{m}\cdot\text{s}^{-1})$
SABO/RELM	1.26	1.39
BP	5.17	5.70
LSTM	3.75	4.08
EKF	11.54	12.21

为 1.26 km 和 $1.39 \text{ m}\cdot\text{s}^{-1}$.

相比常规 EKF 地磁导航方法、BP 融合 EKF 导航方法、LSTM 融合 EKF 导航方法, 本文所提出导航方法的位置导航精度分别提高了 89.08%, 75.63%, 66.40%, 速度导航精度分别提高了 88.62%, 75.61%, 65.93%, 这表明本文所提出的方法相比 BP 和 LSTM, 对地磁模型实际误差修正和补偿的效果较好, 能够有效提高地磁导航的精度.

6 结论

基于一种 SABO/RELM 误差预测模型, 结合扩展卡尔曼滤波算法, 提出了一种融合地磁模型误差修正的地磁导航方法. 该方法利用神经网络的非线性映射特性, 将时间变化信息和空间位置特征作为输入, 直接预测地磁模型误差, 并加入通过最优估计的正则化方法对输出层权值进行标准化, 提高网络的抗干扰能力. 最后, 将模型预测值作为滤波过程中的重要参数, 为状态量的估计值提供校正信息, 从而提高地磁导航的精度. 仿真结果表明, 与常规的地磁滤波导航方法、融合 BP 神经网络的导航方法以及融合 LSTM 的导航方法相比, 本文提出的改进方法可以有效提升地磁导航的精度.

参考文献

- [1] CHEN G F, YU F, ZONG H, *et al.* Geomagnetic orbit determination using fuzzy regulating unscented Kalman filter[J]. *Transactions of Nanjing University of Aeronautics and Astronautics*, 2021, **38**(4): 695-703
- [2] KIANI M, POURTAKDOUST S H. Adaptive square-root cubature – quadrature Kalman particle filter via KLD-sampling for orbit determination[J]. *Aerospace Science and Technology*, 2015, **46**: 159-167
- [3] LI X, SONG B Q, WANG Y J, *et al.* Calibration and alignment of tri-axial magnetometers for attitude determination[J]. *IEEE Sensors Journal*, 2018, **18**(18): 7399-7406
- [4] XIANG Fengzhuo, LI Guangyun, WANG Li, *et al.* Three-axis magnetometer online self-calibration method based on recursive least square[J]. *Transducer and Microsystems Technologies*, 2019, **38**(2): 30-33
- [5] BAI W Q, ZHANG X H, ZHANG S L, *et al.* Long-distance geomagnetic navigation in GNSS-denied environments with deep reinforcement learning[OL]. arXiv preprint arXiv: 2410.15837, 2024
- [6] CHEN Z, LIU K J, ZHANG Q, *et al.* Geomagnetic vector pattern recognition navigation method based on probabilistic neural network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 5909608
- [7] WINTOFT P, WIK M. Exploring three recurrent neural network architectures for geomagnetic predictions[J]. *Frontiers in Astronomy and Space Sciences*, 2021, **8**: 664483
- [8] HE Xinran, ZHONG Qiuzhen, CUI Yanmei, *et al.* Solar flare short-term forecast model based on long and short-term memory neural network[J]. *Chinese Journal of Space Science*, 2022, **42**(5): 862-872 (何欣然, 钟秋珍, 崔延美, 等. 基于长短期记忆神经网络的太阳耀斑短期预报 [J]. *空间科学学报*, 2022, **42**(5): 862-872)
- [9] SICILIANO F, CONSOLINI G, TOZZI R, *et al.* Forecasting SYM-H index: a comparison between long short-term memory and convolutional neural networks[J]. *Space Weather*, 2020, **19**(2): e2020SW002589
- [10] TASISTRO-HART A, GRAYVER A, KUVSHINOV A. Probabilistic geomagnetic storm forecasting via deep learning[J]. *Journal of Geophysical Research: Space Physics*, 2021, **126**(1): e2020JA028228
- [11] YANG Mao, ZHANG Shutian, WANG Bo. Short-term wind power forecasting method based on a causal regularized extreme learning machine[J]. *Power System Protection and Control*, 2024, **52**(11): 127-136
- [12] WANG H, XU L W, TAO Y, *et al.* OP performance prediction for complex mobile multiuser networks based on extreme learning machine[J]. *IEEE Access*, 2020, **8**: 14557-14564
- [13] TROJOVSKY P, MOHAMMAD D. Subtraction-average-based optimizer: a new swarm-inspired metaheuristic algorithm for solving optimization problems[J]. *Biomimetics*, 2023, **8**(2): 149
- [14] ALKEN P, THÉBAULT E, BEGGAN C D, *et al.* International geomagnetic reference field: the thirteenth generation[J]. *Earth, Planets and Space*, 2021, **73**: 49
- [15] ZHANG Tao, ZHANG Wenbo, GAO Dong, *et al.* A geomagnetic navigation method based on neural network prediction model error[J]. *Aerospace Control*, 2024, **42**(1): 37-42
- [16] WINCH D E, IVERS D J, TURNER J P R, *et al.* Geomagnetism and Schmidt quasi-normalization[J]. *Geophysical Journal International*, 2005, **160**(2): 487-504
- [17] GAO Dong, ZHU Minghui, HAN Peng. A geomagnetic/inertial depth fusion navigation method[J]. *Journal of Chinese Inertial Technology*, 2022, **30**(4): 437-444
- [18] JIAO M, WANG D Q, YANG Y, *et al.* More intelligent and robust estimation of battery state-of-charge with an improved regularized extreme learning machine[J]. *Engineering Applications of Artificial Intelligence*, 2021, **104**: 104407
- [19] LU Zhaoxing, LÜ Zhifeng, LI Ting, *et al.* Forecasting of the variable geomagnetic field based on BP neural network[J]. *Journal of Geodesy and Geodynamics*, 2021, **41**(3): 229-233

作者简介



郭红阳 男, 2001 年 3 月出生于河南省洛阳市, 2022 年于辽宁工程技术大学获得学士学位. 目前于河南工业大学机电工程学院就读硕士研究生, 主要研究方向为自主导航、人工智能.

E-mail: 13837955150@163.com



赵治华 (通信作者) 男, 1987 年 8 月出生于河南省新县, 现为河南工业大学机电工程学院副教授, 硕士生导师, 主要研究方向为智能传感器制备及其中粮油食品品质监测、疾病无创诊断等领域的应用.

E-mail: zhaozhihua@haut.edu.cn