http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0141

基于模型数据混合驱动的干扰磁场补偿方法

张德慧[1]，张金生[1]，李婷[1]，马啸宇[1]，廖守亿[1]，倪静[2]，魏豪[2,*]

(1. 火箭军工程大学 导弹工程学院，西安 710025；2. 飞行器数字敏捷设计全国重点实验室，成都 610000)

摘　　要：载体自身干扰磁场的精确补偿是提升地磁导航精度的关键挑战。针对传统补偿方法受限于线性假设和难以适应复杂场景的泛化需求等问题，提出2种基于模型数据混合驱动的磁干扰协同补偿方案。在预处理阶段，采用主成分分析方法对数据进行降维处理，并利用物理模型所求补偿参数对神经网络进行初始化处理；方案一通过分析传统补偿模型的缺陷，利用神经网络求解补偿参数，打破传统模型求解范式并预防可能存在的复共线问题，同时，在干扰磁场中引入随机因子项模拟非线性较强的随机干扰磁场；方案二通过构造损失函数联动数据驱动与模型驱动，将磁场特征的高效提取与干扰场的物理约束深度耦合。实验结果表明：所提方法较纯模型和纯数据补偿方法具有补偿精度高、泛化能力强等优点，在不同高度、不同地域进行泛化能力测试的最高补偿精度分别提高了69.64%和69.39%，验证了所提方法的有效性。

关　键　词：地磁导航；干扰磁场；航磁补偿；物理模型约束；BP神经网络；混合驱动

中图分类号：V249.32; TP183; P318

文献标志码：A　　**文章编号**：1001-5965(2026)09-3202-09

卫星拒止条件下的导航技术正朝着多元融合导航、抗干扰与信号增强、量子化与仿生化等方向发展[1-4]。军事冲突频发和民用领域对导航可靠性的需求更是极大推动了相关技术快速突破与成熟，随着各类新型导航技术的萌芽和人工智能算法的成熟，导航系统将实现更高的自主性与环境适应性。地磁导航技术凭借其独立、低成本且隐蔽性好等优势，展现出重要的应用价值，逐渐成为一种有效的辅助导航定位方法。

地磁场的无源、无辐射、全天时、全天候等特征使在一些特殊环境下，地磁导航能够弥补其他导航方式失效带来的无法精准定位导航的问题。地磁场基准图的制备、地磁场数据的实时测量精度、地磁匹配算法很大程度上影响地磁导航的定位效果，磁场的测量补偿技术是地磁导航的关键技术之一[5]。在常规的数据采集过程中，一般用磁力计来搜集地磁特征数据的设备，但磁力计测得的数据中不仅包含真实的地磁场数据，还包含其他磁源引起的磁干扰，导致地磁场测量精度大幅下降，导航精度大幅下降[6]。理论表明，磁场的强度随距离的三次方衰减[7]，因此，高空飞行器所受到的磁干扰关键来源是机载平台及设备，这些干扰磁场会极大地影响磁场数据的质量，进而降低地磁导航的定位精度。因此，在使用地磁数据前必须将这些干扰磁场数据进行剔除。

当前，载体干扰磁场的软补偿方法主要围绕物理模型驱动与数据驱动2大范式展开。

1）物理模型驱动方法，T-L(Tolles-Lawson)模型及其优化。吕禺萱等提出的基于线性约束与正交约束的递归最小二乘算法进行干扰磁场补偿问题的分析，有效降低了复共线性带来的影响[8]。Ye等提出一种包含36个系数的补偿矩阵，并采用套索正则化牛顿迭代(lasso regularization Newton iteration, LRNM)方法进行求解，极大改善了复共线

收稿日期：2025-03-20；**录用日期**：2025-05-27；**网络出版时间**：2025-07-01 09:36

网络出版地址：link.cnki.net/urlid/11.2625.V.20250630.1804.002

基金项目：国家自然科学基金(62473377)；陕西省自然科学基础研究计划(2024JC-YBQN-0657)；飞行器数字敏捷设计全国重点实验室基金(KFJJ-2024-I-03-05)

* **通信作者**. E-mail：772108312@qq.com

引用格式：张德慧，张金生，李婷，等. 基于模型数据混合驱动的干扰磁场补偿方法[J]. 北京航空航天大学学报，2026，52(9)：3202-3210.

Zhang D H，Zhang J S，Li T，et al. An interference magnetic field compensation method based on a model-data hybrid drive[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(9)：3202-3210 (in Chinese).

性问题[9]。Ma 等提出一种基于弹性权重整合的递归最小二乘算法, 通过控制参数更新方向, 有效抑制了灾难性遗忘问题[10]。T-L 模型作为航磁补偿的基础模型, 具有很强的代表性和物理解释性, 但由于该模型是一个理想化模型, 加上航磁数据之间存在相关性, 复杂环境下表现不佳和可能存在的复共线性始终是影响该模型精度最大的问题。

2)数据驱动方法, 深度学习技术的探索与应用。张宇等利用反向传播(back propagation, BP)神经网络建立干扰磁场数学模型, 将 T-L 模型中的 18 项补偿系数作为网络输入, 并进行目标探测实验, 补偿改善比超过 20[11]。Wang 等提出一种数据驱动的机载电子设备(onboard electronic equipment, OBE)干扰补偿方法, 将小波分解和长短期记忆(long short-term memory, LSTM)网络相结合构建预测模型, 通过半真实数据进行验证, 补偿信号的均方根误差小于 0.009 nT[12]。尽管如此, 数据驱动的方法仍存在数据依赖性高、鲁棒性不足、黑箱特性制约等核心瓶颈, 无法满足现实需求。

融合范式探索, 物理-数据双驱动补偿架构。王劲楠等提出一种基于生成对抗网络(generative adversarial network, GAN)和 LSTM 网络的改进 T-L 磁补偿模型, 通过融合物理模型和神经网络的优势, 为水下反潜任务提供了准确的磁场[13]。Xu 等提出了一种干扰模型引导的神经网络模型用于航空磁补偿, 能够进行非线性补偿, 且对数据的数量和质量依赖性更低[14]。该类方法物理机理约束网络架构与数据驱动优化模型参数的双向耦合, 为突破传统方法瓶颈提供了新思路。

考虑到 T-L 模型和数据驱动的神经网络单独进行补偿时会带来一些问题, 可将 2 种补偿方法结合起来, 弥补互相的缺点。本文提出 2 种模型数据混合驱动的载体干扰磁测建模方案, 这 2 种方案通过融合物理模型和数据驱动的神经网络, 将物理信息注入神经网络中, 以提升载体干扰磁场补偿的精度和泛化能力。

本文首先利用岭回归方法求得 T-L 模型的补偿参数向量, 对神经网络进行初始化处理。然后, 利用主成分分析[15]方法对所选特征进行降维处理, 再进行模型训练。最后, 分别选取训练集部分采样点数据和未知地域的采样点数据进行测试, 并选取均方根误差和决定系数等性能指标评价各方案的补偿效果。

1　理论基础

1.1　载体干扰磁场

载体的机械结构、电控装置、发动机及载体的姿态变化等均会产生局部强磁场[16], 一般情况下, 利用伸杆技术[7]很难实现足够远的距离来抵消干扰磁场, 需进行专业补偿。载体干扰磁场的组成复杂多样, 大多磁干扰的变化存在一定的规律, 方便进行补偿, 但还存在小部分干扰变化莫测, 无迹可寻。载体干扰磁场通常包括恒定磁场、感应磁场、涡流磁场和随机磁场等[17]。

短时间内相对于飞行器机身保持不变的称为恒定磁场, 由机身结构中的硬磁材料磁化引起, 其与飞机的飞行状态无关, 可视为常量。

随飞行器飞行姿态、飞行高度等因素变化的磁场称为感应磁场, 由机身中的软磁材料磁化引起, 其大小与外部激励磁场的大小近似呈线性关系, 与载体材料的磁导率、结构尺寸等多种因素有关, 与外加磁场无关。

随飞行器飞行速度等因素变化的磁场称为涡流磁场, 由穿过载体磁场的磁通量变化率引起, 其大小与载体磁场的变化率、金属体的磁导率、电导率及飞行器运动密切相关。

由载体上的电子设备或其周围环境产生的混乱、随机的干扰磁场称为随机磁场, 该磁场随机性较强, 通常没有规律, 经常通过屏蔽、滤波等方式进行消除。

1.2　T-L 模型

T-L 模型将载体干扰磁场划分为 3 个部分: 恒定磁场、感应磁场和涡流磁场[18]。T-L 模型利用测量磁场与载体坐标系各坐标轴之间的夹角计算方向余弦, 并利用 3 个方向余弦的一阶项、导数项、交叉耦合项分别对 3 种干扰磁场进行建模, 估算载体干扰磁场的强度[19]。

如图 1 所示, $\boldsymbol{H}_{\mathrm{m}}$为测量磁场, $\boldsymbol{H}_{\mathrm{e}}$为地磁场, $\boldsymbol{H}_{\mathrm{i}}$为干扰磁场, X、Y、Z为测量磁场与载体坐标系 3 个轴的夹角, 可得到式(1)所示关系:

$$\boldsymbol{H}_{\mathrm{m}}=\boldsymbol{H}_{\mathrm{e}}+\boldsymbol{H}_{\mathrm{i}} \tag{1}$$

$$|\boldsymbol{H}_{\mathrm{e}}|=\sqrt{|\boldsymbol{H}_{\mathrm{m}}|^2-2\boldsymbol{H}_{\mathrm{m}}\boldsymbol{H}_{\mathrm{i}}+|\boldsymbol{H}_{\mathrm{i}}|^2} \tag{2}$$

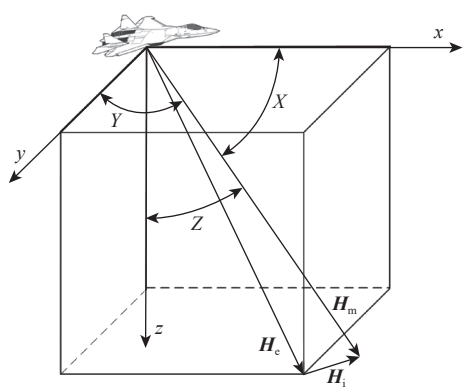


图 1　载体坐标系

Fig. 1　Carrier coordinate system

$$|\boldsymbol{H}_{\mathrm{e}}|=|\boldsymbol{H}_{\mathrm{m}}|\sqrt{1-2\frac{\boldsymbol{H}_{\mathrm{m}}\boldsymbol{H}_{\mathrm{i}}}{|\boldsymbol{H}_{\mathrm{m}}|^2}+\frac{|\boldsymbol{H}_{\mathrm{i}}|^2}{|\boldsymbol{H}_{\mathrm{m}}|^2}} \tag{3}$$

因为$|\boldsymbol{H}_{\mathrm{i}}|^2/|\boldsymbol{H}_{\mathrm{m}}|^2$很小，可忽略不计，并根据$\sqrt{1+x}=1+x/2-x^2/8+\cdots$，对式(3)进一步简化，可得

$$\varepsilon\approx\hat{\boldsymbol{H}}_{\mathrm{m}}\boldsymbol{H}_{\mathrm{i}} \tag{4}$$

式中：$\hat{\boldsymbol{H}}_{\mathrm{m}}=\boldsymbol{H}_{\mathrm{m}}/|\boldsymbol{H}_{\mathrm{m}}|=[\cos X,\ \cos Y,\ \cos Z]$为测量磁场的方向余弦；$\varepsilon=|\boldsymbol{H}_{\mathrm{m}}|-|\boldsymbol{H}_{\mathrm{e}}|$。

T-L模型中干扰磁场的组成为

$$\boldsymbol{H}_{\mathrm{i}}=\boldsymbol{H}_{\mathrm{per}}+\boldsymbol{H}_{\mathrm{inc}}+\boldsymbol{H}_{\mathrm{edd}} \tag{5}$$

式中：$\boldsymbol{H}_{\mathrm{per}}$为恒定磁场；$\boldsymbol{H}_{\mathrm{inc}}$为感应磁场；$\boldsymbol{H}_{\mathrm{edd}}$为涡流磁场。

$$\boldsymbol{H}_{\mathrm{per}}=\begin{bmatrix}a_1\\a_2\\a_3\end{bmatrix} \tag{6}$$

$$\boldsymbol{H}_{\mathrm{inc}}=|\boldsymbol{H}_{\mathrm{m}}|\begin{bmatrix}b_{11}&b_{12}&b_{13}\\b_{21}&b_{22}&b_{23}\\b_{31}&b_{32}&b_{33}\end{bmatrix}\hat{\boldsymbol{H}}_{\mathrm{m}}^{\mathrm{T}} \tag{7}$$

$$\boldsymbol{H}_{\mathrm{edd}}=|\boldsymbol{H}_{\mathrm{m}}|\begin{bmatrix}c_{11}&c_{12}&c_{13}\\c_{21}&c_{22}&c_{23}\\c_{31}&c_{32}&c_{33}\end{bmatrix}\dot{\hat{\boldsymbol{H}}}_{\mathrm{m}}^{\mathrm{T}} \tag{8}$$

将式(5)代入式(4)中，可得

$$\varepsilon\approx\hat{\boldsymbol{H}}_{\mathrm{m}}\begin{bmatrix}a_1\\a_2\\a_3\end{bmatrix}+|\boldsymbol{H}_{\mathrm{m}}|\hat{\boldsymbol{H}}_{\mathrm{m}}\begin{bmatrix}b_{11}&b_{12}&b_{13}\\b_{21}&b_{22}&b_{23}\\b_{31}&b_{32}&b_{33}\end{bmatrix}\hat{\boldsymbol{H}}_{\mathrm{m}}^{\mathrm{T}}+|\boldsymbol{H}_{\mathrm{m}}|\hat{\boldsymbol{H}}_{\mathrm{m}}\begin{bmatrix}c_{11}&c_{12}&c_{13}\\c_{21}&c_{22}&c_{23}\\c_{31}&c_{32}&c_{33}\end{bmatrix}\dot{\hat{\boldsymbol{H}}}_{\mathrm{m}}^{\mathrm{T}} \tag{9}$$

对式(9)进行简化可得

$$\varepsilon=\boldsymbol{A}\boldsymbol{\theta} \tag{10}$$

$$\begin{aligned}\boldsymbol{A}=|\boldsymbol{H}_{\mathrm{m}}|[&\cos X/|\boldsymbol{H}_{\mathrm{m}}|,\cos Y/|\boldsymbol{H}_{\mathrm{m}}|,\cos Z/|\boldsymbol{H}_{\mathrm{m}}|,\\&\cos^2X,\cos X\cos Y,\cos X\cos Z,\cos^2Y,\\&\cos Y\cos Z,\cos^2Z,\cos X\cos'X,\cos X\cos'Y,\\&\cos X\cos'Z,\cos Y\cos'X,\cos Y\cos'Y,\\&\cos Y\cos'Z,\cos Z\cos'X,\cos Z\cos'Y,\cos Z\cos'Z]\end{aligned} \tag{11}$$

$$\begin{aligned}\boldsymbol{\theta}=[&a_1,a_2,a_3,b_{11},\ (b_{12}+b_{21}),(b_{13}+b_{31}),b_{22},\\&(b_{23}+b_{32}),b_{33},c_{11},c_{12},c_{13},c_{21},\ c_{22},c_{23},c_{31},c_{32},c_{33}]^{\mathrm{T}}\end{aligned} \tag{12}$$

式中：$\boldsymbol{A}$为信息矩阵，均为已知信息；$\boldsymbol{\theta}$为补偿参数向量，均为未知数据。$b_{12}+b_{21}$项可简写为b_{12}，其余项同理可进行简写，得到含有18个未知数的向量，如下：

$$\begin{aligned}\boldsymbol{\theta}=[&a_1,a_2,a_3,b_{11},b_{12},b_{13},b_{22},b_{23},\ b_{33},\\&c_{11},c_{12},c_{13},c_{21},c_{22},c_{23},c_{31},c_{32},c_{33}]^{\mathrm{T}}\end{aligned} \tag{13}$$

$$\boldsymbol{\theta}=(\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A})^{-1}\boldsymbol{A}^{\mathrm{T}}\varepsilon \tag{14}$$

如式(14)所示，利用T-L模型进行补偿时需要求解出补偿参数向量$\boldsymbol{\theta}$，进而计算出干扰磁场，从而达到补偿的目的。但航磁数据的相关性，可能会使$\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A}$退化为奇异矩阵，导致补偿参数向量无法正常求解或不存在唯一确定的解。传统方法一般利用岭回归来优化该类问题[20]：

$$J(\boldsymbol{\theta})=\|\varepsilon-\boldsymbol{A}\boldsymbol{\theta}\|^2+\lambda\|\boldsymbol{\theta}\|^2 \tag{15}$$

$$\hat{\boldsymbol{\theta}}=(\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A}+\lambda\boldsymbol{I})^{-1}\boldsymbol{A}^{\mathrm{T}}\varepsilon \tag{16}$$

式中：$J(\boldsymbol{\theta})$为岭回归的目标损失函数；$\hat{\boldsymbol{\theta}}$表示$\boldsymbol{\theta}$的估计值；$\lambda$为L2正则化系数；$\boldsymbol{I}$为单位矩阵。

式(15)和式(16)分别为岭回归方法的目标函数和解析解，岭回归通过L2正则化有效应对过拟合和共线性，适用于高维及相关性强的数据，是提升线性模型稳定性的重要工具。

1.3 BP神经网络

BP神经网络作为深度学习的基础，广泛应用于分类、图像识别与自然语言处理等领域。BP神经网络是一种基于误差BP算法的多层前馈神经网络，属于监督学习模型[21]。其通过前向传播计算输出，再通过BP调整网络的权重和偏置等参数，以最小化预测值与真实值之间的误差，其基本结构如图2所示。

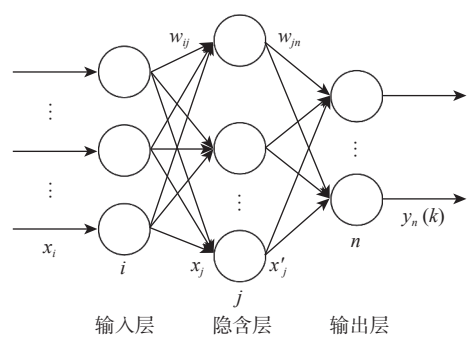


图2 BP神经网络

Fig. 2 BP neural network

BP神经网络主要由输入层、隐含层和输出层组成。输入层用来接收外部输入数据，隐含层通过非线性激活函数处理输入信号来提取特征，输出层输出最终预测结果。

BP神经网络的学习过程由正向传播和BP组成，正向传播用来计算网络的输出：

$$x_j=\sum_i(w_{ij}x_i+b_{ij}) \tag{17}$$

$$x'_j=f(x_j) \tag{18}$$

$$y_n(k)=\sum_j(w_{jn}x'_j+b_{jn}) \tag{19}$$

式中: x_i为网络的输入; w_{ij}和w_{jn}为各层间的权值; b_{ij}和b_{jn}为偏置项; $f(\cdot)$为激活函数; $y_n(k)$为网络的输出。

通过网络的输出$y_n(k)$和标签数据$y(k)$计算损失函数E:

$$e(k)=y(k)-y_n(k) \tag{20}$$

$$E=\frac{1}{2}e(k)^2 \tag{21}$$

BP 利用梯度下降法, 调整各层间的连接权值:

$$w_{ij}(k+1)=w_{ij}(k)+\Delta w_{ij} \tag{22}$$

$$\Delta w_{ij}=-\eta\frac{\partial E}{\partial w_{ij}}=\eta e(k)\frac{\partial y_n}{\partial w_{ij}} \tag{23}$$

$$\frac{\partial y_n}{\partial w_{ij}}=\frac{\partial y_n}{\partial x_j'}\cdot\frac{\partial x_j'}{\partial x_j}\cdot\frac{\partial x_j}{\partial w_{ij}}=w_{jn}\frac{\partial x_j'}{\partial x_j}x_i \tag{24}$$

式中: $w_{ij}(k+1)$为更新后的权值; $w_{ij}(k)$为更新前的权值; Δw_{ij}为权值的变化量; η为学习率。

求解偏导的过程用到链式求导法则, 权值w_{jn}的更新原理同上。

通过设置合理的网络层数、各层神经元数量、学习率、批量大小、迭代次数、正则化系数等超参数, 选取合适的激活函数及构建恰当的损失函数即可完成相关数据的处理工作。

2　模型数据混合驱动的干扰磁场建模方法

2.1　方案一

考虑到 T-L 模型是一个理想化的物理模型, 仅考虑恒定磁场、感应磁场和涡流磁场, 未考虑机载设备中产生的没有物理规律的随机磁场等非线性成分, 这就可能导致安装在舱内的磁力仪无法正常使用 T-L 模型补偿测量数据, 故采用 BP 神经网络输出得到一个随机因子项来模拟舱内产生的随机磁场, 将其引入干扰磁场的建模中。此外, 利用神经网络训练获得补偿参数向量, 一方面, 打破 T-L 模型求解补偿参数的壁垒, 提升线性模型在复杂环境下的表达能力, 另一方面, 预防可能存在的复共线问题。

方案一处理数据过程如图 3 所示, $\boldsymbol{H}_{\mathrm{m}}$为标量磁力计的磁场测量值, D为测量磁场的方向余弦, $\boldsymbol{M}_{\mathrm{s}}$为飞行器上一些传感器数据, $\boldsymbol{\theta}_{\mathrm{p}}$为补偿参数向量的预测值, 共包含 18 个参数, $\boldsymbol{r}_{\mathrm{p}}$为用于改善 T-L 模型的随机因子项。

网络 1 可得到补偿参数向量, 通过式(10)计算出载体坐标系下包括恒定磁场、感应磁场和涡流磁场的干扰磁场; 网络 2 可得到除 T-L 模型中干扰磁场之外的随机干扰因子项。将网络 1 和网络 2 的输出结合得到此方案输出的总干扰磁场, 并构造损失函数, 如下:

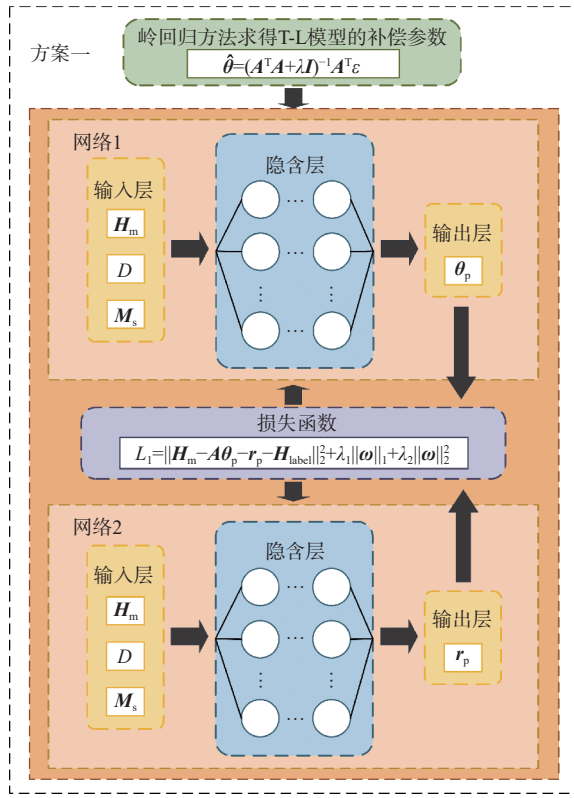


图 3　方案一训练过程

Fig. 3　Training process of scheme one

$$L_1=\left\|\boldsymbol{H}_{\mathrm{m}}-\boldsymbol{A}\boldsymbol{\theta}_{\mathrm{p}}-\boldsymbol{r}_{\mathrm{p}}-\boldsymbol{H}_{\mathrm{label}}\right\|_2^2+\lambda_1\|\boldsymbol{\omega}\|_1+\lambda_2\|\boldsymbol{\omega}\|_2^2 \tag{25}$$

式中: $\boldsymbol{H}_{\mathrm{label}}$为磁场标签值; λ_1为 L1 正则化系数; λ_2为 L2 正则化系数; $\boldsymbol{\omega}$为神经网络的权重参数。

网络 1 的结构为 26: 200: 120: 70: 18, 网络二的结构为 26: 120: 60: 40: 20: 1。

2.2　方案二

考虑到纯数据驱动的神经网络可解释性差且泛化能力不足, 但复杂环境下补偿精度较高; 而基于 T-L 模型的补偿方法在复杂地磁环境下表现力较差, 但其具有一定的物理意义。将两者通过损失函数有机结合起来, 得到一种数模联动的补偿方法。

方案二处理数据的过程如图 4 所示, 网络 1 可得到补偿参数向量, 通过式(10)计算出载体坐标系下包括恒定磁场、感应磁场和涡流磁场的干扰磁场。网络 2 可得到干扰磁场的预测值。构造网络 1 和网络 2 的损失函数如下:

$$L_2^1=\left\|\boldsymbol{A}\boldsymbol{\theta}_{\mathrm{p}}-\boldsymbol{H}_{\mathrm{ip}}\right\|_2^2 \tag{26}$$

$$L_2^2=\left\|\boldsymbol{H}_{\mathrm{m}}-\boldsymbol{H}_{\mathrm{ip}}-\boldsymbol{H}_{\mathrm{label}}\right\|_2^2 \tag{27}$$

式中: $\boldsymbol{\theta}_{\mathrm{p}}$为网络 1 输出的补偿参数向量预测值; $\boldsymbol{H}_{\mathrm{ip}}$为网络 2 输出的干扰磁场预测值。

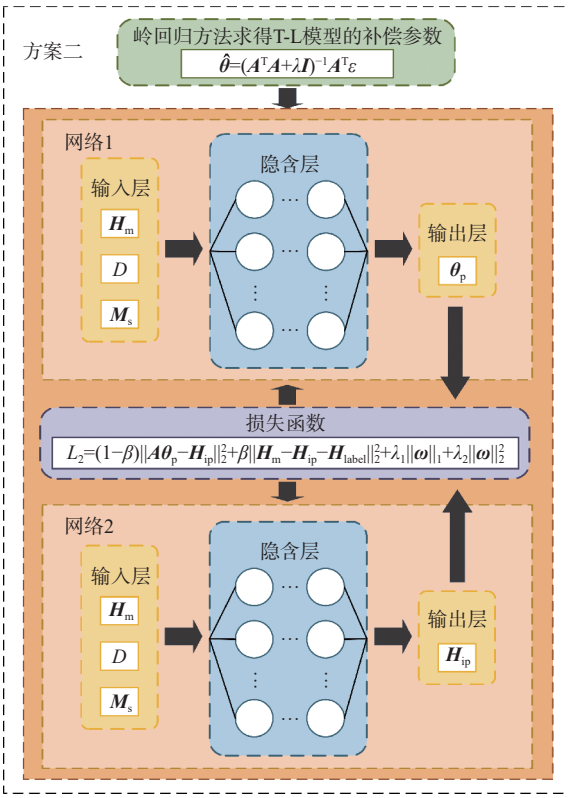


图4 方案二训练过程

Fig. 4 Training process of scheme two

构造方案二的损失函数如下：

$$L_2=(1-\beta)L_2^1+\beta L_2^2+\lambda_1\|\boldsymbol{\omega}\|_1+\lambda_2\|\boldsymbol{\omega}\|_2^2 \tag{28}$$

式中：β为损失函数L_2^2的权重系数，即数据驱动为主的网络所得结果在总损失函数中的占比，本文β设置为0.9。

该方案以测量磁场和网络2所输出干扰磁场之差得到的磁场预测值作为整个网络的输出。网络1的结构为26：200：120：70：18，网络2的结构为26：150：80：30：1。

2.3 网络参数

表1为本文2种方案共同的网络参数。在输入特征的选取中，根据地磁信息和部分机舱内常见的设备信号，选取5个时刻的9个特征，共45个特征，通过5个时刻特征数据的训练来拟合最后时刻的输出，训练过程如图5所示。

由于输入特征信息较多，为高效利用特征量，提升模型的训练速度，在特征量的处理过程中不仅用到归一化处理，还采用主成分分析法。选择累计解释方差达到99.99%的主成分数量，经过降维后，特征量的个数由45个降到26个。

图6为几种常见激活函数的对比，本文选取Swish(·)函数，该函数是一个平滑的非单调激活函数，能够建模更复杂的映射关系，且在正向传播中能够产生较大的梯度，有助于缓解梯度消失问题，提高模型的训练效率。

$$\mathrm{Swish}(x)=x\frac{1}{1+\mathrm{e}^{-\alpha x}} \tag{29}$$

式中：α为一可调参数，本文设置为1。

表1 2种方案的共同网络参数设置

Table 1 Common network parameter settings for the two schemes

模型输入	学习率	批量大小	迭代次数	L1正则化系数	L2正则化系数	激活函数	优化器
45个特征	0.000 1	128	300	0.000 01	0.000 001	Swish(·)函数	Adam

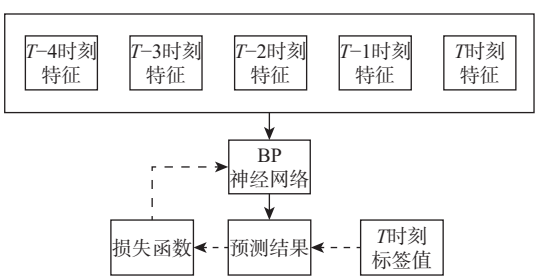


图5 神经网络的训练过程

Fig. 5 The training process of neural networks

在构建损失函数时借鉴弹性网络的特点，损失函数中同时加入了L1和L2正则项。L1正则化对权重的绝对值进行惩罚，倾向于产生稀疏解，适合特征选择；L2正则化对权重的平方进行惩罚，倾向于使权重均匀地趋近于较小值，适合防止过拟合。

本文采用均方根误差(root mean square error, RMSE)和决定系数$R^2$2个性能指标来评判干扰磁场的补偿效果。RMSE用来评估模型的预测精度，RMSE值越小，补偿效果越好；R^2用来评估模型的整体拟合优度，是一个无量纲的统计量，R^2值越接近1，说明模型对数据的解释能力越强。

$$\sigma_{\mathrm{RMSE}}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2} \tag{30}$$

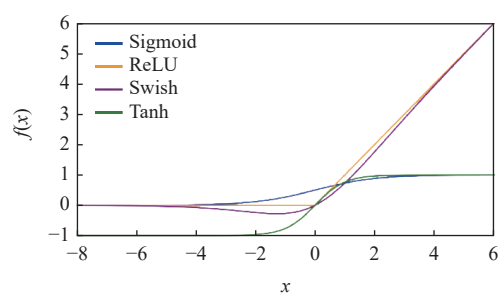


图6 不同激活函数的对比曲线

Fig. 6 Comparative curves of different activation functions

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{31}$$

式中: y_i为标签值; $\hat{y}_i$为预测值; $\bar{y}$为标签值的均值; n为样本数量。

3　实验结果和性能分析

3.1　实验环境及数据集

实验所使用的计算机型号为 Thinkbook15 Ⅱ-L, CPU 为 Intel(R) Core(TM) i7-1065G7CPU @ 1.30 GHz, 16 GB 内存, 深度学习框架为 PyTorch。

使用的数据集以 USAF-MIT“磁信号增强挑战赛”开源数据为基础。该数据集于 2020 年公布, 其中包括载体的飞行信息、磁力计数据和多种传感器数据。

本文选取 1 003 号航班中部分航线的数据, 不同航线的飞行区域如表 2 所示, 由于伦弗鲁省 800 m 高度(1 003.10)的数据为该挑战赛预留内测数据, 暂未公开, 因此, 本文主要以 1 003.02、1 003.04、1 003.08 这 3 段航线展开干扰磁场补偿的相关研究。

表 2　不同航线数据解读

Table 2　Interpretation of data for different routes

航线编号	描述
1 003.02	安大略省东部400 m高度自由飞行
1 003.04	安大略省东部800 m高度自由飞行
1 003.08	伦弗鲁省400 m高度自由飞行

3.2　实验数据及初处理

实验所采用数据的详细描述如表 3 所示, 其中, 测量数据和标签数据均为磁异常数据[22]。mag_4_iuc 为本文研究的测量磁场 $\boldsymbol{H}_{\mathrm{m}}$, 是 4 号标量磁力计(安装在飞行器后舱地板的标量磁力计)未经补偿的磁异常数据, 由 4 号标量磁力计未经补偿的总磁场减去主磁场和日变磁场计算得到。mag_1_ic 为标签数据 $\boldsymbol{H}_{\mathrm{label}}$, 是 1 号磁力计(安装在尾针的标量磁力计)经补偿后的磁异常数据, 由 1 号标量磁力计经补偿后的总磁场减去主磁场和日变磁场计算得到。

其余数据均为数据集中的原始数据。flux_b_x、flux_b_y、flux_b_z 用来表示方向余弦 $\boldsymbol{D}$, cur_strb、cur_ac_hi、cur_heat、vol_bat_1、vol_block 为传感器信号 $\boldsymbol{M}_{\mathrm{s}}$, 是飞行器中电子设备产生的模拟信号, 用来模拟复杂的机载设备环境, 通过引入这些电压和电流的变化将舱内复杂的干扰源映射到 T-L 模型参数的表达中。

表 3　神经网络的输入、标签信息描述

Table 3　Description of input and label information for neural networks

特征量	描述
mag_4_iuc	4号标量磁力计未经补偿的磁异常数据
flux_b_x	磁通门B的X轴方向的磁场大小
flux_b_y	磁通门B的Y轴方向的磁场大小
flux_b_z	磁通门B的Z轴方向的磁场大小
cur_strb	频闪灯的电流传感器
cur_ac_hi	空调风扇高速的电流传感器
cur_heat	惯性导航系统加热器的电流传感器
vol_bat_1	电池1的电压传感器
vol_block	模块的电压传感器
mag_1_ic	1号标量磁力计经补偿后的磁异常数据

3.3　补偿效果对比

选取 1 003.02 航线的 16 000 个采样点作为训练集, 并选取这 16 000 个采样点中的后 2 000 个采样点作为测试集, 验证本文 2 种方案的补偿效果, 补偿结果如图 7 和表 4 所示。

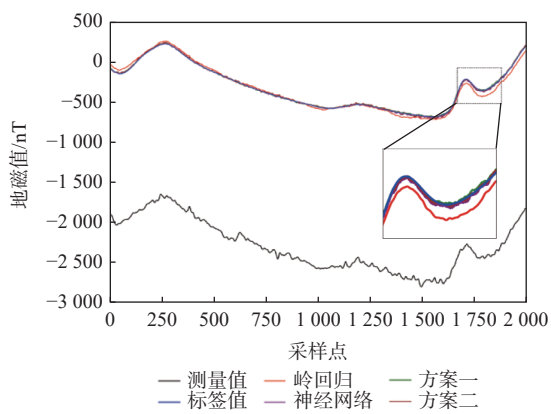


图 7　不同方案的补偿效果

Fig. 7　The compensatory effects of different schemes

表 4　不同方案的补偿能力对比

Table 4　Comparison of compensation capabilities of different schemes

方案	RMSE/nT	R^2
岭回归	33.944	0.985 83
神经网络	9.301	0.998 82
方案一	6.871	0.999 36
方案二	7.313	0.999 27

通过补偿结果发现, 岭回归方法虽然补偿精度较低, 但其遵循 T-L 模型的物理意义, 将测量磁场按照正确的方向进行补偿; 而采用 BP 神经网络的方法补偿精度较高, 体现了神经网络对这类数据的强大解析能力。此外, 本文 2 种方案较传统补偿方法均对测量磁场有较好的补偿效果, 展现出了深度学习

和T-L模型融合在处理此类问题具有一定的优势。

3.4 泛化能力分析

选取1 003.02航线的16 000个采样点作为训练集，分别选取1 003.02航线非训练集的2 000个采样点，1 003.04航线的2 000个采样点，1 003.08航线的2 000个采样点作为验证泛化能力的测试集，2种方案的泛化能力测试如图8所示。

由于2种方案均采用岭回归所求得补偿参数对网络进行初始化处理，为验证向神经网络注入物理信息对泛化能力的提升起到一定的作用，以纯数据驱动网络的补偿方法进行对照实验，构造该网络结构与方案二中网络2结构相同，分别对该网络进行未初始化处理和初始化处理，再进行磁场补偿，补偿效果如表5所示。

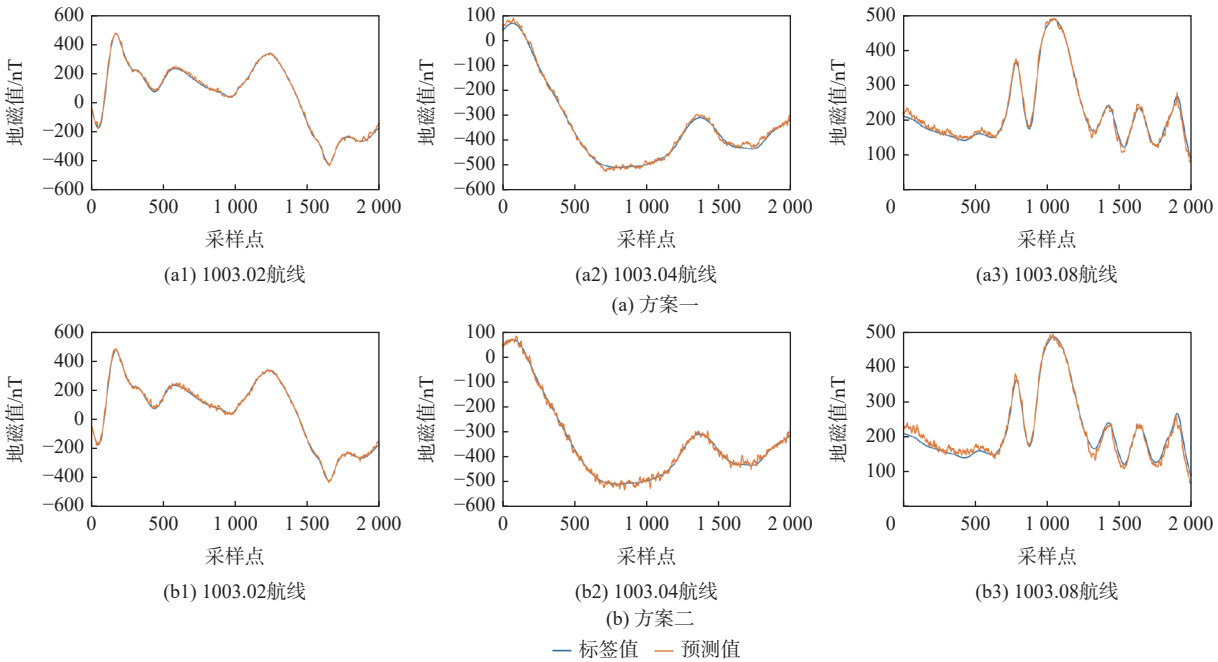


图8 不同航线泛化能力测试结果

Fig. 8 Test results of generalization ability for different routes

表5 不同方案的泛化能力对比

Table 5 Comparison of generalization capabilities of different schemes

方案	RMSE/nT			R^2		
	1003.02航线	1003.04航线	1003.08航线	1003.02航线	1003.04航线	1003.08航线
岭回归	86.490	73.191	133.078	0.834 9	0.811 4	−0.836 4
神经网络未初始化	14.561	31.465	31.153	0.995 7	0.963 4	0.895 3
神经网络初始化	10.849	13.302	16.574	0.997 6	0.993 5	0.970 4
方案一	9.796	9.552	9.536	0.998 0	0.996 6	0.990 2
方案二	9.746	9.761	10.304	0.998 3	0.996 5	0.988 5

通过是否对神经网络进行物理信息初始化处理的补偿效果对比，能够得出在神经网络中引入适当的物理信息能在一定程度上增强模型泛化能力的结论，但随着高度和地域的变化，2种神经网络补偿方法的泛化能力均有所下降。将方案一、方案二与仅依靠物理模型、纯数据驱动网络方法的补偿效果进行对比，2种方案较仅依靠物理模型方法的补偿精度最高可提升92.83%和92.26%，较纯数据驱动网络方法的补偿精度最高可提升69.64%和68.98%。本文2种混合驱动的干扰磁场补偿方案不论是在不同高度，还是在不同地域的磁补偿上均表现出较强的泛化能力。

4 结 论

本文设计了2种模型数据混合驱动的干扰磁场补偿方案，不仅将物理信息注入神经网络中，还将传统T-L补偿模型有机结合到神经网络中进行干扰磁场补偿，通过实验分析可以得出以下结论：

1）方案一通过分析T-L模型的建模机理和模型缺陷，利用神经网络非线性强的特性引入随机因子项改善传统物理模型的弊端，并利用神经网络求解T-L模型的补偿参数向量，打破传统模型求解的

范式, 使其较传统方法的补偿能力有所提升。

2) 方案二通过将数据驱动和模型驱动 2 种方法进行有机结合, 设计损失函数, 构造一种数模联动的补偿方法, 补偿效果优于纯数据驱动和纯模型驱动的补偿效果。

3) 2 种方案分别采用不同的数模结合方式进行干扰磁场的补偿, 通过实验结果对比, 2 种方案在 RMSE 和 R^2 等性能指标上均优于传统补偿方法, 体现了本文方法在干扰磁场补偿泛化能力中的优势。从整体的补偿效果来看, 方案一的补偿效果稍优于方案二。对比 800 m 高度的补偿结果, 2 种方案的评价指标相差不多, 但方案一的预测曲线较为平滑且波动较小, 而方案二的预测曲线波动频繁且幅度较大。

深度学习近些年被广泛应用于各行各业, 但其在实践中最大的不足是可解释性不强, 泛化能力弱等; 物理模型具有很强的物理意义, 但有时灵活性不高, 遇到复杂环境很难使用。在未来的研究中, 将继续探究传统补偿方法与深度学习补偿方法的关系, 通过有效结合 2 种方式, 进一步提升干扰磁场补偿的泛化能力, 并将本文方法拓展到干扰磁场的矢量补偿中, 应用到实地的航磁补偿中。

参考文献 (References)

[1] 何康辉, 董朝阳, 王青. 一种考虑 GPS 信号中断的导航滤波算法[J]. 北京航空航天大学学报, 2019, 45(9): 1874-1881.
He K H, Dong C Y, Wang Q. A navigation filtering algorithm considering GPS signal interruption[J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(9): 1874-1881(in Chinese).

[2] 陈飞强, 孙一凡, 唐小妹, 等. GNSS 信号功率增强对调零抗干扰接收机的性能影响[J]. 国防科技大学学报, 2023, 45(5): 72-77.
Chen F Q, Sun Y F, Tang X M, et al. Effect of signal power enhancement on the performance of GNSS null-steering anti-jamming receiver[J]. Journal of National University of Defense Technology, 2023, 45(5): 72-77(in Chinese).

[3] 吴德伟, 苗强, 何思璇, 等. 量子传感的导航应用研究现状与展望[J]. 空军工程大学学报 (自然科学版), 2021, 22(6): 67-76.
Wu D W, Miao Q, He S X, et al. A study of existing status and prospects for quantum sensor in navigation[J]. Journal of Air Force Engineering University (Natural Science Edition), 2021, 22(6): 67-76(in Chinese).

[4] 朱祥维, 沈丹, 肖凯, 等. 类脑导航的机理、算法、实现与展望[J]. 航空学报, 2023, 44(19): 1-33.
Zhu X W, Shen D, Xiao K, et al. Mechanisms, algorithms, implementation and perspectives of brain-inspired navigation[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(19): 1-33(in Chinese).

[5] 李婷, 王仕成, 张金生. 磁场测量误差补偿技术综述[J]. 电光与控制, 2018, 25(6): 66-71.
Li T, Wang S C, Zhang J S. A review on geomagnetic measurement error compensation technologies[J]. Electronics Optics & Control, 2018, 25(6): 66-71(in Chinese).

[6] 缪林良, 米洒洒, 王玮琳, 等. 航磁矢量测量的误差分析和补偿算法研究[J]. 电子测量与仪器学报, 2021, 35(12): 15-23.
Miao L L, Mi S S, Wang W L, et al. Error analysis and compensation algorithm research of aeromagnetic vector measurement[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(12): 15-23(in Chinese).

[7] 周斌, 王劲东. 卫星磁部件分布对梯度法消除剩磁的影响分析[J]. 中国空间科学技术, 2013, 33(5): 29-34.
Zhou B, Wang J D. Influence of magnetic component distribution of satellite on eliminating remanant magnetic field by gradient method[J]. Chinese Space Science and Technology, 2013, 33(5): 29-34(in Chinese).

[8] 吕禺萱, 雷华明. 磁异常探测中载体干扰磁场 RLS 补偿方法[J]. 电子测量与仪器学报, 2022, 36(3): 96-104.
Lyu Y X, Lei H M. RLS method for carrier interference compensation in magnetic anomaly detection[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(3): 96-104(in Chinese).

[9] Ye L W, Yu Z T, Zhang Y X, et al. An aeromagnetic compensation strategy for large UAVs[J]. Sensors, 2024, 24(12): 3775.

[10] Ma X Y, Zhang J S, Liao S Y, et al. Aeromagnetic compensation method based on recursive least square and elastic weight consolidation[J]. Applied Geophysics, 2025, 22(2): 279-290.

[11] 张宇, 陈正想, 覃涛. 基于 BP 神经网络的航磁补偿方法研究[J]. 数字海洋与水下攻防, 2023, 6(6): 734-742.
Zhang Y, Chen Z X, Qin T. Research on aeromagnetic compensation method based on BP neural network[J]. Digital Ocean & Underwater Warfare, 2023, 6(6): 734-742(in Chinese).

[12] Wang Y Z, Han Q, Zhan D C, et al. A data-driven OBE magnetic interference compensation method[J]. Sensors, 2022, 22(20): 7732.

[13] 王劲楠, 张晓明, 张鸽, 等. 基于 GAN-LSTM 改进 T-L 磁补偿方法[J]. 电子测量技术, 2025, 48(5): 50-56.
Wang J N, Zhang X M, Zhang G, et al. Improved T-L magnetic compensation method based on GAN-LSTM[J]. Electronic Measurement Technology, 2025, 48(5): 50-56(in Chinese).

[14] Xu Y J, Liu Z Y, Zhang Q, et al. Interference model guided neural network for aeromagnetic compensation[J]. IEEE Sensors Journal, 2024, 24(8): 12266-12275.

[15] 王晨阳. PCA 和 GA-BP 结合的地磁导航适配区选择方法[J]. 电光与控制, 2018, 25(6): 110-114.
Wang C Y. Geomagnetic navigation matching area selection based on PCA and GA-BP neural network[J]. Electronics Optics & Control, 2018, 25(6): 110-114(in Chinese).

[16] 林沂, 孙晶京, 闫旭. 地磁导航定位技术原理与方法综述[J]. 全球定位系统, 2023, 48(6): 32-41.
Lin Y, Sun J J, Yan X. A review of the principles and methods of geomagnetic navigation and positioning technology[J]. GNSS World of China, 2023, 48(6): 32-41(in Chinese).

[17] 李季. 地磁测量中载体干扰磁场特性及补偿方法研究[D]. 长沙: 国防科学技术大学, 2013: 99-100.
Li J. Study on the characteristics and compensation method of vehicle interferential magnetic field in geomagnetic measurement[D]. Changsha: National University of Defense Technology, 2013: 99-100(in Chinese).

[18] Tolles W E, Lawson J D. Magnetic compensation of mad equipped

aircraft, 201-1[R]. Mineola: Airborne Instruments Laboratory, 1950: 201-211.

[19] Leliak P. Identification and evaluation of magnetic-field sources of magnetic airborne detector equipped aircraft[J]. IRE Transactions on Aerospace and Navigational Electronics, 1961, ANE-8(3): 95-105.

[20] Su Z N, Jiao J, Zhou S, et al. Aeromagnetic compensation method based on ridge regressional gorithm[J]. Global Geology, 2022, 25(1): 41-48.

[21] 戚德虎, 康继昌. BP 神经网络的设计[J]. 计算机工程与设计, 1998, 19(2): 48-50.
Qi D H, Kang J C. On design of the BP neural network[J]. Computer Engineering and Design, 1998, 19(2): 48-50(in Chinese).

[22] 徐文耀, 白春华, 康国发. 地壳磁异常的全球模型[J]. 地球物理学进展, 2008, 23(3): 641-651.
Xu W Y, Bai C H, Kang G F. Global models of earth's crust magnetic anomalies[J]. Progress in Geophysics, 2008, 23(3): 641-651(in Chinese).

An interference magnetic field compensation method based on a model-data hybrid drive

ZHANG Dehui[1], ZHANG Jinsheng[1], LI Ting[1], MA Xiaoyu[1], LIAO Shouyi[1], NI Jing[2], WEI Hao[2,*]

(1. College of Missile Engineering, Rocket Force University of Engineering, Xi'an 710025, China;
2. The National Key Laboratory of Digital and Agile Aircraft Design, Chengdu 610000, China)

Abstract: The precise compensation of the carrier's self-interference magnetic field is a key challenge in improving the accuracy of geomagnetic navigation. Two model-data hybrid-driven magnetic interference collaborative compensation strategies are presented in response to the drawbacks of conventional compensation techniques, including the linear assumption and the challenge of responding to complex settings. In the preprocessing stage, principal component analysis is used to reduce the dimensionality of the data, and the compensation parameters obtained from the physical model are used to initialize the neural network. In scheme one, the shortcomings of the conventional compensation model are analyzed, the compensation parameters are solved using a neural network, the traditional model-solving paradigm is broken and potential multicollinearity issues are avoided, and a random factor term is introduced in the interference magnetic field to simulate the random interference magnetic field with strong nonlinearity. Scheme two constructs a loss function to link data-driven and model-driven, deeply coupling the efficient extraction of magnetic field features with the physical constraints of the interference field. Experimental results show that the proposed methods have the advantages of high compensation accuracy and strong generalization ability compared with pure model and pure data compensation methods. The highest compensation accuracy in generalization ability tests at different heights and different regions has increased by 69.64% and 69.39%, respectively, verifying the effectiveness of the proposed methods.

Keywords: geomagnetic navigation; interference magnetic field; aeromagnetic compensation; physical model constraint; BP neural network; hybrid drive

Received: 2025-03-20; **Accepted**: 2025-05-27; **Published Online**: 2025-07-01 09:36

URL: link.cnki.net/urlid/11.2625.V.20250630.1804.002

Foundation items: National Natural Science Foundation of China (62473377); Natural Science Basic Research Program of Shaanxi (2024JC-YBQN-0657); The National Key Laboratory of Digital and Agile Aircraft Design (KFJJ-2024-I-03-05)

* **Corresponding author**. E-mail: 772108312@qq.com