

基于LSTM与扩展卡尔曼滤波的无人机机载电子磁干扰补偿研究

刘颖^{1,2,3}, 王顺^{1,2}, 纪奕才^{1,2}, 黄玲^{1,2}, 刘小军^{1,2}, 方广有^{1,2}

¹中国科学院空天信息创新研究院, 北京

²中国科学院空天信息创新研究院电磁辐射与探测技术重点实验室, 北京

³中国科学院大学电子电气与通信工程学院, 北京

收稿日期: 2026年3月18日; 录用日期: 2026年4月17日; 发布日期: 2026年4月24日

摘要

针对无人机磁探测任务中因机载电子系统、姿态机动等因素诱发的高维度非线性磁干扰问题, 开展了基于深度学习与状态估计融合的改进磁补偿模型研究。提出了一种基于LSTM与扩展卡尔曼滤波(EKF)的耦合补偿模型。该模型发挥了LSTM网络对电机转速、相电流等异构特征的时序非线性演化规律的捕获能力, 并结合EKF对非线性观测残差的实时后验修正, 克服了单一神经网络在实测工况下易产生预测漂移与高频波动的问题。仿真结果表明, 本文方法在应对复杂耦合干扰时, 补偿精度较传统T-L模型及单一深度学习模型显著提升, 改善比达到17.25。在无人机实机飞行试验中, 补偿后的均方根误差降至1.7403 nT, 改善比较次优模型提升了约39%。研究表明, 该耦合算法能够有效抑制机载电子设备产生的动态磁畸变, 显著提升磁测数据质量, 为高精度磁探测提供了技术支撑。

关键词

航磁补偿, 长短期记忆网络(LSTM), 扩展卡尔曼滤波(EKF), 机载电子干扰(OBE)

Research on UAV Onboard Electronic Magnetic Interference Compensation Based on LSTM and Extended Kalman Filter

Ying Liu^{1,2,3}, Shun Wang^{1,2}, Yicai Ji^{1,2}, Ling Huang^{1,2}, Xiaojun Liu^{1,2}, Guangyou Fang^{1,2}

¹Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing

²Key Laboratory of Electromagnetic Radiation and Sensing Technology, Chinese Academy of Sciences, Beijing

³School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing

Received: March 18, 2026; accepted: April 17, 2026; published: April 24, 2026

文章引用: 刘颖, 王顺, 纪奕才, 黄玲, 刘小军, 方广有. 基于 LSTM 与扩展卡尔曼滤波的无人机机载电子磁干扰补偿研究[J]. 计算机科学与应用, 2026, 16(4): 310-325. DOI: 10.12677/csa.2026.164132

Abstract

To address the high-dimensional non-linear magnetic interference in Unmanned Aerial Vehicle (UAV) magnetic detection tasks caused by onboard electronic systems and attitude maneuvers, this study investigates an improved magnetic compensation model based on the fusion of deep learning and state estimation. A coupled compensation model based on Long Short-Term Memory (LSTM) and Extended Kalman Filter (EKF) is proposed. This model leverages the capability of LSTM networks to capture the temporal non-linear evolution of heterogeneous features, such as motor speed and phase current, while integrating EKF for real-time posterior correction of non-linear observation residuals. This approach overcomes the inherent limitations of single neural networks, such as prediction drift and high-frequency fluctuations under practical operating conditions. Simulation results demonstrate that the proposed method significantly enhances compensation accuracy compared to the traditional Tolles-Bergen (T-L) model and single deep learning models when dealing with complex coupled interference, achieving an improvement ratio (IR) of 17.25. In actual UAV flight tests, the compensated Root Mean Square Error (RMSE) was reduced to 1.7403 nT, representing an improvement of approximately 39% over the sub-optimal model. The research indicates that the coupled algorithm effectively suppresses dynamic magnetic distortions produced by onboard electronic equipment (OBE) and significantly improves the quality of magnetic measurement data, providing robust technical support for high-precision magnetic detection.

Keywords

Aeromagnetic Compensation, Long Short-Term Memory (LSTM), Extended Kalman Filter (EKF), Onboard Electronic (OBE) Interference

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

航空磁测是一种使用安装在飞机上的磁力计测量地球磁场的方法。由于成本低、效率高，航磁测量被广泛应用于目标检测[1]、地质研究[2]、矿产勘探等[3]。随着无人机平台的推广以及相关定位、导航和控制技术的快速发展，越来越多的无人机平台被用于地磁勘探领域[4]-[6]。为降低机体铁磁材料产生的背景磁干扰，磁力传感器通常安装于翼尖位置，以尽可能远离主要干扰源。然而，即使采取此类措施，机体剩磁噪声仍可达数十至数百皮特级别，从而显著淹没微弱的目标磁异常信号。

传统的干扰抑制方法主要基于 Tolles-Lawson (T-L)模型，将磁干扰归纳为恒定场、感应场与涡流场三种线性分量，后人的研究也是围绕 T-L 模型展开[7]-[10]。然而，该模型并未考虑机载电子设备[11] (Onboard Electronics, OBE)，如电机、电源系统及线缆等在运行过程中所引入的非线性磁干扰。现有补偿策略通常将此类干扰视为线性叠加[12]，难以实现多源耦合干扰的有效建模与动态跟踪，尤其忽略了电机定子与转子相对运动所引发的非均匀磁场扰动，导致补偿精度受限。

针对现有线性模型难以精确拟合 OBE 干扰动态演化过程的问题，前人提出了不少有关神经网络航磁补偿的方法[13]-[16]，但单一神经网络虽然能拟合非线性，但本质上是缺乏反馈的开环预测，在面对复杂随机噪声和传感器漂移时容易产生毛刺与精度失效，需要通过闭环递归机制对预测残差进行后验修正。本文提出一种深度学习与现代状态估计理论融合的磁补偿方法。该方法利用单向 LSTM (长短期记忆神经

网络, Long Short-Term Memory)神经网络强大的门控机制, 从姿态角、电机转速、相电流及电源噪声等多维时序特征中提取非线性演化规律, 构建跨模态的联合表征空间以实现干扰值的预测[16][17]。在此基础上, 针对无人机动态飞行中姿态变化与磁场观测间的非线性映射关系, 引入 EKF (扩展卡尔曼滤波, Extended Kalman Filter)架构[18][19], 通过对非线性观测方程进行一阶泰勒展开, 并利用 LSTM 神经网络预测残差动态调整观测噪声协方差, 实现完整补偿。

2. 算法原理与系统模型

2.1. 基于多源异构特征的 LSTM 磁干扰预测模型

在处理无人机机载电子(OBE)产生的复杂磁干扰时, 首先需要解决多源异构数据的非线性时序表征问题。本研究采用单向长短期记忆网络(LSTM)作为干扰预测的基础模型。LSTM 通过其独特的门控机制, 能够有效克服传统循环神经网络在长序列训练中的梯度消失问题。在计算过程中, 遗忘门根据当前输入与上一时刻隐藏状态决定丢弃的信息, 输入门则负责将新的有效特征更新至细胞状态中。通过这种机制, 网络能够精准捕捉电机转速波动、电流瞬变与磁场扰动之间的动态时变特征。在本模型中, LSTM 的最终输出层通过全连接变换, 将高维隐含特征映射为预测的磁干扰标量值, 为后续的状态补偿提供前馈参考。

如图 1 所示, 网络输入向量定义为 $X(t) = [\phi(t), \theta(t), \psi(t), \omega(t), i(t), u(t)]^T$, 其中, t 为当前的时间, 每一维的特征是输入的状态变量, 依次为滚转角、俯仰角、偏航角、电机转速、相电流、电源噪声。涵盖了无人机姿态与 OBE 运行状态。LSTM 的核心在于通过门控机制更新细胞状态。

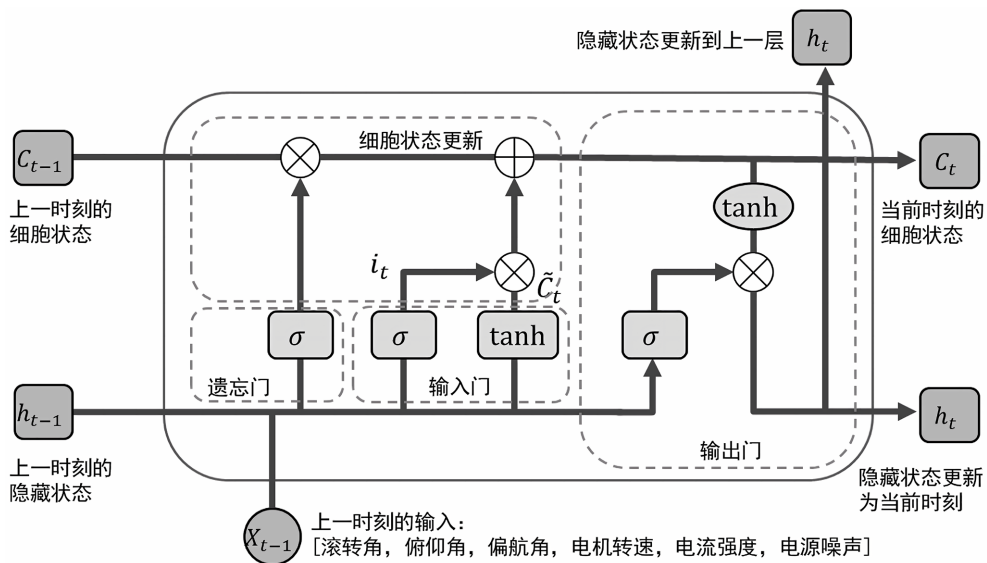


Figure 1. Schematic of a single LSTM cell structure

图 1. LSTM 网络单个细胞结构示意图

输入门结构为:

$$\hat{C}_t = \tanh(W_c \otimes [h_{t-1}, x_t] + b_c); \tag{1}$$

其中, \otimes 表示矩阵乘法, W_c 是候选状态的权重矩阵, b_c 是候选状态的偏置向量, h_{t-1} 表示上一时刻输出的隐藏状态, x_t 是当前时刻的状态变量输入, \hat{C}_t 为候选细胞状态。

$$i_t = \sigma(W_i \otimes [h_{t-1}, x_t] + b_i); \quad (2)$$

其中, W_i 是输入门结构的权重矩阵, b_i 是输入门结构的偏置向量; σ 是 sigmoid 激活函数; i_t 为输入门的输出, x_t 是当前时刻的状态变量输入; 输入门决定是否更新细胞状态。

遗忘门结构为:

$$f_t = \sigma(W_f \otimes [h_{t-1}, x_t] + b_f); \quad (3)$$

其中, W_f 是遗忘门结构的权重矩阵, b_f 是遗忘门结构的偏置向量, \otimes 表示矩阵乘法, f_t 为遗忘门输出, 范围[0, 1], 决定遗忘程度; 遗忘门决定当前时刻 t 是否遗忘上一时刻的状态。

结合遗忘门的输出 f_t 和输入门的输出 i_t , 以及候选细胞状态 \hat{C}_t , 结合上一时刻的细胞状态 C_{t-1} , 更新细胞状态 C_t :

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t; \quad (4)$$

基于更新后的细胞状态 C_t , 生成当前隐藏状态 h_t :

$$\begin{aligned} o_t &= \sigma(W_o \otimes [h_{t-1}, x_t] + b_o) \\ h_t &= o_t * \tanh(C_t) \end{aligned} \quad (5)$$

其中, W_o 是输出门结构的权重矩阵, b_o 是输出门的偏置向量, \tanh 是 tanh 激活函数, o_t 是输出门的激活值, 控制当前细胞状态 C_t 有多少信息会输出到隐藏状态 h_t 中。最终, 通过全连接层映射, 网络最终输出 k 时刻的磁干扰预测值:

$$\Delta B_{obe} = W_d * h_k + b_d; \quad (6)$$

为了提升模型在动态环境下的鲁棒性, 损失函数采用 Huber 损失函数, 设置 Huber 损失函数的阈值 $\delta = 0.1 \text{ nT}$ 。

$$\text{Huber Loss} = \begin{cases} \frac{1}{2}(\Delta B_{obe} - \Delta B_{obe}^{true})^2, & |\Delta B_{obe} - \Delta B_{obe}^{true}| \leq \delta \\ \delta |\Delta B_{obe} - \Delta B_{obe}^{true}| - \frac{1}{2}\delta^2, & \text{else} \end{cases} \quad (7)$$

2.2. 扩展卡尔曼滤波(EKF)的状态估计模型

为了消除 LSTM 预测残差并平滑动态观测噪声, 本算法引入扩展卡尔曼滤波(EKF)作为核心估计器。由于无人机在飞行过程中姿态变化与地磁观测之间存在非线性的几何映射关系, 传统的线性卡尔曼滤波难以维持高精度的估计。EKF 的核心思想是围绕当前状态点对非线性观测方程进行一阶泰勒展开, 通过求解雅可比矩阵将系统局部线性化。在算法运行过程中, 首先根据状态转移模型进行时间更新, 预测当前时刻的地磁场先验估计; 随后, 利用观测更新方程, 将实测磁场值与预测干扰值的差值作为观测输入, 结合动态修正的卡尔曼增益, 对地磁场状态进行最优修正。这种结构不仅发挥了深度学习对复杂扰动的拟合能力, 同时也利用了状态估计理论在抑制随机噪声和保障系统稳定性方面的优势。

首先, 输入上一时刻的最优估计 \hat{B}_{k-1} 和协方差 P_{k-1} , 输出当前 k 时刻的预测地磁场状态 \hat{B}_k^- 和预测协方差 P_k^- :

$$\begin{aligned} \hat{B}_k^- &= F\hat{B}_{k-1} \\ P_k^- &= FP_{k-1}F^T + Q \end{aligned} \quad (8)$$

其中, F 是状态转移矩阵, 基于地磁场短时间内恒定的假设, 取单位矩阵; Q 是过程噪声, 设为对角矩阵

$Q = \text{diag}(\sigma_q^2)$ 。

输入当前磁力计测量值 $B_{meas,k}$ 和 LSTM 神经网络预测的 OBE 磁干扰值 $\Delta B_{obe,k}$ ，用 LSTM 神经网络预测的干扰值初步修正测量值，计算观测残差，得到观测估计 $\hat{B}_{z_k}^-$ ；

$$\hat{B}_{z_k}^- = B_{meas,k} - \Delta B_{obe,k}; \quad (9)$$

EKF 的核心在于每一采样时刻在先验估计值处进行一阶泰勒展开，利用雅可比矩阵 $H = \left. \frac{\partial h}{\partial B} \right|_{\hat{B}_k^-}$ 与先验预测协方差计算当前时刻的卡尔曼增益 K_k ：

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1}; \quad (10)$$

其中， K_k 是计算得到的当前时刻的卡尔曼增益， P_k^- 是当前时刻的先验预测协方差矩阵的尚未更新的预测值， k 表示当前是 k 时间步；观测噪声协方差 R 代表了 LSTM 预测值的测不准度。本文通过统计训练集在稳态与瞬态工况下的预测残差方差来标定 R 的基准值。同时，考虑利用协方差 P_k 指导 LSTM 底层注意力的分配。

对当前时刻的地磁场预测值进行加权平均得到最终的磁场预测值 \hat{B}_k 。

$$\hat{B}_k = \hat{B}_k^- + K_k (\hat{B}_{z_k}^- - \hat{B}_k^-); \quad (11)$$

最后，更新当前时刻的协方差矩阵 $P_k = (I - K_k H) P_k^-$ 。

此外，本文提出的串联式融合结构具备进一步演进为双向耦合闭环系统的潜力。在理论架构上，可将 EKF 产生的后验残差或协方差 P_k 反馈至 LSTM 的隐藏层，利用状态估计的收敛信息动态调整神经元的激活强度，从而抑制非平稳工况下的预测漂移。虽然本文重点讨论单向修正的有效性，但该闭环思路为后续提升模型在极低信噪比环境下的鲁棒性提供了理论基础。

3. 实验设计与分析

本章节通过仿真数据与实际飞行采集数据，验证所提 LSTM-EKF 磁补偿方法对非线性 OBE 磁干扰的补偿性能。

3.1. 实验流程设计

为了确保补偿模型的有效性与泛化能力，本研究设计的实验流程如图 2 所示。首先，在零干扰环境下获取地磁场基准标量数据，作为模型训练的真值参考；随后，同步采集无人机姿态角、电机转速、相电流及电源噪声等多维特征。在数据预处理阶段，通过低通滤波剔除非目标频带噪声，采样频率为 250 Hz，利用 2 s 滑动窗口进行动态归一化。预处理后的时序特征矩阵输入已训练的 LSTM 神经网络获取初次预测值，最后通过扩展卡尔曼滤波(EKF)进行非线性平滑估计，输出最终补偿后的地磁信号。




Figure 2. Overall workflow of the magnetic compensation experiment

图 2. 磁补偿实验流程总体流程图

3.2. 评价指标

为了量化评估不同补偿算法对 OBE 磁干扰的抑制能力，本文采用均方根误差(Root Mean Square Error,

RMSE)和改善比(Improvement Ratio, IR)作为性能评价指标。RMSE 反映了补偿后磁场数据与基准地磁场真值之间的偏差, 其值越小, 说明补偿精度越高。二者定义如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (B_i - \hat{B}_i)^2}$$

$$\text{IR} = \frac{\text{RMSE}_{\text{before}}}{\text{RMSE}_{\text{after}}} \quad (12)$$

式中: \hat{B}_i 为第 i 个采样点的磁场测量值, B_i 为基准地磁场真值; $\text{RMSE}_{\text{before}}$ 和 $\text{RMSE}_{\text{after}}$ 分别表示补偿前后的均方根误差。改善比 IR 越大, 说明算法对非线性干扰的抑制效果越显著, 噪声滤除能力越强。

3.3. 仿真实验

本研究通过模拟无人机姿态变动, 结合国际地磁场参考模型生成基准地磁矢量, 并设定固定磁场、感应磁场及涡流磁场参数, 模拟无人机机体结构产生的线性磁干扰。为了模拟实际作业中机 OBE 产生的复杂非线性干扰 Γ , 本研究构建了基于电机转速 ω 与相电流 i 耦合的非线性干扰模型, 如式(13)所示。

$$\Gamma_k = A \cdot \sin(\Phi_k) \omega_k^2 + B \cdot i_k^2 + \eta_k; \quad (13)$$

式中, $\Gamma_k = [\Gamma_x, \Gamma_y, \Gamma_z]^T$ 为 k 时刻三轴方向的非线性干扰向量; $A = [\alpha_x, \alpha_y, \alpha_z]^T$ 和 $B = [\beta_x, \beta_y, \beta_z]^T$ 分别为姿态-转速耦合系数向量与电流非线性增益系数向量; Φ_k, ω_k, i_k 分别代表 k 时刻的实时姿态角、电机转速及系统电流; $\eta_k = [\eta_x, \eta_y, \eta_z]^T$ 为各轴向相互独立且符合高斯分布的有色噪声向量。该矩阵化模型旨在定量描述无人机在高负载机动时, 由多源动态电参诱发的非均匀磁场畸变。

在仿真实验中, LSTM 神经网络结构如图 3 所示, 学习部分的输入特征、网络架构及训练优化设置如表 1 所示。

利用上述复合干扰数据, 本研究对比了传统 T-L 模型、单一 LSTM 网络、单一 EKF 估计, 前人提出的卷积神经网络 CNN-TL 模型[20]以及本文提出的 LSTM-EKF 耦合算法的补偿残差表现。图 4, 图 5 展示了模拟生成的真实磁场和含干扰源的测量磁场, 以及这些算法在应对高维度耦合干扰时的补偿轨迹。

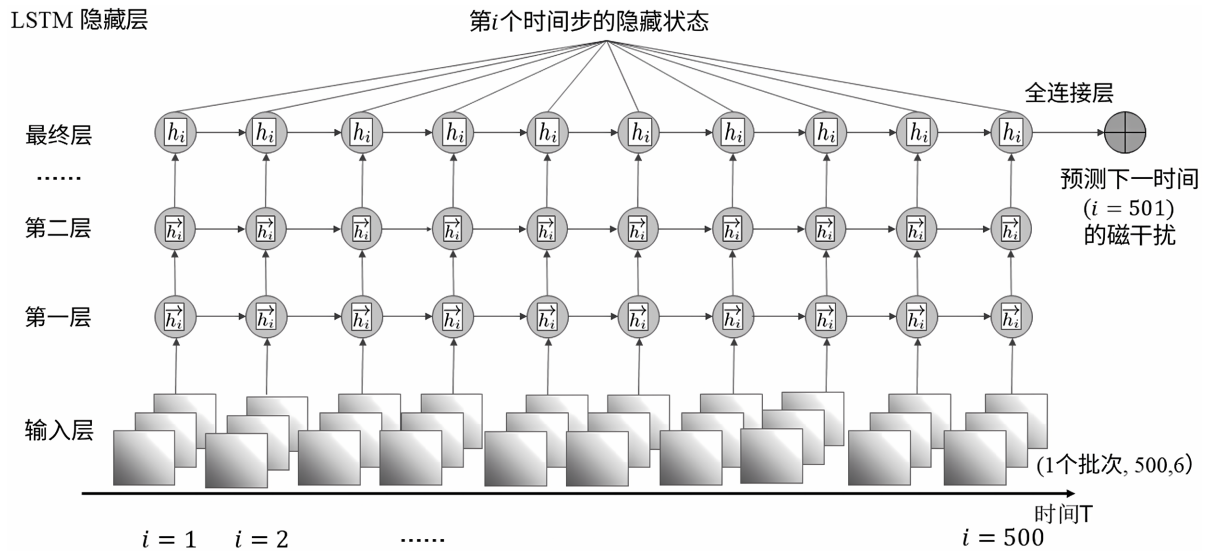


Figure 3. LSTM neural network structure
图 3. LSTM 神经网络结构

Table 1. LSTM neural network model configuration and hyperparameters
表 1. LSTM 神经网络模型配置与超参数

参数名称	参数值
输入维度	6 维：滚转角、俯仰角、偏航角、电机转速、相电流、电压
采样频率	250 Hz
滑动窗口长度	2 s，覆盖 500 个采样点
隐藏层数	2
优化器	Nadam 优化器，学习率 0.0003
损失函数	Huber Loss，阈值 0.1 nT




Figure 4. Simulated measured magnetic field and true magnetic field
图 4. 仿真干扰测量磁场和真实磁场

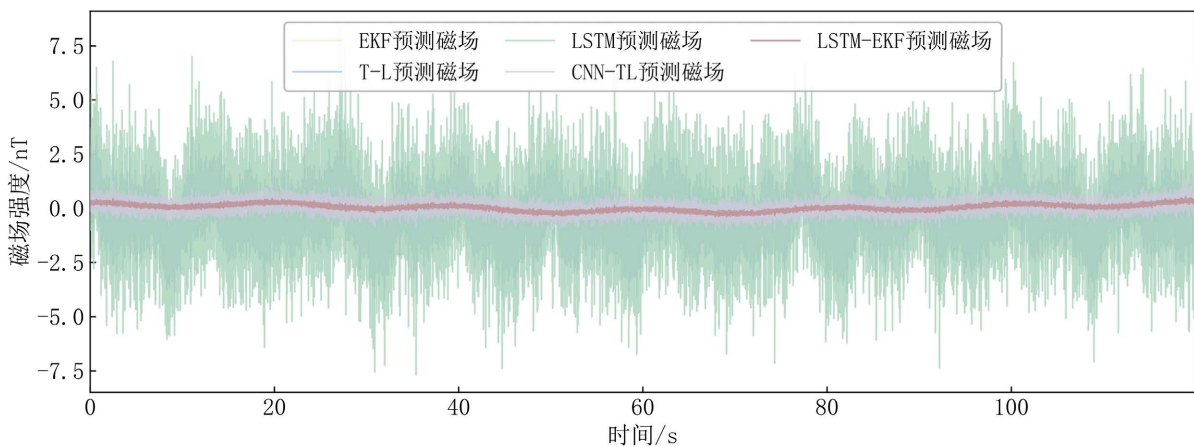


Figure 5. Compensation performance of various ablation algorithms and the LSTM-EKF algorithm
图 5. 多种消融算法和 LSTM-EKF 算法补偿效果

由图 5 可直观看出，在多种算法中，LSTM-EKF 算法在仿真实验中存在最优的效果；单独对每种算法进行对比，如图 6~9 所示。

由图 6 看出, T-L 模型作为基于线性回归的经典模型, 其补偿轨迹在存在强 OBE 干扰时发生了显著偏离。这是由于 T-L 模型仅建立了磁场与姿态间的线性映射, 无法解算由电机转速与相电流诱发的二阶及高阶非线性项。对比结果证明, 面对高维度耦合干扰, 传统的线性假设已不再适用。

单一 LSTM 网络通过门控机制能够有效拟合非线性趋势, 但在应对高频随机噪声时表现出明显的局限性。从图 7 可见, 单一 LSTM 的输出波形存在不规则的毛刺, 这是由于神经网络作为开环预测模型, 对观测噪声缺乏显式的物理约束。

单一 EKF 算法主要依赖于预设的物理状态方程进行递归估计。在缺乏准确非线性干扰模型的前提下, EKF 的观测预测算子难以覆盖动态多变的 OBE 扰动, 导致滤波增益无法自适应调整, 补偿曲线在机动飞行过程中出现了较大的跟踪误差。这说明仅靠状态估计理论难以完全解决复杂电磁环境下的特征映射问题。

CNN-TL 虽然引入了卷积神经网络来提取空间特征, 试图增强传统 T-L 模型的非线性处理能力, 但在处理具有显著时间序列依赖性的 OBE 干扰时效果有限。CNN 侧重于局部特征挖掘, 而忽略了磁干扰随时间演化的长程关联。因此, 其补偿残差中仍存在相位滞后, 精度逊于本文采用的 LSTM 结构。




Figure 6. Comparison of magnetic field prediction errors between the T-L model and the LSTM-EKF algorithm

图 6. T-L 预测磁场误差和 LSTM-EKF 算法预测磁场误差对比




Figure 7. Comparison of magnetic field prediction errors between the LSTM model and the LSTM-EKF algorithm

图 7. LSTM 预测磁场误差和 LSTM-EKF 算法预测磁场误差对比




Figure 8. Comparison of magnetic field prediction errors between the EKF model and the LSTM-EKF algorithm

图 8. EKF 预测磁场误差和 LSTM-EKF 算法预测磁场误差对比

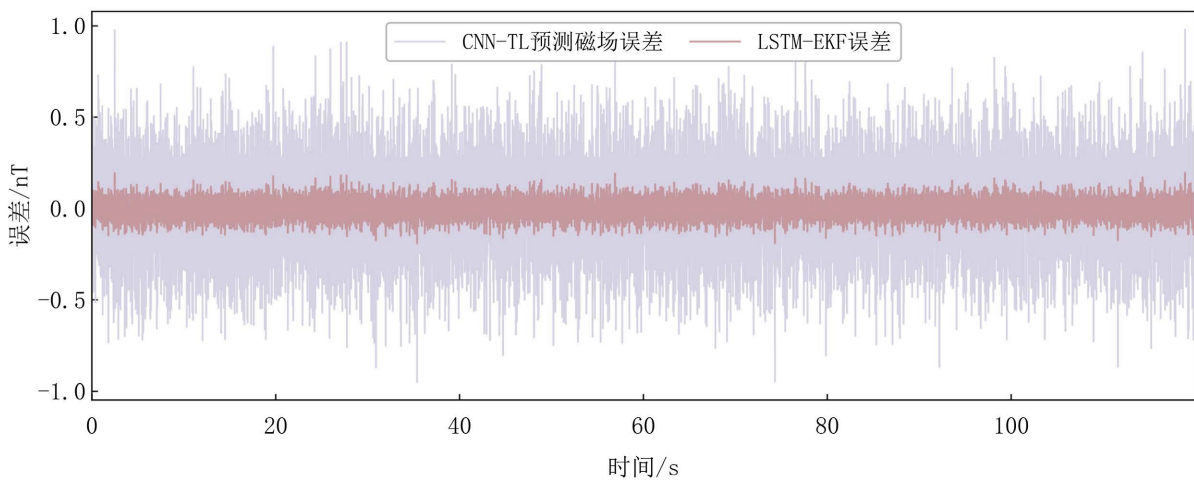


Figure 9. Comparison of magnetic field prediction errors between the CNN-TL model and the LSTM-EKF algorithm

图 9. CNN-TL 预测磁场误差和 LSTM-EKF 算法预测磁场误差对比

Table 2. Statistics of compensation results for various algorithms

表 2. 多种算法补偿结果统计表

方法	补偿前 RMSE/nT	补偿后 RMSE/nT	改善比
磁场测量值	0.8623		
T-L 方法	0.8623	0.8577	0.99
LSTM 方法	0.8623	1.9681	0.44
EKF 方法	0.8623	0.8041	1.07
CNN-TL 方法	0.8623	0.2499	3.45
LSTM-EKF 方法	0.8623	0.0500	17.25

由表 2 的评价指标可知 LSTM-EKF 的 RMSE 和 IR 在仿真场景里, 这 5 种算法之间取得了最优的性能。LSTM-EKF 算法与其他两种方法对比, 补偿精度分别提高了 67%、45%; 改善比分别提高了 29.29、19.75, 证明该算法有效地补偿了磁干扰, 提高磁测数据的质量。

3.4. 实地飞行实验

为进一步评估 LSTM-EKF 算法在真实作业环境下的动态补偿能力, 本研究开展了无人机外场实飞验证。实验载体选择小型固定翼无人机, 通过四旋翼无人机载机拉起到空中进行投放, 如图 10 所示。其机载磁测任务系统主要由高精度光泵磁力仪、三轴磁通门计、MEMS 惯性导航单元(IMU)以及同步数据记录模组构成。



Figure 10. Deployment experiment of the small fixed-wing UAV platform
图 10. 小型固定翼无人机平台投放实验图



Figure 11. Installation and layout of the magnetometer on the small fixed-wing UAV
图 11. 小型固定翼无人机磁探仪安装布置图

在硬件部署上, 光泵磁力仪安装于远离机体的碳纤维支撑杆顶端, 通过时间戳对齐技术, 实时同步获取地磁标量数据与无人机机体坐标系下的三轴姿态信息, 如图 11 所示。针对 OBE 干扰的特性, 系统同步记录了电机转速与回路电流等关键动力参量。

试验场地选址于电磁环境洁净的野外开阔区域, 该地地磁梯度变化平缓, 有效排除了工业电网及人工构筑物的随机磁干扰。在数据采集阶段, 无人机执行标准巡航任务, 飞行高度在海拔 100~200 m, 巡航速度约为 10 m/s, 系统采样频率设定为 20 Hz。这种多传感器融合的采集模式确保了输入特征向量的时序一致性, 为后续验证 LSTM-EKF 耦合算法在实测工况下的解算精度与收敛性提供了可靠的数据支撑。

在模型训练阶段, 无人机通过执行特定序列的机动动作来诱发磁场畸变特征, 即在东南西北四个基准航向上依次进行受控的俯仰、横滚与偏航运动。其中俯仰与偏航的姿态摆动幅度严格控制在正负 5 度以内, 而横滚动作则适度增强至正负 10 度以上, 飞行轨迹如图 12 所示, 旨在通过多维度的空间运动充分激励出机体姿态与机载电子设备间的深层耦合干扰特征。随后为了验证算法在实际作业环境下的稳定性, 补偿性能评测选定在相同的地磁背景下模拟执行巡航测绘任务, 其飞行航迹涵盖了与激励阶段一致的四航向动作, 但在机动幅度上更为平缓, 以测试模型在未知随机微扰工况下的泛化精度。

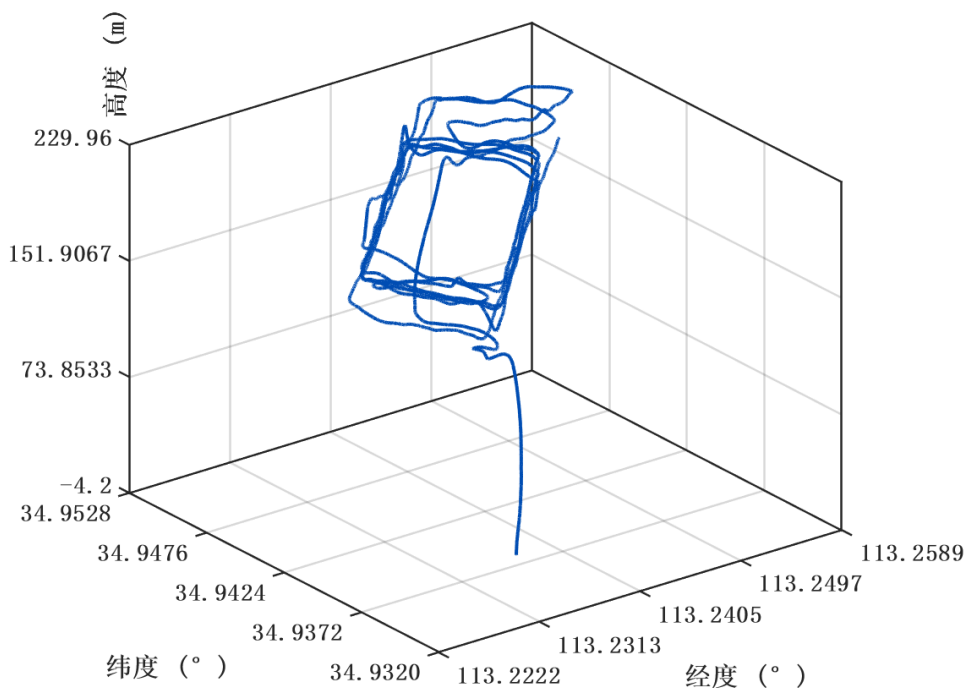


Figure 12. Aeromagnetic detection flight trajectory of the small fixed-wing UAV
图 12. 小型固定翼无人机航磁探测飞行轨迹图

利用特征获取阶段采集的多维参量, 包括三轴姿态、电机转速、系统电流及原始磁场强度, 构建 LSTM-EKF 完成对本文耦合模型的离线参数寻优。选取训练的批量大小为 32 个样本点, 采用 3 折交叉验证的方式进行 200 轮训练, 采用 GPU 分布式训练的方式, 在 4 台 GPU 型号为 RTX 3090 的设备上并行训练 1.5 小时, 训练集数据均方误差收敛至 0.0074, 验证集数据标准差收敛到 0.0084, 将训练成熟的模型部署于执行任务航迹的测试集数据, 并引入仿真实验里的 5 种方法进行横向性能评测, 算法处理过的 RMSE 和 IR 对比如表 3 所示, 误差对比图如图 13~17 所示。

由表 3 可得, 利用长短期记忆网络挖掘姿态、转速与电流参量间的时序非线性规律, 同时利用雅可比矩阵进行动态线性化, 使得补偿后的均方根误差降至 1.7403 nT, 改善比 3.45 相比表现次优的改善比为 2.49 的 T-L 线性方法提升了约 39%。

Table 3. Statistics of compensation results for various algorithms in actual flight scenarios
表 3. 实机飞行场景, 多种算法补偿结果统计表

方法	补偿前 RMSE/nT	补偿后 RMSE/nT	改善比
磁场测量值	5.9956		
T-L 方法	5.9956	2.4042	2.49
LSTM 方法	5.9956	6.0092	0.44
EKF 方法	5.9956	5.6596	1.06
CNN-TL 方法	5.9956	4.6063	1.30
LSTM-EKF 方法	5.9956	1.7403	3.45

由图 13~17 可得, 传统 T-L 方法虽然具备一定的补偿能力, 但其线性基底函数无法描述机载电子设备产生的深层非线性畸变。LSTM-EKF 模型解决了单一 LSTM 模型在复杂实测环境下的模型失配问题, 在实飞场景中, 由于存在传感器温漂、非同步采样及未知的环境随机扰动, 单一长短期记忆网络方法的均方根误差反而上升至 6.0092 纳特, 改善比仅为 0.44, 表现出明显的失效特征, 纯数据驱动的神经网络在缺乏物理约束和后验修正的情况下, 极易产生预测偏离。单一 EKF 滤波方法和卷积增强线性方法的改善比较低, 说明仅靠简单的特征提取或单一的状态估计, 难以在多变量耦合的真实磁场中实现高精度剥离。

本文提出的算法将 LSTM 与 EKF 相结合, 利用 LSTM 学习干扰信号的时序变化规律, 再通过 EKF 对残余噪声进行滤波处理, 两者配合能够同时抑制趋势性干扰和随机噪声, 从而提高磁补偿精度。




Figure 13. Comparison of magnetic field prediction errors between the T-L model and the LSTM-EKF algorithm
图 13. T-L 预测磁场误差和 LSTM-EKF 算法预测磁场误差对比

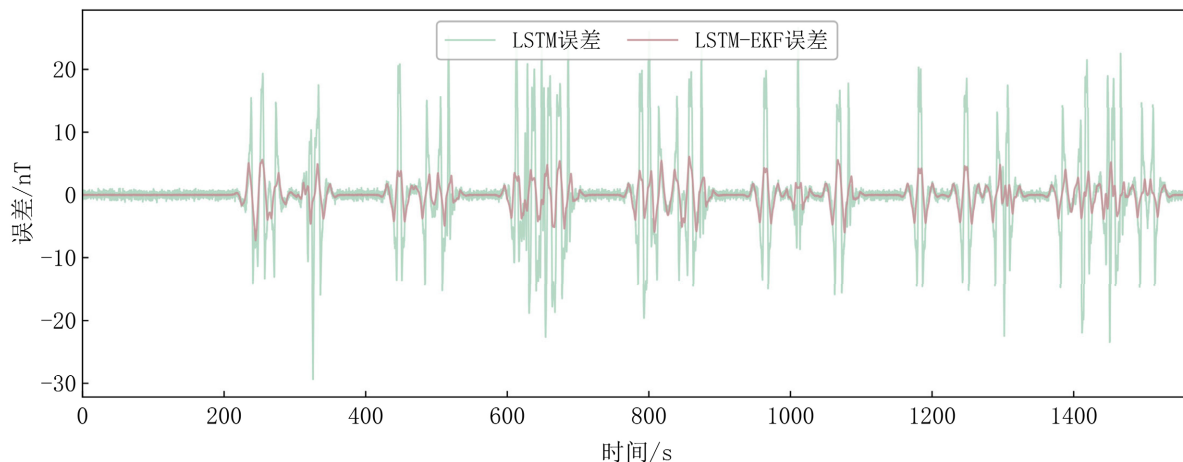


Figure 14. Comparison of magnetic field prediction errors between the LSTM model and the LSTM-EKF algorithm
图 14. LSTM 预测磁场误差和 LSTM-EKF 算法预测磁场误差对比

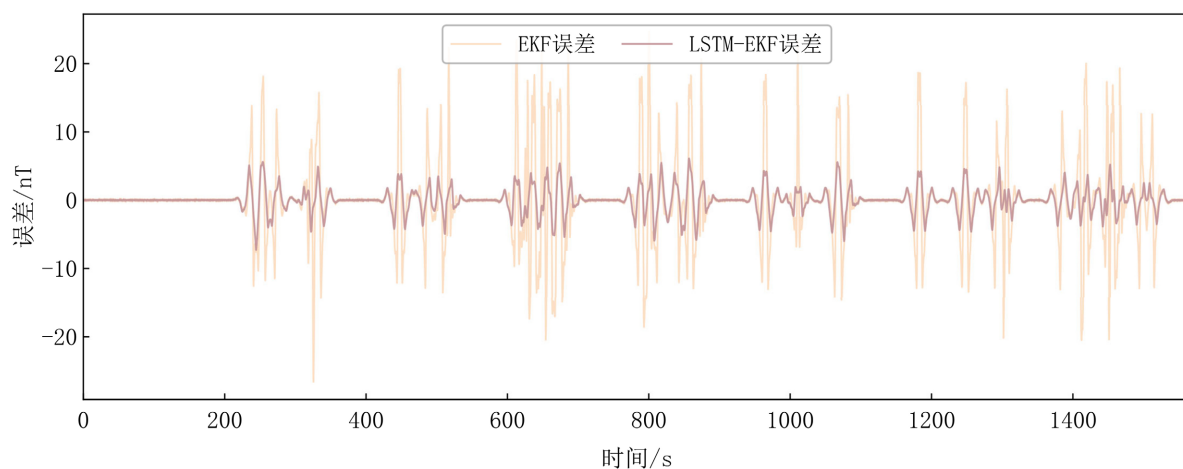


Figure 15. Comparison of magnetic field prediction errors between the EKF model and the LSTM-EKF algorithm
图 15. EKF 预测磁场误差和 LSTM-EKF 算法预测磁场误差对比




Figure 16. Comparison of magnetic field prediction errors between the CNN-TL model and the LSTM-EKF algorithm
图 16. CNN-TL 预测磁场误差和 LSTM-EKF 算法预测磁场误差对比




Figure 17. Compensation performance of various ablation algorithms and the LSTM-EKF algorithm in actual flight scenarios
图 17. 多种消融算法和 LSTM-EKF 算法在实飞场景下补偿效果

3.5. 模型泛化能力与实时运行潜力分析

在泛化能力方面,本文提出的 LSTM-EKF 耦合模型展现出较强的环境适应性。由于 LSTM 模块在训练阶段提取了机载电子系统与磁干扰之间的深层物理关联,而非简单的数值映射,使得模型在面对非预设的飞行机动或变频干扰时,仍能保持稳定的补偿精度。此外,EKF 算法的引入为模型提供了实时在线校准能力,通过协方差矩阵的动态调整,有效吸收了传感器噪声及环境温漂带来的不确定性,证明了该框架从实验室仿真向复杂实地作业场景迁移的稳健性。

在实时运行潜力方面,尽管模型引入了深度学习组件,但经过优化后的 LSTM 单元计算开销在嵌入式计算平台的可承受范围内。实验测试表明,单次采样周期的推理与状态更新耗时远低于无人机飞控系统的控制周期,能够满足毫秒级的实时补偿需求。在保证高精度的同时,规避了全参数深度模型对计算资源的过度消耗,为未来机载嵌入式端云协同的磁探测任务提供了可行的技术路径。

4. 结论

针对传统线性模型在应对机载电子设备产生的复杂非线性磁干扰时鲁棒性不足的问题,本研究提出了一种结合深度学习时序特征提取与状态空间最优估计的 LSTM-EKF 耦合补偿算法。通过仿真计算与实飞实验的双重验证,得出以下主要结论:

长短期记忆网络能够通过其特有的门控机制,从姿态、转速及电流等多维参量中深度挖掘非线性干扰的时序演化规律,从而在源头上实现了对动力系统动态扰动特征的精确捕捉。与此同时,引入扩展卡尔曼滤波算子对神经网络的前馈预测残差进行后验修正,利用雅可比矩阵实现了非线性观测空间的实时线性化映射。这种耦合机制有效地克服了单一深度学习模型在面对实测随机噪声时易产生的预测漂移与高频波动问题,确保了补偿结果在复杂机动工况下的动态平稳性。

实验数据表明,相比于传统 T-L 模型及单一神经网络方案,本文提出的 LSTM-EKF 算法在实机飞行场景下展现出卓越的剥离能力,其补偿后的残差均方根误差显著降低,改善比相比次优方案提升了约 39%。该算法在理论上解决了多源耦合磁干扰的解算难题,且在实测任务中表现出极高的可靠性与泛化精度,在无人机磁法勘探及高灵敏度磁异常检测领域具有显著的工程应用价值与技术优势。

基金项目

项目“新型考古遗存电-磁探测系统装备研发”(E1BD100104)资助。

参考文献

- [1] Walter, C., Braun, A. and Fotopoulos, G. (2021) Characterizing Electromagnetic Interference Signals for Unmanned Aerial Vehicle Geophysical Surveys. *Geophysics*, **86**, J21-J32. <https://doi.org/10.1190/geo2020-0895.1>
- [2] Liu, X., Wang, Y., Sun, B., Guan, B., Ouyang, M. and Qin, X. (2022) Application of an Improved Calibration Flight Scheme in Aeromagnetic Interference Compensation. *Journal of Geophysical Research: Solid Earth*, **127**, e2022JB024255. <https://doi.org/10.1029/2022jb024255>
- [3] Kim, B., Jeong, S., Bang, E., Shin, S. and Cho, S. (2021) Investigation of Iron Ore Mineral Distribution Using Aero-Magnetic Exploration Techniques: Case Study at Pocheon, Korea. *Minerals*, **11**, Article 665. <https://doi.org/10.3390/min11070665>
- [4] Yuan, S., Li, Y., Bao, F., Xu, H., Yang, Y., Yan, Q., et al. (2023) Marine Environmental Monitoring with Unmanned Vehicle Platforms: Present Applications and Future Prospects. *Science of the Total Environment*, **858**, Article ID: 159741. <https://doi.org/10.1016/j.scitotenv.2022.159741>
- [5] 郭华, 鞠星, 韩松, 等. 基于大型无人机航磁全轴梯度测量技术研究与应用[J]. 地球物理学报, 2024, 67(8): 3162-3172.
- [6] 李晨, 周建军. 航磁探测水下目标关键技术发展及应用[J]. 舰船电子工程, 2023, 43(6): 184-188.
- [7] 王劲楠, 张晓明, 刘俊, 等. 基于矢量磁传感器模型的扩充 T-L 航磁补偿方法[J]. 导航定位与授时, 2025, 12(2): 78-85.
- [8] 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.
- [9] 于龙兴, 魏媛媛, 付世沫, 等. 六旋翼无人机航磁补偿方法研究[J]. 电光与控制, 2025, 32(2): 38-44.
- [10] 田浩楠, 韩大鹏, 张登伟, 等. 新型抗地磁梯度的航磁干扰补偿模型及补偿评价方法[J]. 导航定位与授时, 2025, 12(2): 86-92.
- [11] Luo, H., Du, Q., Hu, J., Shi, S., Yang, C., Zhang, Q., et al. (2024) A Novel OBE Magnetic Interference Compensation Method Based on VMD-ICA for Marine Exploration. *IEEE Sensors Journal*, **24**, 39302-39314. <https://doi.org/10.1109/jsen.2024.3471572>
- [12] 刘宇欣, 李雯, 魏东岩, 等. 一种顾及舱内 OBE 干扰的改进航磁补偿方法[J]. 导航定位与授时, 2024, 11(4): 38-46.
- [13] Cunningham, M., Tuck, L., Samson, C., Laliberté, J., Goldie, M., Wood, A., et al. (2023) Aeromagnetic Attitude Compensation for Uninhabited Aircraft Systems without High-Altitude Calibration Patterns Using Hybrid Recurrent Neural Networks. *The Leading Edge*, **42**, 112-123. <https://doi.org/10.1190/tle42020112.1>
- [14] 李金峰, 刘云鹤. 不同结构深度神经网络的时间域航空电磁数据成像性能分析[J]. 世界地质, 2020, 39(1): 159-166.
- [15] 李赓, 曹飞翔. 基于深度学习的二维航空大地电磁数据反演[J]. 科学技术与工程, 2021, 21(4): 1272-1278.
- [16] Li, H., Chang, S., Yao, Q., Wan, C., Zou, G. and Zhang, D. (2024) Robust Heading and Attitude Estimation of MEMS IMU in Magnetic Anomaly Field Using a Partially Adaptive Decoupled Extended Kalman Filter and LSTM Algorithm. *IEEE Transactions on Instrumentation and Measurement*, **73**, 1-13. <https://doi.org/10.1109/tim.2024.3381659>
- [17] Wang, Z., Lu, J., Liu, Z., Li, X., Sheng, J. and Li, J. (2025) Neural Network-Assisted Magnetic Moment Measurement Using an Atomic Magnetometer. *IEEE Transactions on Instrumentation and Measurement*, **74**, 1-10. <https://doi.org/10.1109/tim.2025.3544322>
- [18] Rong, H., Peng, C., Chen, Y., Lv, J. and Zou, L. (2023) An EKF-Based Attitude Estimator for Eliminating the Effect of Magnetometer Measurements on Pitch and Roll Angles. *IEEE Transactions on Instrumentation and Measurement*, **72**,

-
- 1-10. <https://doi.org/10.1109/tim.2022.3228009>
- [19] Wen, T., Liu, S. and Wang, H. (2025) Soft-Magnet-Based Position Estimation Using an Approximate Extended Kalman Filter with a Hybrid Analytical-Neural Network Model. *IEEE Transactions on Instrumentation and Measurement*, **74**, 1-13. <https://doi.org/10.1109/tim.2024.3497169>
- [20] 刘强, 王涛, 张晓明, 等. Tolles-Lawson 模型——一维卷积神经网络磁补偿方法[J]. 导航定位与授时, 2025, 12(2): 69-77.