

基于运动状态识别的车辆磁干扰补偿方法研究^{*}潘凯霖^{1,2} 张晓明^{1,2} 张 鹤^{1,2} 范义伟^{1,2} 李博宇^{1,2}

(1. 中北大学仪器与电子学院 太原 030051; 2. 极限环境光电动态测试技术与仪器全国重点实验室 太原 030051)

摘要: 车辆地磁导航在动态行驶中面临磁干扰影响导航精度的关键问题,传统固定参数补偿方法难以适应不同运动状态下的干扰变化。通过分析运动状态与磁补偿效果的关系,揭示了单一固定参数补偿模型的局限,为发展自适应补偿方法提供了理论基础。研究构建的 CNN-SRU 运动状态识别模型实现了 99.61% 的识别准确率,训练效率较对比模型提升 12.8%~28.4%,推理延迟降低 25.4%~38.5%。基于识别结果系统评估了单一椭球拟合模型的补偿性能,发现不同运动状态下补偿效果差异显著:匀速直线运动的性能最优补偿后标准差为 49.39 nT;转向运动受复杂磁干扰影响补偿后标准差为 533.35 nT;加速运动因瞬态干扰强烈补偿后标准差达 147.98 nT。研究表明运动状态是影响磁补偿效果的关键因素,固定参数模型无法满足全工况需求。本研究建立的“状态识别-补偿评估”框架为开发自适应磁补偿方法提供了理论支持与技术路径。

关键词: 地磁导航;运动状态识别;CNN-SRU;磁干扰补偿

中图分类号: U666;TN96 **文献标识码:** A **国家标准学科分类代码:** 510.8099

Research on vehicle magnetic interference compensation
method based on motion state recognitionPan Kailin^{1,2} Zhang Xiaoming^{1,2} Zhang Ge^{1,2} Fan Yiwei^{1,2} Li Boyu^{1,2}

(1. School of Instrumentation and Electronics, North University of China, Taiyuan 030051, China; 2. National Key Laboratory for Extreme Environment Optoelectronic Dynamic Testing Technology and Instrumentation, Taiyuan 030051, China)

Abstract: Vehicle geomagnetic navigation faces a key issue of magnetic interference affecting navigation accuracy during dynamic driving. Traditional fixed-parameter compensation methods struggle to adapt to interference changes under different motion states. This paper reveals the limitations of a single fixed-parameter compensation model by analyzing the relationship between motion state and magnetic compensation effect, providing a theoretical basis for the development of adaptive compensation methods. The CNN-SRU motion state recognition model constructed in the study achieved a recognition accuracy of 99.61%, with training efficiency improved by 12.8%~28.4% compared to the comparative model, and inference delay reduced by 25.4%~38.5%. Based on the recognition results, the compensation performance of the single ellipsoid fitting model was systematically evaluated, and significant differences in compensation effects under different motion states were found: The standard deviation after compensation was 49.39 nT for uniform linear motion, which exhibited the best performance; the standard deviation after compensation was 533.35 nT for steering motion due to complex interference; and the standard deviation after compensation reached 147.98 nT for acceleration motion due to strong transient interference. The research indicates that motion state is a key factor affecting the magnetic compensation effect, and fixed-parameter models cannot meet the requirements of all operating conditions. The “state recognition-compensation evaluation” framework established in this paper provides theoretical support and technical paths for the development of adaptive magnetic compensation methods.

Keywords: geomagnetic navigation; motion state recognition; CNN-SRU; magnetic interference compensation

0 引言

近年来,无人装备技术发展迅速,对连续、稳定、自主导

航与定位的需求日益增强,相关导航与定位技术也在不断地进行研究^[1-2]。而地磁场作为地球固有的天然矢量场且具有全天候、无源自主等优势,已成为导航与探测领域的重

要研究对象^[3-5]。目前,针对于无人装备导航研究主要集中在卫星组合导航技术上^[6-9],但在卫星信号受限环境下,地磁导航凭借其全天候、自主性强等特点成为一种有效的补充导航方案^[10-13]。

在无人车上可靠地应用地磁导航仍面临许多挑战。准确获取地磁场数据是实现精准导航的前提,但车辆本身的硬磁和软磁材料以及运动过程中产生的涡流效应将引入复杂的磁干扰^[14],这将严重影响磁力计数据的准确性。目前,基于椭球拟合的磁力计校准和补偿方法已得到广泛研究,例如:Li等^[15]在椭球拟合基础上引入张量混合源分离技术来进一步求解旋转矩阵,有效校正非对准误差与软磁干扰;Chang等^[16]提出了一种基于M估计器的迭代鲁棒椭球调整方法,以提高对异常值的抵抗能力;Fu等^[17]则从硬件层面设计了三轴线圈主动补偿方案。然而,这些方法普遍采用静态补偿策略,即标定参数一经确定即固定不变,从而缺乏对车辆实时运动状态及其引发的时变磁干扰的适应能力。当车辆进行复杂的机动时,动态磁干扰特性使固定参数模型的补偿效果在不同的运动状态下不一致,从而限制了地磁导航在其中的适用性。

因此,迫切需要开发一种基于运动状态的自适应补偿方法,以实现动态磁干扰补偿的有效策略。近年来,基于深度学习的车辆运动状态识别方法逐渐受到关注。例如,Xie等^[18]采用CNN-LSTM模型识别车辆行为;Liu等^[19]利用CNN-GRU模型提升了模型的训练效率;然而,这些模型难以平衡在复杂度、推理延迟与计算资源消耗之间关系,难以满足无人车在复杂场景下对高实时性与低功耗的严格要求。

针对上述问题,本文提出一种基于卷积神经网络(convolutional neural network, CNN)与简化循环单元(simple recurrent unit, SRU)相结合的深度学习模型。该模型通过构建CNN-SRU混合神经网络,实现了对静止、加速、匀速直线与转向4种典型运动状态的精准识别。在此基础上通过系统评估单一标定参数的椭球拟合方法在不同运动状态下的补偿效果,揭示运动状态对磁补偿效果的关键影响,为建立基于运动状态识别的动态参数调整机制提供基础,为实现全工况自主稳定的地磁导航探索新的技术路径。

1 分析与方法

1.1 车辆运动状态与磁干扰相干性分析

在车辆实际运行过程中,所产生的磁干扰呈现出明显的动态特性,其强度与运动状态密切相关。从机理上分析,这种干扰主要源于3种效应:由硬磁材料引起的固定偏置、由软磁材料引起的姿态相关转换,以及在运动过程中导电部件切割地磁场线而产生的时变涡流,这3种效应的大小和空间分布受到运动状态的显著影响。

在匀速直线运动中,由于姿态变化较为平缓,硬磁和软

磁效应是主要的干扰源,其表现相对稳定。相比之下,在加速和转弯操作中,车辆姿态的快速变化不仅改变了软磁干扰的分布,还引发了强烈的涡流效应,从而导致复合干扰迅速随时间变化。这给基于静态假设的传统补偿方法的适应性带来了挑战。

因此,车辆的运动状态会通过改变其动态行为直接影响各种磁干扰的强度、空间分布和时间变化特性。这种紧密的关联表明磁干扰补偿效果与运动状态之间存在内在联系。准确建立这两者之间的映射关系不仅对于理解磁干扰的机制至关重要,而且也基于状态识别开发自适应补偿方法提供了关键的理论基础。

1.2 基于CNN-SRU的运动状态识别模型

准确识别车辆的运动状态是分析磁补偿效果的重要前提。惯性测量单元输出的三轴加速度和三轴角速度构成了六维时序数据,这些数据既包含空间关联性,又具有时间依赖性。为此,本文构建了卷积神经网络与简单循环单元相结合的混合模型,通过卷积神经网络挖掘空间特征与简单循环单元捕捉时序规律,实现对运动状态的精准实时识别。

1) 卷积神经网络

CNN是一种常应用于图像信息处理的深度学习模型,在时序分析、计算机视觉和自然语言处理等领域取得广泛应用。随着研究的不断深入,卷积神经网络在时序信号处理领域也展现出强大的应用潜力。

卷积神经网络的结构通常由输入层、卷积层、激活函数、池化层、全连接层、输出层构成(如图1所示)。在时序分析中,CNN通过卷积操作可有效提取时间维度上的局部依赖特征,实现对序列数据的高效表征。




图1 CNN基本结构

Fig. 1 Basic structure of CNN

2) 简单循环单元

SRU^[20]是循环神经网络的高效变体(结构如图2所示)。在图2中展示了SRU单元的内部结构包括遗忘门、重置门、内部状态和输出向量的计算流程。该模型通过优化门控机制在保持序列建模能力的同时显著提升运算效率。SRU的核心组件包括重置门与更新门:前者控制历史信息保留程度,后者调节新信息融入比例,二者协同工作实现对长期依赖关系的有效捕捉。

相较于传统长短时记忆网络(long short-term memory networks, LSTM)和门控循环单元(gated recurrent unit, GRU)单元,SRU通过分离时间步间与时间步内计算实现




图 2 SRU 基本结构

Fig. 2 Basic structure of SRU

了更高层次的运算并行化,在处理长序列数据时展现出显著的效率优势的同时,还保持相当的建模能力。

$$\tilde{\mathbf{x}}_t = \mathbf{W}\mathbf{x}_t \quad (1)$$

$$\mathbf{f}_t = \sigma(\mathbf{W}_f\mathbf{x}_t + \mathbf{b}_f) \quad (2)$$

$$\mathbf{r}_t = \sigma(\mathbf{W}_r\mathbf{x}_t + \mathbf{b}_r) \quad (3)$$

$$\mathbf{c}_t = \mathbf{f}_t \odot \mathbf{c}_{t-1} + (1 - \mathbf{f}_t) \odot \tilde{\mathbf{x}}_t \quad (4)$$

$$\mathbf{h}_t = \mathbf{r}_t \odot \mathbf{g}(\mathbf{c}_t) + (1 - \mathbf{r}_t) \odot \mathbf{x}_t \quad (5)$$

其中, $\mathbf{x}_t$ 为 t 时刻的输入向量; $\mathbf{W}$ 、 $\mathbf{W}_f$ 、 $\mathbf{W}_r$ 为权重矩阵; $\mathbf{b}_f$ 、 $\mathbf{b}_r$ 为偏置向量; $\tilde{\mathbf{x}}_t$ 为经过线性变化后的输入向量; $\mathbf{f}_t$ 与 $\mathbf{r}_t$ 分别表示遗忘门和重置门; $\mathbf{c}_t$ 、 $\mathbf{c}_{t-1}$ 为内部状态向量; $\mathbf{h}_t$ 为输出向量。

3) CNN-SRU 组合模型

基于车辆运动数据的特性,本文设计了图 3 所示的 CNN-SRU 混合架构。该模型采用分层处理策略:前端 CNN 模块通过多组卷积-池化层从原始 IMU 数据中提取空间特征;后端 SRU 模块对特征序列进行时序建模从而捕捉状态转换的关键节点。




图 3 CNN-SRU 模型结构

Fig. 3 CNN-SRU model architecture

输出层通过 Dropout 进行正则化处理,经全连接层映射至 4 类运动状态对应维度,最终通过 Softmax 函数输出概率分布。这种架构有效克服了单一模型的局限:CNN 难以建立长期时序依赖,而循环网络在原始信号特征学习方面效率较低。

该混合模型充分考虑了实际应用中的实时性需求:CNN 的前向传播具有高度并行性,SRU 的简化结构保障了快速序列处理能力,使其适合部署于资源受限的嵌入式平台,为车辆实时运动分析提供可靠技术支持,表 1 为 CNN-SRU 网络参数。

1.3 磁场数据标定及补偿方法

车辆在运行过程中,由于车体自身产生的磁干扰会严重影响磁力计测量数据的准确性。理论上,在均匀地磁场环境中,当载体进行充分的三维姿态机动时,无干扰条件下的磁力计测量数据应分布在一个球面上。然而,在实际行驶条件下,车辆受自身运动状态和场地的限制,车辆主要在二维平面内运动,导致其姿态变化范围相对有限,无法完全的进行三维姿态运动,导致三轴磁力计测量数据在三维空间中的分布呈现三维椭球面特征。这种椭球分布主要源于两方面因素:一方面是车辆在平面运动过程中,偏航角变化使 X、Y 轴磁场数据变化显著,而有限的俯仰和滚转角变化使 Z 轴数据变化相对较小,但不可忽略;另一方面,硬磁效应(固定偏置)和软磁效应(各向异性缩放和交叉耦合)的共同作用,使数据分布沿各轴产生不同程

表 1 CNN-SRU 网络参数

Table 1 CNN-SRU network parameters

网络层	输出大小	参数数量
Input	(None, 100, 6)	0
Conv1(3×1,32)	(None, 100, 32)	608
BatchNorm1	(None, 100, 32)	64
MaxPool1(2)	(None, 50, 32)	0
Conv2(3×1,64)	(None, 50, 64)	6 208
BatchNorm2	(None, 50, 64)	128
MaxPool2(2)	(None, 25, 64)	0
Conv3(3×1,128)	(None, 25, 128)	24 704
BatchNorm3	(None, 25, 128)	256
MaxPool3(2)	(None, 12, 128)	0
SRU1	(None, 12, 256)	98 304
SRU2	(None, 12,256)	196 608
Dense1(256→128)	(None, 128)	32 896
Dropout	(None, 128)	0
Dense2(128→4)	(None, 4)	516

度的缩放和平移,从而形成椭球面。

综合上述分析,本文采用椭球拟合方法对磁力计数据进行标定与补偿。通过采集车辆在机动过程中的三轴磁场数据拟合最优椭球曲面,进而解算硬磁效应向量与软磁效应矩阵,实现对三轴磁干扰数据的精确补偿^[21]。

1) 椭球拟合数学模型

磁力计在载体坐标系中的测量模型可以表示为:

$$\mathbf{H}_m = \mathbf{M} \cdot \mathbf{H}_e + \mathbf{H}_p \quad (6)$$

其中, $\mathbf{H}_m = [H_{mx}, H_{my}, H_{mz}]^T$ 为磁力计测量值, $\mathbf{H}_e = [H_{ex}, H_{ey}, H_{ez}]^T$ 为真实地磁场矢量, $\mathbf{M}$ 为 3×3 软磁效应矩阵, $\mathbf{H}_p$ 为硬磁效应向量。

在无干扰理想情况下,地磁场强度模值恒定:

$$\mathbf{H}_e^T \cdot \mathbf{H}_e = H_0^2 \quad (7)$$

其中, H_0 为当地地磁场标量值。将测量模型代入可得:

$$(\mathbf{H}_m - \mathbf{H}_p)^T \cdot (\mathbf{M}^T \mathbf{M})^{-1} \cdot (\mathbf{H}_m - \mathbf{H}_p) = H_0^2 \quad (8)$$

令 $\mathbf{A} = (\mathbf{M}^T \mathbf{M})^{-1}$, 得到椭球方程:

$$(\mathbf{H}_m - \mathbf{H}_p)^T \cdot \mathbf{A} \cdot (\mathbf{H}_m - \mathbf{H}_p) = H_0^2 \quad (9)$$

2) 椭球拟合算法

将椭球方程展开为一般二次曲面形式:

$$aH_{mx}^2 + bH_{my}^2 + cH_{mz}^2 + 2dH_{mx}H_{my} + 2eH_{mx}H_{mz} + 2fH_{my}H_{mz} + 2pH_{mx} + 2qH_{my} + 2rH_{mz} + g = 0 \quad (10)$$

其中,系数 $a, b, c, d, e, f, p, q, r, g$ 为待求解参数。

设有 N 个磁力计测量点 $\mathbf{H}_{mi} = [H_{mxi}, H_{myi}, H_{mzi}]^T$, $i = 1, 2, \dots, N$, 定义参数向量:

$$\boldsymbol{\theta} = [a, b, c, d, e, f, p, q, r, g]^T \quad (11)$$

定义矩阵 $\mathbf{D}$, 其第 i 行元素为:

$$\mathbf{D}_i = \begin{bmatrix} H_{mxi}^2, H_{myi}^2, H_{mzi}^2, 2H_{mxi}H_{myi}, \\ 2H_{mxi}H_{mzi}, 2H_{myi}H_{mzi}, 2H_{mxi}, \\ 2H_{myi}, 2H_{mzi}, 1 \end{bmatrix} \quad (12)$$

最小二乘拟合的目标是最小化代数距离平方和:

$$\min \|\mathbf{D} \cdot \boldsymbol{\theta}\|^2 \quad (13)$$

为保证拟合结果为椭球面,需施加约束条件。本文采用约束条件 $kJ - I^2 > 0$, 即:

$$\begin{cases} I = a + b + c \\ J = ab + bc + ac - d^2 - e^2 - f^2 \end{cases} \quad (14)$$

其中, k 为约束参数。通过带约束的最小二乘法求解, 得到最优参数估计 $\boldsymbol{\theta}^*$ 。

3) 补偿参数推导

从拟合参数 $\boldsymbol{\theta}^*$ 中提取椭球几何参数。定义二次项系数矩阵和一次项系数向量:

$$\mathbf{A}_1 = \begin{bmatrix} a & d & e \\ d & b & f \\ e & f & c \end{bmatrix} \quad (15)$$

$$\mathbf{B} = \begin{bmatrix} p \\ q \\ r \end{bmatrix} \quad (16)$$

椭球中心坐标(即硬磁效应向量)为:

$$\mathbf{H}_p = -\mathbf{A}_1^{-1} \mathbf{B} \quad (17)$$

椭球形状矩阵为:

$$\mathbf{A}_e = \frac{\mathbf{A}_1}{\mathbf{B}^T - \mathbf{A}_1^{-1} \mathbf{B} - g} \quad (18)$$

对 $\mathbf{A}_e$ 进行奇异值分解:

$$\mathbf{A}_e = \mathbf{U} \cdot \sum \cdot \mathbf{U}^T \quad (19)$$

其中, $\mathbf{U}$ 为正交矩阵, $\sum$ 为对角矩阵。则软磁干扰矩阵为:

$$\mathbf{M} = \mathbf{H}_0 \cdot \mathbf{U} \cdot \sum^{-1/2} \cdot \mathbf{U}^T \quad (20)$$

4) 实时磁补偿

获得软磁效应矩阵 $\mathbf{M}$ 与硬磁效应向量 $\mathbf{H}_p$ 后, 对实时磁力计测量值进行补偿:

$$\mathbf{H}_e = \mathbf{M}^{-1} \cdot (\mathbf{H}_m - \mathbf{H}_p) \quad (21)$$

其中, $\mathbf{H}_e$ 为补偿后的地磁场值。该方法通过椭球拟合实现了对三轴磁力计的全面标定, 有效提高了车辆在各种运动状态下的磁场测量精度, 为地磁导航提供了可靠的数据基础。

2 试验与分析

2.1 数据采集

为了探究车辆运动状态与磁补偿效果之间的相关性, 本次试验为此搭建了一个基于无人车载体的综合试验平台。该平台搭载了多源传感器集成系统, 包括光泵磁传感器、三轴磁力计、惯性测量单元(IMU)以及 GNSS/INS 组合导航系统(如图 4 所示)。其中光泵磁传感器作为地磁场基准测量设备, 提供真实地磁场参考值; 三轴磁力计用于采集受干扰的磁场测量数据; 惯性测量单元(IMU)提供三轴加速度与角速度数据信息, 用于识别无人车运动状态变化情况; GNSS/INS 组合导航系统输出车辆的位置、速度等信息。




图4 无人车试验平台

Fig. 4 Autonomous vehicle test platform

试验地点选择在某个磁环境稳定区域中开展试验(如图 5 所示)。该区域地磁场环境稳定, 周围没有大型磁干扰源, 能够确保磁测数据的可靠性和准确性。在试验过程中, 无人车按照预先设计的测试轨迹行驶, 覆盖车辆常见的 4 种典型运动状态, 包括静止状态、加速状态、匀速直线状态、转向状态。



图 5 试验场地

Fig. 5 Test site

2.2 运动状态识别模型性能验证

为了评价 CNN-SRU 混合模型作为运动状态识别模型的可靠性,本节从模型构建与数据准备、训练过程分析、训练与推理效率评价、测试等多个维度进行了系统评价。

1) 模型构建及数据准备

本研究选取惯性测量单元 IMU 中记录的加速度与角速度信息作为输入特征,通过 CNN-SRU 模型对车辆运动状态进行学习。为了充分捕获传感器数据的动态时序特征,本研究采用了一种长度为 100 个数据点的滑动窗口方法,该窗口在时间轴上连续滑动,生成形状为 100×6 的序列作为神经网络模型的输入。该方式不仅保留了运动状态的连续性,还增强了模型对状态转换边界的识别能力。

本次试验中所使用的数据集经过清洗后共包含 33 500 个有效数据点,为保证模型评估的客观性,按照 6-4 的比例划分为训练集与测试集。其中训练集包含 20 100 个样本,测试集包含 13 400 个样本。在训练过程中,进一步从训练集中随机选取 25% 的数据作为验证集,用于监控训练过程并防止过拟合,运动轨迹如图 6 所示。




图 6 车辆运行轨迹

Fig. 6 Vehicle trajectory

2) 模型训练过程分析

神经网络模型训练的核心目的是优化算法调整 CNN-

SRU 网络的参数,使结果与真实标签之间的损失函数最小化。为了对 CNN-SRU 模型的性能进行全面评估,在使用完全相同的超参数设置和数据集的情况下,对 CNN-SRU、CNN-GRU、CNN-LSTM 3 种模型进行了对比测试。所有训练试验均在搭载 NVIDIA GTX 3080 显卡的计算平台上进行,使用 Python3 编程语言和 PyTorch 深度学习框架,以确保对比试验的公平性。

图 7 展示了训练过程中 3 个模型的准确度和损失函数的变化曲线,这些曲线清楚地反映了模型的学习动态。从准确度曲线中可以看出,模型能够快速收敛,训练准确度随迭代次数增加而稳步上升,在经历 25 个训练周期后达到了较高的稳定水平。图 8 展示了验证过程中 3 个模型的精度和损失函数的变化曲线。从两幅图中可以观察到,3 种模型在相同的数据集上都具有相似的准确度与损失值,因此这 3 种模型具有可比性。




图 7 训练集的准确度与损失函数

Fig. 7 Accuracy and loss function of the training set




图 8 验证集的准确度与损失函数

Fig. 8 Accuracy and loss function of the validation set

3) 模型的训练与推理效率

在车辆上部署模型时实时推理效率与准确性同等重要,图 9 展示了 3 种混合模型完成训练过程所需的时间对比结果,从图 9 中可以看出 CNN-SRU 模型在单轮训练时间和总训练时间上均显著优于对比模型。这一优势主要

源于 SRU 通过简化门控结构和优化计算流程,实现了比 GRU 和 LSTM 更高的计算并行度,从而有效加快了模型的收敛速度。




图 9 模型训练效率对比

Fig. 9 Comparison of model training efficiency

模型的实时推理性能是决定其能否成功应用于在线系统的关键因素。为评估模型的实时性,测试了 3 种模型在处理批量数据与单一样本时的延迟表现(如图 10 所

示)。分析表明 CNN-SRU 模型在批次处理延迟和单样本推理延迟两项关键指标上均表现最优。特别值得指出的是,其单样本推理时间远低于单个数据采集周期,表明模型具备充足的能力来处理连续输入的实时数据流。表 2 进一步提供了 3 种模型在训练效率、模型复杂度、识别性能和实时性能等方面的详细对比数据。




图 10 模型实时性效果对比

Fig. 10 Comparison of model real-time performance

表 2 不同模型性能指标对比

Table 2 Comparison of performance indicators for different models

模型	训练效率			模型复杂度		识别能力		实时性能		
	单轮 时间/s	总时间/ s	收敛 时间/s	浮点运算量 (MFLOPs)	总节点 个数	准确度/ %	F1 分数/ %	批次 延迟/ms	单样本 延迟/ms	吞吐量 (样本个数/s)
CNN-SRU	39.87	1 993.72	955.79	17.00	2 180	99.61	99.52	35.12	0.548 7	1 820
CNN-GRU	45.74	2 287.16	1 134.05	18.30	2 180	99.68	99.59	44.06	0.688 5	1 451
CNN-LSTM	55.64	2 782.23	1 391.25	19.60	2 180	99.73	99.64	57.10	0.892 3	1 119

4)模型的验证测试

为了最终确认模型的泛化能力,本研究在完全独立的测试集(13 400 个样本)上进行了严格的验证测试,并采用了目前公认的评估指标进行评价,如混乱矩阵、准确度和 F1 分数,如表 3 所示。

表 3 模型泛化验证数据集

Table 3 Model generalization validation dataset

数据分类	数据个数	占比/%
静止	2 430	18.13
加速	1 576	11.76
匀速	2 615	19.51
转向	6 779	50.59

图 11 所示的混淆矩阵直观地呈现了 CNN-SRU 模型在 4 个运动状态类别上的详细识别性能。矩阵对角线上的高数值表明模型对所有状态均具备卓越的区分能力。模型在 4 种运动状态上的识别准确率均超过 99%,在动态

特征可能较为相似的加速与转向状态之间模型的误判率极低,这充分证明了 CNN-SRU 模型能够从复杂的六维 IMU 时序数据中,学习到不同运动状态之间细微而关键的特征差异。




图 11 CNN-SRU 模型混淆矩阵

Fig. 11 Confusion matrix of CNN-SRU model

针对表 3 中运动状态样本分布不均的情况需说明的是,样本分布的差异性主要源于车辆在实际运动过程中各状态自然发生率,而非人为有意设置的偏差。在对数据进行的训练过程中,训练集包含了所有 4 种运动状态(静止、加速、匀速、转向)的数据,确保了模型能够全面学习并区分各类运动特征。此外,在验证集中也同样包含 4 种运动状态的数据,确保了对各类状态的有效验证。

尽管验证集中 4 种运动状态样本量不均,但从图 11 的混淆矩阵显示中可以看出,CNN-SRU 模型在样本较少的加速和静止等状态下仍保持较高的识别精度与低误判率,这也表明模型并未因样本分布差异而削弱对少数类别的判别能力。此结果也说明了模型所学习到的是运动状态的内在特征而非单纯依赖于样本数量,因此,这也体现了模型良好的泛化能力与鲁棒性,为后续基于运动状态的自适应磁补偿提供了可靠的运动状态判别依据。

图 12 进一步对比了 CNN-SRU 混合模型与单一的 CNN、SRU 模型的整体性能。结果显示,CNN-SRU 模型在整体准确率和 F1 分数上均显著优于两个单一模型,这一发现充分验证了所提混合架构在特征提取与时序建模上的协同增效作用。CNN 模块擅长提取局部空间特征,而 SRU 模块则有效捕捉长期时序依赖,二者的结合实现了优势互补。




图 12 不同模型的准确率和 F1 分数

Fig. 12 Accuracy and F1 score of different models

综合以上测试结果,CNN-SRU 模型在识别准确性、鲁棒性和实时性等多个方面都表现出了优异的性能,有效验证了其在车辆运动状态识别任务中的实用性和可靠性,为后续的车辆磁干扰补偿提供了可靠的运动状态信息的支撑。

2.3 运动状态与磁干扰补偿效果分析

为评估单一补偿参数对车辆全工况运动中磁干扰的适应能力,本研究通过融合运动状态识别与椭球拟合标定补偿方法,系统分析了椭球拟合模型在不同运动状态下的补偿性能。

1) 磁补偿数据标定

磁补偿标定的主要目的是为了消除车辆自身产生的磁干扰,从而获得一组有效的补偿参数,并为后续补偿其

他磁场数据提供基础。本文采用连续转圈运动作为车辆标定的机动方式,这主要是因为车辆在转圈过程中会产生足够的偏航角变化,进而有效激发磁场的变化,使得椭球拟合方法能够更好地适应磁场数据的分布特点。

图 13 展示了车辆的运动轨迹图,明确显示了车辆在平面内的转动路径,确保了在一定范围内覆盖不同姿态的变化。图 14 展示了在转圈运动中采集到的三轴磁通门数据。从信号曲线可以看出,在转圈运动下,X、Y 轴磁场呈现明显的周期性波动,而 Z 轴变化相对平缓,反映出磁场畸变与车辆运动状态之间的关联。




图 13 车辆运行轨迹

Fig. 13 Vehicle trajectory




图 14 三轴磁通门数据

Fig. 14 Three-axis fluxgate data

图 15 展示了基于转圈标定数据的补偿结果图。从图 15 中可以看出,原始的三轴磁场数据存在明显的周期性波动,与基准数据相比存在较大的差距。然而,在进行椭球拟合标定并进行补偿后,数据明显更接近基准数据,波动幅度大大减小。这表明,椭球拟合标定能够有效抑制由车辆运动引起的磁场干扰,验证了该方法在实际应用中的有效性和良好的补偿效果。

这一结果进一步证明,通过转圈标定得到的补偿系数能够显著改善磁场测量的准确性,为后续的磁干扰补偿提




图 15 标定数据补偿结果

Fig. 15 Calibration data compensation result

供了可靠的基础。

2) 补偿结果分析

基于椭圆拟合标定获得的固定参数,对包含完整运动状态的传感器数据进行补偿处理。图 16 展示了车辆运动轨迹;图 17(a)与(b)中的加速度计和陀螺仪数据清晰反映了车辆运动状态的动态变化特征;图 18 展示了三轴磁通门的原始数据。





图 16 车辆运行轨迹

Fig. 16 Vehicle trajectory

图 19 展示了完整运动状态的补偿结果,从图 19 中看出不同运动状态的补偿结果呈现出明显的差异。结合图 20 中 CNN-SRU 模型识别出的运动状态数据,选取 3 个典型运动片段进行深入分析。


图 21 为选取的转向运动状态下的数据图,其中图 21(a)与(b)分别对应转向运动状态下的加速度计与陀螺仪的数据,从图中可以看出该状态下剧烈的姿态变化;图 21(c)为磁通门采集到的原始磁场数据,图 21(d)则为补偿后的结果。分析可得,转向过程中因姿态快速变化与强烈涡流干扰并存,即便经过补偿,磁场数据仍表现出较明显的波动。

图 22 为选取的加速运动状态下的数据图,其中



(a) 加速度计数据

(a) Accelerometer data



(b) 陀螺仪数据

(b) Gyroscope data

图 17 多种运动状态下的 IMU 数据

Fig. 17 IMU data in multiple motion states




图 18 三轴磁通门数据

Fig. 18 Three-axis fluxgate data

图 22(a)与(b)分别对应加速运动状态下的加速度计与陀螺仪的数据,从图 22 中可以观察到明显的加速特征;图 22(c)为磁通门采集到的原始磁场数据,图 22(d)则为补偿后的结果。分析表明,该状态下动力系统瞬态电磁干扰




图 19 补偿结果
Fig. 19 Compensation result







图 20 车辆运动状态识别数据
Fig. 20 Vehicle motion state recognition data




(a) 加速度计数据
(a) Accelerometer data



(b) 陀螺仪数据
(b) Gyroscope data



(c) 原始数据
(c) Raw data



(d) 补偿后的数据
(d) Compensated data

图 21 转向运动状态数据
Fig. 21 The steering motion state data graph shows

较强,补偿效果受到明显制约。

图 23 为选取的直线运动状态下的数据图,其中图 23(a)与(b)分别对应直线运动状态下的加速度计与陀螺仪的数据,从图中可以看出运动姿态保持稳定;图 23(c)为磁通门采集到的原始磁场数据,图 23(d)则为对原始数据补偿后的结果。分析显示,在该运动状态下由于姿态变化平稳,干扰相对稳定,补偿后的结果平稳,补偿效果

最优。

以上分析进一步表明,运动状态显著影响磁补偿效果,这为后续研究自适应补偿方法提供了依据。

在磁补偿评估中,标准差反映磁测数据的离散程度,改善比则量化补偿算法对于干扰磁场的抑制效果。表 4 中的数据进一步验证了上述趋势。转向运动的改善比最高为 6.55,但由于补偿前干扰较强度为 3 495.39 nT,补偿





图 22 加速运动状态数据
Fig. 22 The data graph of accelerated motion state

后的标准差仍处于较高水平为 533.35 nT。匀速直线运动的改善比为 1.67, 补偿后标准差降至 49.39 nT, 表现最为稳定。相比之下, 加速运动的改善比仅为 0.85, 补偿后标准差达到 147.98 nT, 这说明在当前固定参数下, 补偿过程不仅未能有效消除干扰, 反而可能带来一定的误差引入。

试验结果明确显示, 运动状态是决定磁补偿效果的核心因素。不同运动状态下补偿效果的明显差异说明, 采用固定参数的补偿模型无法在全工况中保持稳定性能。进一步分析补偿后的地磁数据质量可以发现, 在匀速直线等平稳运动状态下, 补偿结果具有较高的可靠性; 而在加速、转向等动态工况中, 受复杂磁干扰影响, 补偿数据的可信






图 23 直线运动状态数据

Fig. 23 The linear motion state data graph shows

表 4 不同运动状态结果对比

Table 4 Comparison of results under different exercise states

运动状态	补偿前	补偿后	改善比/
	标准差/nT	标准差/nT	%
加速运动	126.46	147.98	0.85
转向运动	3 495.39	533.35	6.55
直线运动	82.76	49.39	1.67
完整运动	3 897.42	230.92	16.87

度明显下降。通过系统性的试验,本研究验证了发展基于运动状态识别的自适应磁补偿策略既必要也可行。所建立的运动状态与补偿效果之间的对应关系,为实时补偿过程中评估地磁数据可信度提供了重要参考,也为实现车辆在全工况下的高精度地磁导航奠定了实验与理论基础。

3 结 论

针对无人车地磁导航在动态行驶中磁干扰补偿适应性不足的问题,本研究从车辆运动状态角度系统研究了磁干扰特性及其补偿效果。通过设计基于 CNN-SRU 的识别模型,实现了运动状态的高效实时感知。研究证实,运动状态显著影响磁干扰表现与补偿效果,传统固定参数方法难以适应全工况需求,需发展状态相关补偿机制。据此构建的“识别-评估”分析框架,为地磁数据可信度判别提供了方法依据。目前研究尚未形成完整的自适应补偿体系,强动态干扰下的参数实时调整仍需深入。未来将聚焦于状态-参数关系建模,并融合多源信息,以提升复杂环境下地磁导航的精度与鲁棒性。

参考文献

[1] 黄磊,杨铭远,刘备. 基于优化 Cartographer-SLAM 算法的机器人自主导航系统设计[J/OL]. 电子测量与仪器学报, 1-10 [2026-04-10]. <https://link.cnki.net/urlid/11.2488.TN.20251127.1337.002>.

HUANG L, YANG M Y, LIU B. Design of a robot autonomous navigation system based on optimized Cartographer-SLAM algorithm [J/OL]. Journal of Electronic Measurement and Instrumentation, 1-10 [2026-04-10]. <https://link.cnki.net/urlid/11.2488.TN.20251127.1337.002>.

[2] 路永乐, 杨杰, 鄢誉, 等. 基于函数拟合姿态更新方法的足绑式行人导航算法[J]. 仪器仪表学报, 2024, 45(5): 291-299.

LU Y L, YANG J, YAN Y, et al. Foot mounted pedestrian navigation algorithm based on the function fitting attitude update algorithm[J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 291-299.

[3] 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.

[4] 陆一, 魏东岩, 纪新春, 等. 地磁定位方法综述[J]. 导航定位与授, 2022, 9(2): 118-130.

LU Y, WEI D Y, JI X CH, et al. Review of geomagnetic positioning method [J]. Navigation Positioning & Timing, 2022, 9(2): 118-130.

[5] HAN Y Q, LIANG R R. A high-altitude geomagnetic matching area selection approach based on geomagnetic information entropy and geomagnetic direction entropy[J]. Measurement and Control, 2025, 58(1): 119-127.

[6] 张且且, 郭静茹, 赖际舟. 车载 GNSS/INS 组合导航任意安装角在线自动标定算法研究[J]. 仪器仪表学报, 2025, 46(9): 290-300.

ZHANG Q Q, GUO J R, LAI J ZH. Research on online auto-calibration algorithm of arbitrary

- installation angles for vehicle GNSS/INS integrated navigation [J]. Chinese Journal of Scientific Instrument, 2025, 46(9): 290-300.
- [7] HE Y, LI J C, LIU J CH. Research on GNSS INS & GNSS/INS integrated navigation method for autonomous vehicles: A Survey [J]. IEEE Access, 2023, 11: 79033-79055.
- [8] 蔡庸辉, 周凌柯, 李胜, 等. 基于 SINS/GNSS 动态差分序列的 AEKF 算法研究[J]. 电子测量技术, 2024, 47(19): 44-53.
CAI Y H, ZHOU L K, LI SH, et al. Study of AEKF algorithm based on SINS/GNSS dynamic difference sequence [J]. Electronic Measurement Technology, 2024, 47(19): 44-53.
- [9] 马超, 瞿智, 李献斌, 等. 北斗新体制 BOC B1C 导航信号模拟与生成[J]. 电子测量与仪器学报, 2024, 38(1): 154-159.
MA CH, QU ZH, LI X B, et al. BeiDou BOC B1C navigation signal simulation and generation[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(1): 154-159.
- [10] 刘强, 王涛, 张晓明, 等. Tolles-Lawson 模型——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.
LIU Q, WANG T, ZHANG X M, et al. A one-dimensional convolutional neural network aeromagnetic compensation method based on Tolles-Lawson model[J]. Navigation Positioning & Timing, 2025, 12(2): 69-77.
- [11] QUAN S H, ZHOU Y L, ZHAO SH, et al. An inertial constraint-aided geomagnetic matching algorithm for underwater navigation [J]. Measurement, 2025, 256: 118156.
- [12] LUO H H, PAN M CH, DU Q F, et al. Velocity-related magnetic interference compensation of unmanned underwater vehicle [J]. Remote Sensing, 2023, 15(17): 4164.
- [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.
- [14] NORIEGA G. UAV-based magnetometry—practical considerations, performance measures, and application to magnetic anomaly detection[J]. The Leading Edge, 2022, 41(7): 472-480.
- [15] LI R Y, MIAO H S, HAO Y, et al. Improved ellipsoid fitting method based on tensor mix source separation for correcting the three-component magnetometer [J]. IEEE Sensors Journal, 2025, 25(4): 6226-6233.
- [16] CHANG H T, CHANG J Y. Iterative robust ellipsoid fitting based on M-estimator with geometry radius constraint[J]. IEEE Sensors Journal, 2022, 23(2): 1397-1407.
- [17] FU J, NING ZH W, CHANG Y. Active compensation method for strong magnetic interference of MEMS electronic compass[J]. IEEE Access, 2021, 9: 48860-48872.
- [18] XIE Y D, LIU N, LYU SH H. CNN-LSTM method for vehicle motion behavior recognition[C]. 2023 42nd Chinese Control Conference (CCC). IEEE, 2023: 8337-8342.
- [19] LIU N, XIE Y D, SU ZH, et al. Adaptive Kalman filter-integrated navigation measurement using inertial sensor for vehicle motion state recognition [J]. Measurement, 2025, 248: 116907.
- [20] SHE Q SH, MU G Y, GAN H T, et al. Spatio-temporal SRU with global context-aware attention for 3D human action recognition[J]. Multimedia Tools and Applications, 2020, 79: 12349-12371.
- [21] 秦赓, 管雪元, 李文胜. 基于椭球补偿的三维载体磁场误差补偿方法[J]. 电子测量技术, 2018, 41(2): 37-40.
QIN G, GUAN X Y, LI W SH. Compensation method of magnetic field error of three-dimensional vehicle based on ellipsoid compensation[J]. Electronic Measurement Technology, 2018, 41(2): 37-40.

作者简介

潘凯霖, 硕士研究生, 主要研究方向为地磁导航中的磁干扰补偿。

E-mail: 15503658484@163.com

张晓明(通信作者), 教授, 博士研究生导师, 主要研究方向为动态测试与组合导航。

E-mail: zxm_auto@nuc.edu.cn

张鸽, 博士研究生, 主要研究方向为微弱磁信号处理及智能组合导航。

E-mail: gezhang_auto@163.com

范义伟, 博士研究生, 主要研究方向为智能组合导航。

E-mail: fyw852206809@163.com

李博宇, 硕士研究生, 主要研究方向为地磁导航中的磁干扰补偿。

E-mail: lbytg19@163.com