

## 基于 GGA-ELM 神经网络的飞行器地磁定位方法

邹维宝<sup>1</sup>, 常超飞<sup>1</sup>, 李启栋<sup>1</sup>, 刘恩铭<sup>1</sup>, 韩大恒<sup>1</sup>, 彭鑫<sup>2</sup>

(1. 长安大学 地质工程与测绘学院, 西安 710054; 2. 中国人民解放军 61363 部队, 西安 430071)

**摘要:** 在地磁导航定位中应用人工智能时, 传统神经网络面临训练效率低和易陷入局部最优等挑战。针对这些问题, 提出了一种基于改进遗传算法优化极限学习机神经网络 (GGA-ELM) 的飞行器地磁定位方法。通过在传统遗传算法中引入精英反向学习策略, 优化后的 ELM 网络提高了训练效率, 有效降低了陷入局部最优的风险。实验结果表明: 与 CNN、BiLSTM 和 LSTM 模型相比, GGA-ELM 模型的训练时间显著减小, 此外, GGA-ELM 模型的定位误差约为 4 m, 定位时间为 0.003 s。与 ELM、GA-ELM、CNN、BiLSTM、RBF 及 LSTM 模型相比, GGA-ELM 模型方法的定位精度分别提高了 86.6%、115.9%、417.8%、187.6%、216.5%、107.5%; 定位时间最多减小了 0.947 s。所提方法在航磁数据上的定位稳定性更好, 准确性更高。

**关键词:** 飞行器; 遗传算法; 极限学习机; 地磁定位; 航磁数据

**中图分类号:** V249.3

**文献标志码:** A

## Aircraft geomagnetic localization algorithm based on GGA-ELM neural network

ZOU Weibao<sup>1</sup>, CHANG Chaofei<sup>1</sup>, LI Qidong<sup>1</sup>, LIU Enming<sup>1</sup>, HAN Daheng<sup>1</sup>, PENG Xin<sup>2</sup>

(1. School of Geology Engineering and Geomatics, Chang'an University, Xi'an 710054, China;

2. People's Liberation Army Unit 61363, Xi'an 430071, China)

**Abstract:** Traditional neural network algorithms are prone to consuming a long time and getting stuck in local optima when artificial intelligence methods are applied to geomagnetic navigation and positioning. To address these issues, a method for geomagnetic positioning of aircraft based on improved gradient-based genetic algorithm optimized extreme learning machine neural network (GGA-ELM) is proposed. The training efficiency is greatly improved based on the optimized ELM network and the risk of falling into local optimum is effectively reduced as well by introducing an elite reverse learning strategy into the traditional genetic algorithm. Some aeromagnetic data measured by drone are used for investigation. The experimental results show that the training time of the GGA-ELM model is significantly reduced compared with the CNN, BiLSTM and LSTM models. In addition, the localization error of the GGA-ELM model is about 4 m, and the localization time is 0.003 s. Compared with the ELM, GA-ELM, CNN, BiLSTM, RBF and LSTM models, based on the GGA-ELM method, the localization accuracy is improved by 86.6%, 115.9%, 417.8%, 187.6%, 216.5%, and 107.5%, respectively. The localization time is reduced up to 0.947 s. From the results, it is clearly seen that the proposed method has better positioning stability and higher accuracy on aircraft localization.

**Key words:** aircraft; genetic algorithm; extreme learning machine; geomagnetic localization; aeromagnetic data

近年来, 卫星导航定位技术的广泛应用在经济与军事领域展现出巨大价值, 但其信号易受干扰与遮挡

的缺点, 使得无人机、航天器等在卫星拒止环境下导航定位能力受限<sup>[1]</sup>。惯性导航系统虽能提供相对精确

**收稿日期:** 2024-10-25; **修回日期:** 2025-06-10

**基金项目:** 国家自然科学基金 (42174006, 42371356); 国防科技创新项目 (19-163-00-KX-002-030-01)

**作者简介:** 邹维宝 (1967—), 男, 副教授, 硕士生导师。从事地磁导航研究。

的位置估计,但存在累积误差问题<sup>[2]</sup>。地磁导航凭借其全天时、全天候、全地域的优势,以及隐蔽性和抗干扰能力,成为导航技术领域的重要研究方向<sup>[3]</sup>。

地磁导航定位算法分为传统匹配算法与智能化算法两大类<sup>[4]</sup>。传统方法如地磁轮廓匹配算法(Magnetic Contour Matching, MAGCOM)<sup>[5]</sup>与最近等值线迭代算法(Iterative Closest Contour Point, ICCP)<sup>[6]</sup>等,虽能实现实时定位,但定位精度受导航区域地磁特征丰富程度影响。随着统计学与信号处理理论的引入,基于统计模型<sup>[7]</sup>与卡尔曼滤波<sup>[8]</sup>的地磁定位算法在提升定位精度方面取得显著进展。

近年来,机器学习技术在地磁定位中的应用成为研究热点。通过将机器学习算法融入地磁定位,如文献[9]利用卷积神经网络(Convolutional Neural Network, CNN)实现智能手表实时定位,文献[10]使用长短时记忆网络(Long Short-Term Memory, LSTM)在不同规模实验场地实现定位,文献[11]提出基于贝叶斯估计的地磁辅助导航算法,以及文献[12]探讨通过增加地磁相关特征参数提升神经网络训练效果,均展示了机器学习在地磁定位领域的潜力。尽管如此,传统神经网络在训练阶段可能面临效率低的问题,尤其是在处理复杂地磁环境中的大量数据时,训练过程往往需要较长时间。这种低训练效率可能限制其在实际应用中的快速部署与实时响应能力,尤其是在动态变化的环境中。因此,如何提升训练效率并优化神经网络的学习速度和适应性,成为提升其在复杂地磁环境中应用性能的关键因素。极限学习机(Extreme Learning Machine, ELM)作为一种高效的单隐层前馈神经网络算法,以其快速训练速度与强大的泛化能力,展现了在地磁定位中的巨大潜力<sup>[13]</sup>。尽管 ELM 能够在一定程度上缓解传统神经网络的训练效率问题,但其在特征提取与参数优化方面仍存在一定的不足,这可能影响其在复杂环境中的应用效果。因此,如何进一步优化 ELM 的性能,尤其是在复杂地磁环境下的精度与鲁棒性,仍然是当前研究的重要方向。

针对上述问题,提出了一种基于改进遗传算法(Gradation Genetic Algorithm, GGA)优化的极限学习机(ELM)飞行器地磁定位方法。GGA 通过引入精英反向学习策略,有效提高种群质量;使用 GGA 优化 ELM,可以找到适合 ELM 神经网络的最佳权值和阈值,再结合 ELM 的快速学习特性,最终可以实现高精度与高效率的地磁定位。本文旨在通过改进遗传算法优化 ELM,解决传统神经网络在地磁定位中的训练效率与性能问题,为智能化定位技术的发展提供新的思路与方法。

## 1 GGA-ELM 地磁定位方法

### 1.1 极限学习机

ELM 是一种特殊的单隐层前馈神经网络,在训练阶段抛弃传统的神经网络中基于梯度的算法(后向传播),随机选取输入层权重和隐藏层偏置,输出层权重通过最小化由训练误差项和输出层权重范数的正则项构成的损失函数,依据穆尔-彭罗斯(Moore-Penrose, MP)广义逆矩阵理论计算解析求出。该算法具有训练参数少、学习速度快、泛化能力强等特点,解决了神经网络训练耗时长问题。ELM 模型的网络结构如图 1 所示。




图 1 ELM 模型结构

Fig.1 ELM model structure

对于给定的训练集  $\{x_i, t_i | x_i \in R^D, t_i \in R^m, i=1, 2, \dots, N\}$ , 其中,  $x$  表示输入的地磁特征量,  $t$  表示对应的位置标签。ELM 的计算过程可以表示为:

$$f_L(x) = \sum_{i=1}^L \beta_i h_i(x) = \sum_{i=1}^L \beta_i g(w_i x + b_i), i=1, 2, \dots, N \quad (1)$$

式(1)中,  $N$  为训练集中样本的个数;  $h_i(x)$  是第  $i$  个隐藏层节点的输出;  $g$  为激活函数, 本文采用 sigmoid 函数作为激活函数;  $w_i$  为输入权重,  $\beta_i$  为输出权重;  $b_i$  为隐藏层中第  $i$  个神经元的偏置。

式(1)可以写成:

$$H\beta = T \quad (2)$$

在 ELM 算法中,  $w_i$  和  $b_i$  可以随机给定,  $H$  为隐藏层的输出矩阵。输出权值矩阵可通过求解式(2)得到。

$$\beta^* = \min \| H\beta - T \| \quad (3)$$

通过矩阵运算, 可得:

$$\beta^* = H^+ T \quad (4)$$

式(4)中,  $H^+$  为矩阵  $H$  的 MP 广义逆矩阵。

### 1.2 改进遗传优化算法

遗传算法是一种基于生物进化原理的全局优化搜索技术, 通过选择、交叉、变异等操作迭代求解最优解。选择操作依据适应度函数, 优先选择适应性强的个体进行遗传。交叉和变异操作则促进种群多样性,

提升全局搜索能力。然而，遗传算法存在过早趋同的风险，即当某个个体的适应度显著高于种群中其他个体时，可能导致算法陷入局部最优解，而非全局最优解。

为克服这一局限，在该算法中引入精英反向学习策略。该策略通过当前问题的最优解构建反向解，增加种群的多样性。在当前解与反向解中选择部分最优个体作为下一代的种子，以确保种群的高质量和多样性并有效避免过早趋同，提升算法的全局搜索性能。

精英反向解定义为：假设种群中个体对应的极值为精英个体，即  $X_{i,j}^e = (X_{i,1}^e, X_{i,2}^e, \dots, X_{i,d}^e)$ ， $(i=1,2,\dots,s; j=1,2,\dots,d)$  其反向解  $\overline{X_{i,j}^e} = (\overline{X_{i,1}^e}, \overline{X_{i,2}^e}, \dots, \overline{X_{i,d}^e})$  可以表示为：

$$\overline{X_{i,j}^e} = K \cdot (\alpha_j + \beta_j) - X_{i,j}^e \quad (5)$$

其中， $K$  为  $(0,1)$  上的动态系数； $X_{i,j}^e \in [\alpha_j, \beta_j]$ ， $\alpha_j = \min(X_{i,j})$ ， $\beta_j = \max(X_{i,j})$ ， $\alpha_j, \beta_j$  为动态边界，动态边界克服了固定边界难以保存搜索经验的缺点，使精英反向解可以在狭窄的空间中进行搜索，不易陷于局部最优。若动态边界操作使  $\overline{X_{i,j}^e}$  越过边界成为非可行解，可以利用随机生成的方法重置，重置方式如式(6)所示：

$$\overline{X_{i,j}^e} = rand(\alpha_j, \beta_j) \quad (6)$$

### 1.3 算法流程

尽管 ELM 神经网络在多数测试点的定位上表现出高精度，但其权值和阈值的随机生成特性对定位系统的稳定性和精度带来了显著影响，这在实际应用中常常导致过拟合问题。利用遗传算法的优化能力，可以搜索到适合 ELM 神经网络的最佳权值和阈值。这一优化过程基于概率函数，通过选择多个最优点来有效克服 ELM 神经网络所面临的过拟合问题。

本文提出的定位方法融合了一种高效的优化策略与一种快速的 ELM 神经网络学习技术。借助遗传算法，该方法能够筛选出一组更优的初始权重和偏置。遗传算法通过维持种群多样性并结合精英保留策略，能够在较大解空间中进行全局寻优，从而显著降低陷入局部最优的风险。具体而言，算法在每一代进化中通过交叉和变异操作探索新的解区域，并结合适应度评价（均方误差）筛选出性能更优的个体，使得优化过程不易过早收敛于局部次优解。此外，在遗传算法的种群迭代过程中，引入了精英反向学习的策略，通过评估适应度函数来比较常规解与反向解的优劣，进而选择出更优秀的染色体，以此提升所构建种群的质

量。GGA-ELM 的算法流程如图 2 所示。GGA-ELM 算法实现步骤如下：

- (1) 输入样本数据并对其进行归一化；
- (2) 将 ELM 神经网络随机生成的权值和阈值编码后作为遗传算法的初始种群；
- (3) 计算种群的适应度值（本算法使用的适应度函数为均方误差函数。均方误差公式为  $MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$ ，式中  $n$  为样本数， $y_i$  表示真实值， $\hat{y}_i$  表示预测值）；
- (4) 种群个体经过选择、交叉、变异后，将此刻的个体利用精英反向学习策略进行反向解的求解，然后计算适应度，将挑选所得的解中误差较低的部分来组成下一代新种群；
- (5) 经过遗传算法迭代优化后，获得全局近似最优的权值与阈值组合；
- (6) 将解码得到的最优权值和阈值赋给 ELM 神经网络，用于构建地磁定位模型。该模型以地磁序列特征为输入，通过训练好的网络直接输出位置坐标。在地磁定位阶段，采集实时地磁数据并经相同预处理后输入至 GGA-ELM 模型，模型的前向传播输出即对应目标的定位结果。

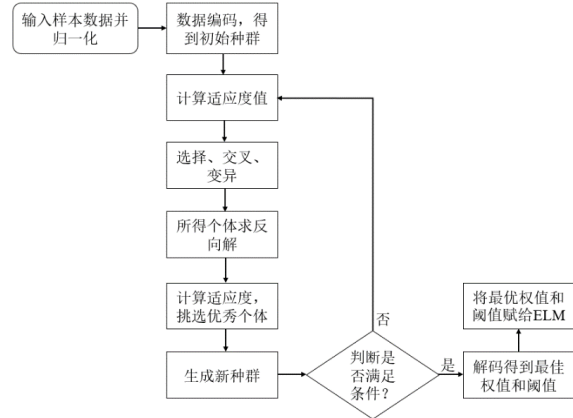


图 2 GGA-ELM 算法流程图  
Fig.2 Flowchart of GGA-ELM algorithm

## 2 数据采集与处理

### 2.1 数据采集

本文采用无人机搭载航磁系统在东南沿海某区域开展航磁测量作业，采集地磁数据。数据采集方式采用倒“S”式，如图 3 所示。本次航空磁测作业系统包括航磁测量系统、日变站观测系统和地面定位系统。航磁测量系统设备包括磁通门测量仪、旋翼无人机和雷达高度计等。除此之外还包括地面磁日变观测的质子磁力仪、地面定位系统的 RTK。在进行中高精度磁测时，需要架设专门仪器并由专人负责观测地磁场全

天变化, 该站点称为地磁日变站。野外地磁日变观测站的选址要选在地磁场相对平缓、远离车辆、人员稀少以及远离一切可能引起地磁场变化因素的地点。地磁日变站的有效控制半径在 200 km~500 km。数据测量系统设备相关性能指标如表 1 所示。




图 3 航磁数据采集路线示意图

Fig.3 Schematic of aeromagnetic data acquisition route

在采集过程中, 无人机飞行高度保持在 129 m 左右, 飞行速度设置为 6 m/s, 磁力仪的采样频率设置为 200 Hz, 数据采集时长为两天。本次采集的原始数据

为总磁场强度  $F$  及每个测点对应的经纬度与姿态数据。通过对总场  $F$  及姿态数据进行处理与解算, 得到了北向分量  $X$ 、东向分量  $Y$  与垂直分量  $Z$  三个地磁分量。水平分量  $H$  可由  $X$  与  $Y$  计算得出。  $X$ 、 $Y$ 、 $Z$  的曲线图如图 4 所示。

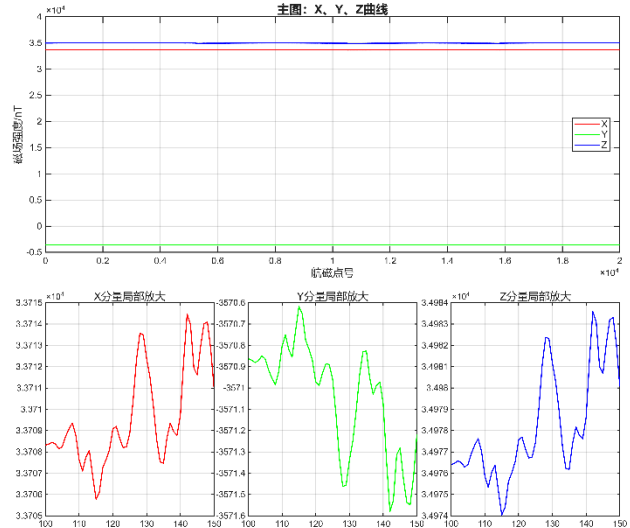


图 4 地磁特征量 X、Y、Z 曲线图

Fig.4 X, Y, Z curves of geomagnetic features

表 1 航磁测量系统设备集成

Tab.1 Integration of equipment for aeromagnetic measurement systems

序号	设备名称	型号	主要功能或性能参数
1	多功能智能化旋翼无人机	DN20-G4	空机重量 6.7 kg; 空载飞行时间 56 min; 抗风能力小于等于 6 级
2	MagDrone 磁通门测量仪	DN-R3	分辨率<0.3 nT; 测量范围为±75000 nT
3	质子磁力仪	GSM-19T	分辨率为 0.01 nT; 动态测量范围为 20000-120000 nT; 采样间隔为 5 s
4	中绘 i70 智能 RTK	DN-PPK	提供无人机的空间位置坐标

## 2.2 数据处理

通过无人机航磁测量系统获取原始地磁数据及其对应的初始三维位置坐标, 并利用地面日变站磁测系统提供的同期日变数据对无人机磁测数据进行日变改正。高精度三维定位系统通过时间匹配, 将初始坐标替换为经 PPK 后处理得到的高精度坐标。在航磁数据处理平台上, 依次进行数据预处理、误差补偿、日变改正及高精度坐标匹配, 最终获得精确的地磁数据及与之对应的高精度三维坐标。

在余姚区域, 共采集了 21 条规划主测线上的航磁数据。所使用的地磁传感器采样频率为 200 Hz, 无人机飞行速度约为 6 m/s, 因此在每条测线上每 1 米范围内可采集约 30 个航磁点数据。为便于后续地磁场分析, 对 21 条主测线上采集的密集航磁点数据进行抽稀处理, 并按测线顺序依次编号。相邻测线间距约为 100 m, 每条测线上相邻航磁点之间的平均距离约为 1.15 m。

将处理后的地磁数据按 8:2 的比例划分为训练集与测试集。每个采样点的地磁特征与位置坐标一一对应。以某一样本点为例, 设其表示为  $X_i = [D_i, P_i]$ , 其中  $D_i$  表示第  $i$  个点的地磁特征量,  $P_i$  表示第  $i$  点对应的位置。

由于地磁要素与位置坐标在量级和单位上存在差异, 为消除量纲影响, 采用 min-max 归一化将原始数据映射至 [0,1] 区间, 归一化公式如式(7)所示:

$$\tilde{X} = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

式(7)中,  $X_{\max}$  是样本数据的最大值,  $X_{\min}$  是样本数据的最小值。

## 3 实验与分析

### 3.1 模型参数设置

本次实验构建了 GGA-ELM 地磁定位方法。输入

数据为地磁特征量，输出数据为位置坐标。在模型训练时，通过滑动窗口将航磁数据序列分割为多个连续的地磁子序列，并为每个子序列划分相应的位置信息。滑动窗口的大小设置为 3 s，预测窗口设置为 7 s，步长为 1 s，意味着每次滑动窗口向前移动 1 s。具体来说，输入数据使用了 3 个地磁特征量，通过历史时刻的 7 s 内的航磁数据来预测未来 1 s 的数据。

在定位模型中，遗传算法种群规模设置为 10。隐藏层节点数和最大迭代次数对模型精度具有显著影响，需通过实验加以优化。最佳迭代次数依据适应度函数收敛行为确定，当迭代次数增加至 15 时适应度趋于稳定（图 5 所示），故设定最大迭代次数为 15。为确定最优隐藏层节点数，采用控制变量法，固定其他参数，调整隐藏层节点数并分析其对 RMSE 和训练时间的影响（图 6 所示）。结果表明，随隐藏层节点数增加，训练时间逐渐延长，而 RMSE 呈现先降后升的趋势，在节点数为 60 时 RMSE 达到最低，因此最终选择隐藏层节点数为 60。




图 5 适应度曲线图  
Fig.5 Fitness graph

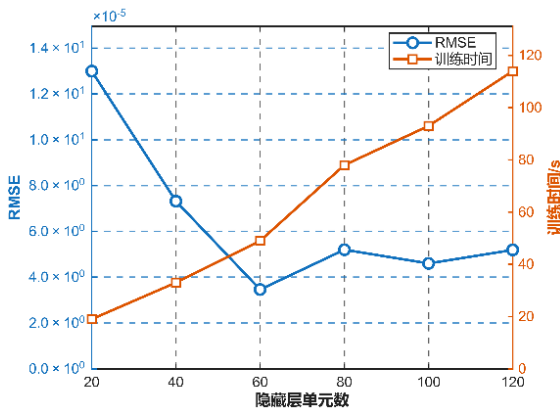


图 6 最佳隐藏层单元选取图

Fig.6 Best hidden layer element selection diagram

### 3.2 地磁特征量的选取实验

在构建地磁定位模型时，地磁特征量的选择需兼

顾信息丰富性与模型复杂度。尽管多特征融合有助于提升模型刻画能力，但若特征数量过多，尤其当部分特征间存在较强相关性时，不仅会显著增加计算负担，还可能引入噪声或冗余，削弱模型的泛化性能。

因此，为实现定位精度与计算效率的平衡，本实验着重筛选信息量丰富、冗余度低、区分度高的特征组合。本小节通过对比不同特征组合下模型的定位表现，以确定最优特征子集，实验结果如表 2 所示。

为全面评估定位算法的性能，需从效率与精度两方面建立评价体系。效率方面主要考虑训练时间与定位时间；精度评价则采用均方根误差 RMSE，平均绝对误差 MAE 和决定系数 R<sup>2</sup>，各指标计算公式如下：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (8)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

其中  $y_i$  表示真实值， $\hat{y}_i$  表示预测值， $\bar{y}$  表示坐标真实值的平均值。RMSE 和 MAE 越小，表明模型的效果越好。R<sup>2</sup> 的范围在 [0,1] 之间，越接近 1，表示模型拟合的效果越好。

表 2 特征量组合选取评价指标对比  
Tab.2 Comparison of evaluation indicators for feature quantity combination selection

序号	特征量组合	RMSE/m	MAE/m	R <sup>2</sup>	训练时间/s
1	X、Y、Z	3.85	2.78	0.99	49
2	X、Y、Z、F、H	5.67	4.82	0.99	52
3	X、Y、F	8.25	7.29	0.99	49
4	X、Y、H	7.51	5.99	0.99	49
5	Y、Z、F	9.26	6.95	0.99	51
6	Y、Z、H	7.11	6.29	0.99	50
7	X、F、H	5.27	4.61	0.99	49
8	Z、F、H	4.61	4.14	0.99	51



(a) Root mean square error for different feature combinations (b) Average absolute error for different feature combinations

图 7 不同组合下预测结果的均方根误差和平均绝对误差柱状图对比

Fig.7 Comparison of root mean square error and mean absolute error histograms of prediction results under different combinations

从表 2 的实验结果可以看出,不同特征量组合下定位模型预测的均方根误差在 3.85 m~9.26 m,平均绝对误差在 2.78 m~6.95 m,决定系数都保持在 0.99。


从图 7 可以看出,组合 1 (X、Y、Z) 的定位模型预测结果与实际值最为接近,这表明 X、Y、Z 这三个特征量在定位模型中起着至关重要的作用,属于核心特征量。当在核心特征量的基础上添加地磁特征量 F 和/或 H 时(如组合 2、7、8),定位精度有所变化,虽然这些组合的决定系数仍然很高,但 RMSE 和 MAE 的增加表明地磁特征量的引入在某些情况下可能引入了冗余信息或干扰,或者它们与核心特征量之间存在复杂的相互作用,导致模型性能下降。另外,组合 7 和组合 8 的定位精度仅次于组合 1, RMSE 相较于组合 1 分别增大了 36.7%和 19.7%,这表明地磁特征量 F 和 H 也可用于在一定范围内对载体位置的唯一标定。组合 2 相较于组合 1 来说, RMSE 增大了 47.1%, MAE

增大了 73.2%,训练时间增大了 6.1%,这表明输入的地磁数据量增加会影响模型的计算效率。

综上,选择组合 1 (X、Y、Z) 作为定位模型的输入特征量。

### 3.3 仿真实验

为了验证所提模型 GGA-ELM 的性能,展开设计以下几种模型进行对比实验: CNN, BiLSTM, RBF, LSTM, GA-ELM, ELM。在这一实验中,模型的输入为过去 7 秒的地磁数据,预测的是接下来的 1 秒钟内的位置坐标。对于每个模型,训练过程中都以“窗口滑动”方式将数据分割成多个时间序列,并使用每个子序列的历史数据来预测当前位置。模型对经度和纬度的预测结果如图 8 和图 9 所示。每个模型均运行 10 次,然后取平均值。最终的评价指标结果如表 3 所示。



(a) 第 1-1500 个点的预测轨迹


(b) 第 490-502 点的局部轨迹放大图

(a) Predicted trajectory from points 1 to 1500

(b) Localized trajectory magnification from points 490 to 502

图 8 纬度方向模型预测轨迹对比

Fig.8 Comparison of predicted trajectories from latitude-direction models



(a) 第 1-1500 个点的预测轨迹 (b) 第 520-580 点的局部轨迹放大图  
 (a) Predicted trajectory from points 1 to 1500 (b) Localized trajectory magnification from points 520 to 580

图 9 经度方向模型预测轨迹对比

Fig.9 Comparison of longitude direction model predicted trajectories

表 3 不同定位模型的预测结果对比

Tab.3 Comparison of prediction results of different localization models

序号	模型	RMSE/m	R <sup>2</sup>	MAE/m	训练时间/s	定位时间/s
1	CNN	20.04	0.94	15.58	189	0.09
2	BiLSTM	11.13	0.98	8.60	220	0.17
3	GGA-ELM	3.87	0.99	2.67	49	0.003
4	LSTM	12.25	0.98	10.48	187	0.13
5	RBF	8.03	0.97	7.96	737	0.95
6	ELM	15.58	0.98	12.25	0.03	0.003
7	GA-ELM	8.35	0.99	6.63	30	0.0035

从图 8 和图 9 可以看出, 在纬度方向上, 从稳定性上来看, 各算法所预测的轨迹波动性都较小, 稳定性都比较高; 从准确性上来看, 模型 3-7 的预测轨迹与实际飞行轨迹吻合度高, 准确性较好, 而模型 1 和 2 的预测轨迹与实际飞行轨迹之间的距离较大, 准确性最差。在经度方向上, 模型 1-7 的预测轨迹都有一定的波动性, 模型 1 的波动性最大; 模型 1、模型 3 和模型 7 的预测轨迹与实际飞行轨迹最为接近, 其中模型 3 的轨迹吻合度最高。

从表 3 的结果可以看出, 各个模型预测的定位误差在 3.87 m~20.04 m, 决定系数在 0.94~0.99, 平均绝对误差在 2.67 m~15.58 m, 定位时间在 0.003 s~0.95 s。模型 3 的预测效果最好, 模型 1 的预测效果最差。模型 3 相较于模型 6 和模型 7, 定位误差分别减小了 86.6% 和 115.9%, 这表明在模型 3 中融入精英反向策略后, 种群质量得到了提升, 成功找到了适合定位算法的最佳权值与阈值, 很好的学习到了地磁特征量与位置之间的映射关系, 模型的预测精度得到了提升。

模型 3 相比于模型 1、2、4、5 来说, 定位误差分别减小了 417.8%, 187.6%, 107.5%, 216.5%, 决定系数分别增大了 5.31%, 1.02%, 1.02%, 2.06%, 训练速

度分别提高了 30 倍, 57 倍, 317 倍和 43 倍。结合图 6 和表 3 来看, 模型 1 在定位的过程中不稳定, 误差波动很大, 对航磁数据的拟合度不高。模型 2 和模型 4 的定位误差相比于模型 1 减小了 80.05% 和 63.59%, 这表明模型 2、4 可以很好的处理长时间的地磁序列依赖关系, 自动提取地磁序列中的地磁语义特征, 但学习地磁序列与位置序列之间的映射规律所用时间很长, 模型效率不高。模型 5 相比于模型 1、2、4, 定位误差减小了 149.6%、38.6%、52.6%, 但需要牺牲很大的模型训练时间, 不适合数据量很大的航磁数据的定位。

### 3.4 多步预测实验

为了评估本文提出的地磁定位算法在动态环境下的多步预测精度与效率, 开展了多步预测实验, 目标是根据历史数据连续预测多个未来时刻的位置。具体来说, 在每个预测步长内, 模型会输出下一个时间点的预测位置, 并将其作为下一个时刻预测的输入数据, 依此类推。比如, 若预测步长为 2 s, 则模型会输出当前位置的预测值, 并基于该预测值再进行一次预测, 依此类推进行连续预测。在实验中保持模型其他参数不变, 仅调整预测步长。实验结果如表 4 所示。

表 4 多步预测评价指标结果

Tab.4 Multi-step prediction of evaluation indicator results

预测步长/步	RMSE/m	训练时间/s	定位时间/s
2	4.02	49	0.004
4	5.33	49	0.004
6	5.92	49	0.004
8	6.58	51	0.003
10	7.56	51	0.003
12	8.27	50	0.003

从表 4 可以看出, 在短步数预测的情况下 ( $\leq 6$  步), 模型预测的定位误差在 4.02 m~5.92 m, 训练时间保持在 49 s, 定位时间保持在 0.004 s, 表明本文提出的地磁定位方法在短时间内能够较为准确地捕捉飞行器的运动状态。随着预测步数的增加, 模型预测的距离误差逐渐增大, 8 步、10 步、12 步预测与 6 步预测相比, 定位误差分别增大了 11.15%、27.7% 和 39.7%, 训练时间分别增大了 4.1%、4.1% 和 2.04%, 这反映出预测误差的累积效应。尽管如此, 模型的定位速度依然保持较高水平, 这表明在较长时间范围内, 环境因素的随机性和不确定性对定位结果的影响显著增强。因此, 选择合适预测步数是提升定位精度的关键因素。

#### 4 结论

本文研究提出了一种基于改进遗传算法优化极限学习机的飞行器地磁定位方法。该方法在遗传算法中引入了精英反向学习策略, 以提升种群的质量, 从而在优化过程中有效寻找适合本算法的最佳权重和阈值, 并将其应用于 ELM 模型, 以实现最佳的定位效果。通过实测数据进行仿真实验, 得出以下结论:

(1) X、Y、Z 是 GGA-ELM 定位方法的最佳地磁特征量组合。

(2) GGA-ELM 地磁定位方法相较于单一的 ELM 及经过遗传算法优化的 GA-ELM, 虽然在训练速度上略有下降, 但其在定位速度上依然保持了高水平, 成功地在定位精度与速度之间实现了优化的平衡。进一步地, 与当前主流的地磁定位算法如卷积神经网络 (CNN)、双向长短期记忆网络 (BiLSTM)、径向基函数网络 (RBF) 以及长短期记忆网络 (LSTM) 相比, GGA-ELM 方法在定位精度与速度两项关键指标上均展现出了最优性能, 充分验证了该方法的有效性和先进性。

(3) 本文提出的 GGA-ELM 地磁定位方法可以适应不同轨迹长度下的位置预测。在实际飞行任务中, 可以根据定位精度要求合理选择预测步长。

需要指出的是, 本文的实验仅在一个相对较小的区域内进行, 未来的研究将考虑在更大样本数据量的基础上进行定位实验, 以进一步验证算法对大尺度区

域的适应性。同时, 未来的研究将探索进一步改进算法, 以提升其在长时间预测中的定位性能, 从而增强飞行器在复杂环境中的导航定位能力。

#### 参考文献 (References):

- [1] 郭迟, 陈毅超, 罗亚荣. 一种世界坐标系下的 GNSS/SINS 松组合导航矩阵李群滤波算法[J]. 中国惯性技术学报, 2024, 32(03): 242-249.  
Guo C, Chen Y, Luo Y. Matrix Lie group filtering algorithm for GNSS/SINS loosely integrated navigation in the world frame[J]. Journal of Chinese Inertial Technology, 2024, 32(03): 242-249.
- [2] 杨文钰, 李东兵, 隋毅, 等. 2020 年国外不依赖卫星的导航技术发展综述[J]. 飞航导弹, 2021, (01): 25-30+70.  
Yang W, Li D, Sui Y, et al. Overview of the development of satellite-independent navigation technology abroad in 2020[J]. Scuderia missile, 2021, (01): 25-30+70.
- [3] 陈棣湘, 陈卓, 张琦, 等. 航空平台地磁矢量匹配导航算法研究进展[J]. 中国测试, 2024, 50(05): 1-10.  
Chen D, Chen Z, Zhang Q, et al. Research progress on geomagnetic vector matching navigation algorithm for aerospace platforms[J]. China Test, 2024, 50(05): 1-10.
- [4] 陆一, 魏东岩, 纪新春, 等. 地磁定位方法综述[J]. 导航定位与授时, 2022, 9(02): 118-130.  
Lu Y, Wei D, Ji X, et al. Overview of geomagnetic positioning methods[J]. Navigation, positioning and timing, 2022, 9(02): 118-130.
- [5] 王崇兵, 范荣双, 李大伟, 等. 一种改进混沌蚁群的地磁匹配算法[J]. 导航定位学报, 2022, 10(03): 116-122.  
Wang C, Fan R, Li D, et al. A geomagnetic matching algorithm with improved chaotic ant colony[J]. Journal of Navigation and Positioning, 2022, 10(03): 116-122.
- [6] 付希禹, 孙永荣, 李荣冰. 基于 MSD 和 ICCP 改进的地磁联合匹配算法[J]. 南京航空航天大学学报, 2021, 53(06): 928-933.  
Fu X, Sun Y, Li R. Improved geomagnetic joint matching algorithm based on MSD and ICCP[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2021, 53(06): 928-933.
- [7] Carrillo D, Moreno V, Úbeda B, et al. Magicfinger: 3d magnetic fingerprints for indoor location[J]. Sensors, 2015, 15(7): 17168-17194.
- [8] Gnadt A. Machine learning-enhanced magnetic calibration for airborne magnetic anomaly navigation[C]//AIAA SciTech 2022 Forum. 2022: 1760.
- [9] Al-Homayani F, Mahoor M. Improved indoor geomagnetic field fingerprinting for smartwatch localization using deep learning[C]//2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN). France, September 24-27, 2018: 1-8.
- [10] Bae H J, Choi L. Large-scale indoor positioning using geomagnetic field with deep neural networks[C]//ICC 2019-2019 IEEE International Conference on Communications (ICC). China, May 20-24, 2019: 1-6.
- [11] 刘岳峰, 郑培晨. 一种基于贝叶斯估计的地磁辅助惯性导航算法[J]. 北京大学学报: 自然科学版, 2017, 53(5): 873-880.  
Liu Y, Zheng P. A geomagnetically assisted inertial navigation algorithm based on Bayesian estimation[J]. Journal of Peking University: Natural Science Edition, 2017, 53(5): 873-880.
- [12] Cuenca A, Moncayo H. Machine learning application to estimation of magnetospheric contributions for geomagnetic-based navigation[C]//AIAA SCITECH 2022 Forum. San Diego, January 3-7, 2022: 1714.
- [13] Chen K, Laghrouche S, Djerdir A. Degradation model of proton exchange membrane fuel cell based on a novel hybrid method[J]. Applied Energy, 2019, 252: 113439.
- [14] Al-Khaleefa A S, Ahmad M R, Isa A A M, et al. Knowledge preserving OSELM model for Wi-Fi-based indoor localization[J]. Sensors, 2019, 19(10): 2397.