

神经网络拟合的激光陀螺惯组重力实时测量滤波

高春峰^{1,2},程嘉奕^{1,2},陈迈伦^{1,2},魏国^{1,2},罗晖^{1,2},侯承志^{1,2},朱旭^{1,2},马海阳^{1,2},王景^{1,2*}
(1. 国防科技大学 前沿交叉学科学院, 湖南 长沙 410073; 2. 国防科技大学 南湖之光实验室, 湖南 长沙 410073)

摘要:为了解决激光陀螺惯组重力测量系统中传统重力滤波方法的固定长时延问题,提出一种基于神经网络拟合滤波的重力数据实时处理方法,通过对有限长单位冲激响应(finite impulse response, FIR)滤波器进行神经网络拟合,降低对未来数据的长依赖,从而有效减少滤波时延。实验结果表明,与FIR滤波器相比,该方法的处理时延降低了93%,平均滤波精度优于2 mGal,表明所提方法在保持较高精度的同时显著提升了数据处理的实时性,为激光陀螺惯组重力测量系统的实时重力测量提供了解决方案。

关键词:重力测量;神经网络;FIR低通滤波;实时处理;重力数据处理

中图分类号:V241.5+58 文献标志码:A 文章编号:1001-2486(2025)05-070-08



Real-time gravity measurement filtering of laser gyro inertial group fitted by neural network

GAO Chunfeng^{1,2}, CHENG Jiayi^{1,2}, CHEN Mailun^{1,2}, WEI Guo^{1,2}, LUO Hui^{1,2}, HOU Chengzhi^{1,2}, ZHU Xu^{1,2}, MA Haiyang^{1,2}, WANG Jing^{1,2*}

(1. College of Advanced Interdisciplinary Studies, National University of Defense Technology, Changsha 410073, China;
2. Nanhu Laser Laboratory, National University of Defense Technology, Changsha 410073, China)

Abstract: To overcome the inherent fixed time-delay limitation of conventional gravity filtering methods in laser gyro-based inertial navigation gravity measurement systems, a real-time gravity data processing method based on neural network-approximated FIR (finite impulse response) filtering was proposed. By fitting the FIR filter through neural network implementation, the long dependency on future data was effectively reduced, thereby effectively reducing filtering delay. Experimental results show that compared with the FIR filter, the processing delay of the proposed method is reduced by 93%, and the average filtering accuracy is better than 2 mGal. This indicates that the proposed method can significantly improve the real-time performance of data processing while maintaining high accuracy, providing a solution for the real-time gravity measurement of the laser gyroscope inertial group gravity measurement system.

Keywords: gravity measurement; neural network; FIR low-pass filtering; real-time processing; gravity data processing

在动态连续重力测量中,由于载体在运行过程中受加减速、中高频振动、环境因素等影响,激光陀螺惯性基系统原始重力异常数据中包含大量噪声^[1]。重力异常信号基本集中在低频段,所占频带很窄,而噪声的幅值较大,在频带内的分布较宽且大多在高频段^[2]。由于重力异常信号与噪声信号混叠在一起,需要采用低通滤波器对计算得到的重力数据进行处理,才能有效去除高频噪声,获得逼近真实的重力异常信号。目前,在重力数据处理过程中,有多种滤波技术可供选择,其中

较为常用的包括有限长单位冲激响应(finite impulse response, FIR)低通滤波、无限脉冲响应(infinite impulse response, IIR)低通滤波、卡尔曼滤波和小波滤波等。其中,最通用的为FIR数字滤波器^[3],可以满足实时性的为卡尔曼滤波^[4]。

然而,传统滤波方法在实际应用中存在一些局限性。卡尔曼滤波方法的建模方式在不同的测量仪器与测量区域之间会有所不同,不同数据性质也会对结果产生不同的影响,因此使用卡尔曼滤波器获得重力数据时需要针对测量仪器、测量

收稿日期:2025-01-13

基金项目:国家自然科学基金资助项目(62203454)

第一作者:高春峰(1989—),男,山东济南人,副研究员,博士,E-mail:neil1989@126.com

*通信作者:王景(1997—),男,甘肃张掖人,博士研究生,E-mail:jingwang.ac@nudt.edu.cn

引用格式:高春峰,程嘉奕,陈迈伦,等.神经网络拟合的激光陀螺惯组重力实时测量滤波[J].国防科技大学学报,2025,47(5):70-77.

Citation:GAO C F, CHENG J Y, CHEN M L, et al. Real-time gravity measurement filtering of laser gyro inertial group fitted by neural network[J]. Journal of National University of Defense Technology, 2025, 47(5): 70-77.

区域、测量数据类型等展开大量研究工作,不能简单套用某一模型,且其精度和适用性有待进一步验证^[5]。FIR 数字滤波器虽然相比其他滤波方式具有更高精度,然而其需要使用一组对称的系数来实现线性相位响应,导致输出信号相对于输入信号产生固定时延,在重力测量领域通常在百秒量级。随着日益增长的实时性重力测量的需求,百秒的时延已经无法满足重力测量的实时性需求。因此,传统滤波方法在高精度、高适用性与高实时性之间存在冲突,难以同时满足重力匹配等测量应用场景对重力异常信息实时性和精度较高的需求。

为了解决上述问题,结合神经网络的非线性学习能力,提出一种基于神经网络拟合 FIR 低通滤波器的重力数据实时处理方法 SimFIR-NN (simulated FIR with neural network)。该方法通过建立神经网络和中心对称滤波器的拟合关系,挖掘滤波数据与原始数据之间的短依赖关系,利用大量重力原始数据与经过 FIR 低通滤波处理后的数据训练出 FIR 低通滤波拟合模型。利用该模型可以在保持滤波精度的同时极大降低固定时延,提高数据过滤实时性。

1 基于神经网络的 FIR 滤波器拟合描述

FIR 低通数字滤波器是一种基于有限长度脉冲响应的线性时不变系统,其输出仅依赖于当前及过去的有限个输入值,系统函数可表示为:

$$H(z) = \sum_{k=0}^M h(k)z^{-k} \quad (1)$$


式中, $h(k)$ 为滤波器系数, M 为滤波器阶数, z^{-k} 表示将信号延迟 k 个采样周期。FIR 滤波器通过设计对称的系数 $h(n) = h(M - n)$ 能够实现严格的线性相位特性,确保信号通过滤波器后无相位失真。在重力数据处理中, FIR 低通滤波器常用于分离低频重力异常信号与高频噪声,其截止频率和阶数的选择至关重要,直接影响实时性、滤波后重力异常的分辨率以及数据的内符合精度。因此,截止频率的优化需在噪声抑制、信号保留与实时性之间取得平衡。具体而言,截止频率 f_c 的选择应该兼顾载体行驶速度 v 和重力数据的空间分辨率 λ ,三者之间的关系^[6-7]可表示为:

$$\lambda = \frac{v}{2f_c} \quad (2)$$

在车载重力测量中,载体运行速度通常低于 40 km/h。为保证空间分辨率和滤波精度,一般采用截止频率为 0.3 Hz 的 601 阶 FIR 低通滤波器,


并通过加窗函数设计实现过渡带宽度与阻带衰减的优化平衡^[8]。然而,这种线性相位特性会引入固定的时延,即信号通过滤波器后会产生 $\tau = M/2$ 个采样点的延迟^[9]。在车载重力测量中,采样频率通常为 1 s,采用上述参数会导致滤波数据产生 300 s 的时延,尤其在动态测量场景中,严重影响数据处理的实时性。如何在保证滤波性能的同时降低时延,成为车载重力测量中滤波器设计的关键问题。

因此,本研究提出基于神经网络的 FIR 滤波器滤波过程拟合方法,以 300 s 周期的 FIR 滤波器设置参数为基准,设计一种适合重力数据特性的神经网络结构。该网络通过学习 FIR 滤波器的输入-输出映射关系,利用过去 300 个采样点数据及未来 20 个采样点数据作为输入特征,直接预测当前时刻的滤波值。通过这种方式,将未来数据依赖量从 FIR 滤波方法的 300 s 压缩至 20 s,同时保持滤波精度。该过程基本示意图如图 1 所示。



(a) FIR 滤波器滤波过程示意图

(a) Schematic diagram of the filtering process of FIR filter



(b) 神经网络拟合滤波器过程示意图

(b) Schematic diagram of the process of neural network fitting filter

图 1 FIR 滤波器与神经网络拟合滤波过程示意图

Fig. 1 Schematic diagram of the FIR filter and neural network fitting filtering process

神经网络对 FIR 滤波器滤波过程的拟合实现,依赖于大量数据对网络模型进行训练。由于神经网络无法直接学习到滤波过程的数学表达,因此需要通过 FIR 滤波器对原始数据进行处理,并将滤波后的结果作为真值标签,用于约束网络的训练过程。通过构建输入-输出映射关系,神经网络能够从原始重力数据与 FIR 滤波后数据的对应关系中挖掘潜在的映射规律,从而实现对滤波过程的拟合。

2 SimFIR-NN 神经网络模型结构及参数设计

多层感知机(multilayer perceptron, MLP)是一种基础且功能强大的神经网络结构,广泛应用于各种机器学习任务中^[10-11]。其主要由输入层、隐藏层和输出层构成,是一种全连接神经网络。MLP 的每一层都由多个节点组成,层与层之间的节点完全连接。输入层负责接收数据,每个节点对应一个输入特征;输入层将数据传递到隐藏层,隐藏层可以包含一层或多层,每个节点通过加权求和操作并结合非线性激活函数(如 ReLU、Sigmoid 或 Tanh 等)进行特征变换,从而赋予网络学习复杂模式的能力^[12];输出层的节点数通常与任务的输出维度一致,用于生成最终的预测结果。通过这种分层结构,MLP 能够从输入数据中提取多层次特征并实现复杂的非线性映射。

针对重力数据处理设计了一个五层的 MLP,称为 SimFIR-NN 模型,通过建立输入数据与 FIR 滤波真值间的非线性映射关系,实现 FIR 滤波器的智能拟合。SimFIR-NN 采用倒金字塔结构的节点数目设计,旨在从高维度数据中逐步提取由粗粒度到细粒度的特征,从而更好地服务于输入与输出之间映射关系的建立。SimFIR-NN 的具体模型结构如图 2 所示。




图 2 SimFIR-NN 模型结构示意图

Fig. 2 SimFIR-NN model structure diagram

设 SimFIR-NN 的五层神经元数目分别为 N_1 、 N_2 、 N_3 、 N_4 、 N_5 , 连接权值为 w , 偏置项为 b , 激活函

数为 f , 则输入层第 i 个神经元与隐藏层第 j 个神经元的连接权值为 w_{ij} , 偏置项为 b_{ij} ; 前一个隐藏层 l 的第 m 个神经元和后一个隐藏层 $l+1$ 的第 n 个神经元的连接权值为 w_{lmn} , 偏置项为 b_{ln} ; 隐藏层第 p 个神经元和输出层第 q 个神经元的连接权值为 w_{4pq} , 偏置项为 b_{4q} ; 则中间第 l 隐藏层的输出如下:

$$o_l = \begin{cases} f_{1j}(\sum_{i=1}^{N_1} w_{1ij}x_i + b_{1j}) & l = 1 \\ f_{ln}(\sum_{m=1}^{N_l} w_{lmn}o_{l-1} + b_{ln}) & 1 < l \leq 3 \end{cases} \quad (3)$$

输出层的输出如下:

$$y = f_{4q}(\sum_{p=1}^{N_4} w_{4pq}o_l + b_{4q}) \quad (4)$$

SimFIR-NN 模型的具体配置为五层全连接网络,神经元配置遵循 321—100—50—10—1 的逐层递减模式。其中输入层融合 300 个历史点与 20 个未来点的时空特征,三个隐藏层通过 ReLU 激活函数完成多尺度特征提取,输出层采用线性激活实现滤波值回归。

神经网络的参数集合由权重 w 、偏置项 b 、神经元数目 N 和其他相关参数组成。通过在大规模数据集上学习已知的输入与输出数据,利用损失函数进行优化训练,逐步降低预测输出与真实输出之间的损失值 ε ,并不断调整这些可训练参数,使预测输出与真实输出之间的误差逐渐减小,从而实现输入到输出的映射拟合^[13-15]。在训练过程中,采用均方误差(mean square error, MSE)作为损失函数来约束模型的收敛方向,其定义如式(5)所示:

$$\varepsilon_{\text{MSE}}(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N \|y_i - \hat{y}_i\|^2 \quad (5)$$

式中: y 为 SimFIR-NN 模型输出的滤波结果; $\hat{y}$ 为 FIR 滤波器得到的结果,即为真值标签。

3 SimFIR-NN 模型训练及测试数据集构建

训练数据来源于 2023 年 5 月在中国湖南省长沙市黑麋峰使用课题组自研的激光陀螺重力仪采集的实测数据^[16]。实验以车辆为测量平台,激光陀螺重力仪由惯性导航系统、卫星导航系统、激光多普勒测速仪、导航计算机及电源等设备组成。其中,捷联惯导系统由实验室自研,激光陀螺精度优于 $0.003 (^{\circ})/\text{h}$,加速度计精度优于 $10 \mu\text{g}$,加速度组件温度控制精度优于 $0.005 ^{\circ}\text{C}$,采样频率为 100 Hz;激光多普勒测速仪也由实验室自研,测速

仪的测速精度优于 1‰,采样频率为 100 Hz;GNSS 的定位精度优于 0.4 m,输出频率为 1 Hz;车内温度控制在 26 ℃左右。

选取实验中 5 次单条重复测线的重力测量数据作为模型训练与可行性分析的基础数据。原始测量数据需基于第 1 节所述的 FIR 滤波器拟合原理进行预处理,以构建符合神经网络输入的规范化数据集。

首先使用 300 s FIR 滤波器对原始重力数据进行预处理,生成真值数据标签。为适配神经网络模型的输入需求,对每条测线数据进行滑窗分割:以 t 时刻为中心,截取其前 300 个和后 20 个采样点,构成长度为 321 的数据输入样本,并以 t 时刻对应的 FIR 滤波值作为真值标签,形成一个样本对。通过系统化处理所有数据,最终构建包含 7 895 个样本对的数据集,该过程如图 3 所示。该数据集充分融合了重力信号的时空关联特性,为 SimFIR-NN 模型的训练与参数优化提供了高质量的数据支持。




图 3 数据集构建过程示意图

Fig. 3 Diagram of the data set construction process

在数据集划分阶段,首先单独提取一条测线数据独立构成测试集,不参与训练调参。剩余测线数据统一作为训练集候选池,从中按 8 : 2 比例随机划分训练集和验证集。以上训练和验证过程进行 10 次重复,取平均值作为结果,避免因单次随机种子导致训练集/验证集划分偏差,从而防止产生过拟合特定数据划分的超参数配置和模型状态。

设置样本批次大小为 64,学习率为 0.000 1,最大迭代次数为 850,使用 NAdam 优化器进行优化。实验运行在带有 Intel Xeon W - 2104 @ 3.2 GHz 型号 CPU 的计算工作站上,运行环境 64 位 Windows10 操作系统,算法模型使用带有 PyTorch1.12.0 的 Python3.7 进行编写运行。为了对所提方法进行评估,选取平均绝对误差 (mean absolute error, MAE) 指标对模型预测值和真值之间的误差进行评估:

$$\varepsilon_{\text{MAE}}(y, \hat{y}_i) = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (6)$$

4 实验结果分析

4.1 训练过程分析

神经网络的训练过程至关重要,网络模型的性能好坏需要在训练过程中关注损失曲线的情况来判断,本小节绘制了训练过程的损失曲线来观察模型训练情况,如图 4 所示。




图 4 SimFIR-NN 模型训练过程示意图

Fig. 4 SimFIR-NN model training process diagram

由图 4 可见,模型在训练至 350 次时已达到初步收敛,但由于所提的任务是一种回归预测任务,对模型稳定性的要求较为严格,所以需要加大训练迭代次数。根据局部细节图中黑色水平线的趋势拟合可以看出,在大约迭代至 700 次时模型可稳定收敛。尽管 700 次后损失曲线在微观尺度仍存在小幅振荡,但其宏观波动幅度已趋近于收敛阈值,且预测值与真值的泛化误差稳定在极低水平,验证了神经网络拟合 FIR 滤波过程的可行性。需注意的是,尽管训练的过程耗时较长,但训练模型本身属于事前准备阶段的工作,训练后的模型在工作状态下的推理调用是极快的,表明该方法在工程实践中具备应用价值。

4.2 超参数敏感分析

训练超参数对模型性能具有显著影响。为确定最优参数配置,本研究基于控制变量法,分别从学习率和批次大小两个维度开展对比实验,结果如表 1、表 2 所示。按照神经网络领域的设置经验,将学习率设置在 [0.000 05, 0.000 5] 之间,样本批大小设置在 [32, 128] 之间。在学习率为 0.000 1 的情况下,样本批大小选择 64 时,模型收敛稳定性显著优于其他配置,且与目前主流深度学习中所设置的批大小一致。固定样本批大小,探讨不同的学习率设置,可发现学习率设置为 0.000 1 可使训练过程稳定收敛,设置过大将导致损失函数振荡,设置过小则显著延长收敛时间。因此合适的训练超参数应选择样本批大小为 64、学习率为 0.000 1。

表 1 样本批大小参数分析结果

Tab. 1 Sample batch size parameter analysis results

批大小	损失值
32	0.000 10
64	0.000 04
128	0.000 05

表 2 学习率参数分析结果

Tab. 2 Learning rate parameter analysis results

学习率	损失值
0.000 05	0.000 04
0.000 1	0.000 04
0.000 5	0.000 09

4.3 拟合结果分析

将训练好的神经网络模型使用测试专用的测线数据进行了有效性验证,用 MAE 指标进行评估,综合选取了训练 10 次后的测试结果取平均值,结果如表 3 所示。可以看出,模型预测的结果和真实的结果差距较小,波动也很小,说明了拟合效果较好。同时,对预测的滤波曲线和真实 FIR 滤波曲线的结果做了可视化输出,如图 5 所示,从图中可以看出拟合效果较好,趋势的拟合相对准确。由此说明提出的 SimFIR-NN 模型的预测准确性与稳定性较高。

表 3 10 次模型验证结果及平均值

Tab. 3 Results and average values of ten times of model validation

验证序号	$\varepsilon_{MAE}/mGal$
1	0.004 602 8
2	0.004 523 3
3	0.004 595 8
4	0.004 518 9
5	0.004 563 5
6	0.004 547 8
7	0.004 592 1
8	0.004 543 1
9	0.004 528 7
10	0.004 516 4
平均值	0.004 553 2




图 5 SimFIR-NN 模型预测结果示意图

Fig. 5 Schematic diagram of SimFIR-NN prediction results

4.4 实验预测结果分析


为了验证 SimFIR-NN 模型的适用性,选择在中国湖北神农架地区展开车载重力测量实验,通过 SimFIR-NN 模型与 FIR 滤波方式分别对重力测量数据进行处理,并将两种重力滤波结果进行对比验证。

在重力测量实验中,测量设备与第 3 节所述设备一致,唯一区别在于测速仪的安装位置由实验车底部改为侧方,具体安装示意图如图 6 所示。



(a) 实验车外部安装图片

(a) External installation diagram of the experimental car



(b) 实验车内部安装图片

(b) Experimental car interior installation diagram

图 6 设备安装示意图

Fig. 6 Equipment installation diagram

实验地点单条测线的路程约为 29 km,共选取 1 376 个重力异常点,沿途海拔变化约为 1 047 m,重力异常变化范围约为 90 mGal。实验车辆以约 30 km/h 的速度行驶,单次测线全程耗时约 57 min,共进行了 4 次重复测线实验,实验路径规划如图 7 所示。




图 7 实验轨迹


Fig.7 Experimental trajectory

将系统解算出的重力异常结果分别进行 300 s 的 FIR 低通滤波处理和 SimFIR-NN 神经网络预测处理,处理后的结果如图 8 所示。由图 8 可以看出,SimFIR-NN 模型的预测结果与 FIR 滤波结果的变化趋势高度一致,且两者在数值上吻合较好。

为了验证 SimFIR-NN 模型预测值的有效性,分别对 4 条测线重力异常滤波结果的预测值和真实值进行了可视化输出,如图 9 所示。图 9 可更直观地看出,4 条测线的预测结果均具有较高准确性。同时,选取 FIR 滤波器计算的结果作为真




(a) FIR 低通滤波结果
(a) FIR filtering results




(b) SimFIR-NN 模型预测结果
(b) Prediction results of SimFIR-NN model

图 8 FIR 和 SimFIR-NN 处理后的重力异常数据
Fig.8 Gravity anomaly data processed by
FIR filter and SimFIR-NN model


值,用 MAE 指标对 4 条测线的神经网络预测结果进行评估,结果如表 4 所示。可以看出,模型预测的结果和真实的结果差距均在 2.5 mGal 以内,波动也很小,平均预测误差在 2 mGal 左右,充分证




(a) 测线 1
(a) Line 1



(b) 测线 2
(b) Line 2



(c) 测线 3
(c) Line 3



(d) 测线 4
(d) Line 4

图 9 SimFIR-NN 模型在四条测线中的拟合结果
Fig. 9 Fitting results of SimFIR-NN model in four measurement lines

表 4 SimFIR-NN 模型的预测误差

Tab. 4 Prediction error of SimFIR-NN model

测线	$\varepsilon_{\text{MAE}}/\text{mGal}$
测线 1	1.211 4
测线 2	2.437 6
测线 3	2.014 5
测线 4	1.988 8
平均值	1.913 1

明了 SimFIR-NN 模型具有较高的稳定性和可靠性。

为评估重力测量系统的性能,通常采用重复测线内符合精度评估方法。由于 4 次测量过程中难以保证车辆行驶速度和位置完全一致,不同测线结果可能存在水平偏移,因此需对数据进行平差处理后方可进行内符合精度评估。内符合精度

通过以下步骤计算:

1) 计算 4 条测线测点的重力算术平均值构建基准测线;

2) 计算各测线与基准测线间各个测点的残差序列;

3) 利用公式 $RMS = \sqrt{\frac{\sum_{i=1}^n \Delta g_i^2}{n}}$ 计算单条测线

的均方根 (root mean square, RMS), 其中 Δg_i 为第 i 个测点的重力残差, n 为测点总数;

4) 利用公式 $RMS_{\text{总}} = \sqrt{\frac{\sum_{j=1}^m \sum_{i=1}^n \Delta g_{ij}^2}{m \cdot n}}$ 计算所有

测线的总内符合精度, 其中 g_{ij} 为第 j 条重复测线上第 i 个测点的重力残差, n 为测线公共段观测点数量, m 为重复测线的条数。

对平差后 300 s 的 FIR 滤波器处理数据和 SimFIR-NN 模型预测数据分别进行内符合精度评估, 结果分别如表 5 和表 6 所示。结果表明, FIR 滤波方法计算的系统总内符合精度为 1.08 mGal, 而 SimFIR-NN 模型预测方法计算的系统总内符合精度为 1.81 mGal, 两者仅相差 0.73 mGal。这一结果说明, SimFIR-NN 神经网络过滤的重力异常数据能够有效用于内符合精度评估, 且其性能接近传统 FIR 滤波器。

表 5 基于 FIR 滤波器的重力测量内符合精度

Tab. 5 Internal coincidence accuracy of gravity measurement based on FIR filter

单位: mGal

测线	最大值	最小值	RMS	总体 RMS
测线 1	2.15	-4.38	1.72	1.08
测线 2	1.23	-1.34	0.66	
测线 3	1.84	-1.44	0.76	
测线 4	1.60	-1.19	0.86	

表 6 基于 SimFIR-NN 模型的重力测量内符合精度

Tab. 6 Internal coincidence accuracy of gravity measurement based on SimFIR-NN model

单位: mGal

测线	最大值	最小值	RMS	总体 RMS
测线 1	3.88	-5.07	2.67	1.81
测线 2	1.91	-1.83	1.02	
测线 3	2.24	-3.16	1.25	
测线 4	3.40	-3.67	1.86	

5 结论

针对传统 FIR 低通滤波器存在的固定长时延、难以实时处理的局限性,提出了采用神经网络拟合 FIR 滤波器的滤波方法,以多层感知机原理为基础,设计了一个基于五层神经网络的 FIR 滤波器拟合模型 SimFIR-NN。在神经网络的 FIR 滤波器拟合原理基础上,设计了 SimFIR-NN 的结构和参数,构建了模型训练及测试数据集,并通过半实物仿真实验对训练过程、超参数敏感和拟合结果进行分析验证,通过实验对 SimFIR-NN 模型的适用性与精度进行验证。结果表明提出的神经网络拟合 FIR 滤波器的方法使重力异常测量的时延由 300 s 降低至 20 s,同时具有较高的精度与适用性,有效提升了激光陀螺惯组重力测量系统的实时测量能力。

此次研究主要探索了拟合神经网络在重力数据实时处理中的应用,设计了以神经网络为基础的 MLP 类神经网络,后续研究人员可根据实验任务的模式,设计更为有效的网络以满足实验需求。未来的研究将进一步探究增量学习模型在重力数据实时处理中的应用,进一步提高拟合神经网络在工程应用中的可行性。此外,拟合神经网络的数据处理思路也可尝试与其他滤波方法结合以提升性能,并探索其在地震监测、海洋重力测量等更复杂测量场景下的应用潜力。

参考文献 (References)

[1] AI W Y, ZHONG S, LENG Y, et al. A real-time autonomous gravity measurement method for underwater gravity-aided navigation[J]. IEEE Access, 2023, 11: 135728 – 135737.

[2] BRUTON A M. Improving the accuracy and resolution of SINS/DGPS airborne gravimetry [D]. Calgary: University of Calgary, 2000.

[3] 蔡劭琨, 吴美平, 张开东. 航空重力测量中 FIR 低通滤波器的比较[J]. 物探与化探, 2010, 34(1): 74 – 78.

CAI S K, WU M P, ZHANG K D. A comparison of digital lowpass FIR-filters in airborne gravimetry [J]. Geophysical and Geochemical Exploration, 2010, 34(1): 74 – 78. (in Chinese)

[4] 张平. 基于最优参数估计的海洋重力数据处理方法研究[D]. 南京: 东南大学, 2017.

ZHANG P. Research on marine gravity data processing

method based on optimum parameters estimation [D]. Nanjing: Southeast University, 2017. (in Chinese)

[5] 蔡体菁, 颜颖, 王新宇. 捷联航空重力测量中的卡尔曼滤波[J]. 压电与声光, 2019, 41(3): 436 – 439.

CAI T J, YAN Y, WANG X Y. Kalman filtering of strapdown airborne gravity measurement [J]. Piezoelectrics & Acoustooptics, 2019, 41(3): 436 – 439. (in Chinese)

[6] 黄漠涛, 刘敏, 欧阳永忠, 等. 重力场对飞行器制导的影响及海洋重力测线布设[J]. 测绘学报, 2016, 45(11): 1261 – 1269.

HUANG M T, LIU M, OUYANG Y Z, et al. Effect of external disturbing gravity field on spacecraft guidance and surveying line layout for marine gravity survey [J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(11): 1261 – 1269. (in Chinese)

[7] HOU C Z, CHENG J Y, ZHU X, et al. Vehicle-borne gravity vector measurement method based on SINS/GNSS/LDV integrated navigation [J]. IEEE Access, 2024, 12: 170610 – 170619.

[8] XIONG Z M, WU M P, CAO J L, et al. An underwater gravimetry method using inertial navigation system and depth gauge based on trajectory constraint [J]. IEEE Geoscience and Remote Sensing Letters, 2021, 18(9): 1510 – 1514.

[9] MEYER-BAESE U. Digital signal processing with field programmable gate arrays [M]. 2nd ed. [S.l.]: Springer, 2004: 60 – 66, 112 – 113.

[10] ZHOU S, LIU X, GUO J Y, et al. Bathymetry of the gulf of Mexico predicted with multilayer perceptron from multisource marine geodetic data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 4208911.

[11] BASHEER I A, HAJMEER M. Artificial neural networks: fundamentals, computing, design, and application [J]. Journal of Microbiological Methods, 2000, 43(1): 3 – 31.

[12] DUBEY S R, SINGH S K, CHAUDHURI B B. Activation functions in deep learning: a comprehensive survey and benchmark [J]. Neurocomputing, 2022, 503: 92 – 108.

[13] WANG J J, LI Y L, ZHAO R, et al. Physics guided neural network for machining tool wear prediction [J]. Journal of Manufacturing Systems, 2020, 57: 298 – 310.

[14] SHEN S, LU H, SADOUGHI M, et al. A physics-informed deep learning approach for bearing fault detection [J]. Engineering Applications of Artificial Intelligence, 2021, 103: 104295.

[15] RUSSELL M, WANG P. Physics-informed deep learning for signal compression and reconstruction of big data in industrial condition monitoring [J]. Mechanical Systems and Signal Processing, 2022, 168: 108709.

[16] CHENG J Y, HOU C Z, ZHU X, et al. Vehicle dynamic continuous gravimetry technology based on high-precision 2-D LDV and GNSS [J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 7508005.