DOI:10.14075/j.jgg.2024.09.421

文章编号:1671-5942(2025)10-1065-06

双通道 BP 神经网络在几内亚湾海底地形反演中的应用

刘 浩[1,2] 袁佳佳[1,2] 杨 晨[1] 董 迪[2,3] 于道成[4] 仵振东[5]

1 安徽理工大学空间信息与测绘工程学院,安徽省淮南市泰丰大街 168 号,232001
2 自然资源部海洋环境探测技术与应用重点实验室,广州市新港西路 155 号,510300
3 国家海洋局南海规划与环境研究院,广州市新港中路 353 号,510300
4 辽宁工程技术大学测绘与地理科学学院,辽宁省阜新市玉龙路 88 号,123000
5 池州学院地理与规划学院,安徽省池州市牧之路 199 号,247000

摘 要:提出一种基于双通道 BP 神经网络的海底地形反演方法,结合重力异常数据(包含长、短波重力异常和残差长、短波重力异常)和船载测深数据,对几内亚湾海底地形进行反演。将反演结果分别与重力地质法反演结果及 GEBCO_2023 和 Topo_25.1 模型进行比较,结果表明,基于双通道 BP 神经网络的反演精度优于其他模型。本文研究结果可为深度学习在海洋大地测量中的应用提供新思路,同时提升海底地形反演精度。

关键词:BP 神经网络;海底地形;重力异常;GEBCO_2023;Topo_25.1

中图分类号:P223 **文献标识码**:A

精确的海底测绘资料在海洋运输、海岸管理、资源开发、政策制定和环境保护等领域具有关键的支持作用和深远意义[1]。当前海底测绘主要以船基声呐探测技术为主,虽然该方法精度较高,但存在数据获取周期长、测量覆盖范围有限、成本高昂等问题,难以满足大范围、高效率的海底地形测绘需求[2-4]。卫星测高技术可为海底地形反演提供一种全新的方法,已逐渐成为海底测绘的重要补充手段[1,4]。

卫星测高技术间接获取海底地形的主要理论依据是卫星测高数据获得的海洋重力场信息与海底地形起伏之间存在强相关性[3-4]。基于该理论衍生出许多海底地形反演方法,如重力地质法(GGM)[5]、Sandwell 法[6]等。许多海底地形反演方法虽然都能在一定程度上得到很好的反演结果,但或多或少存在一定缺陷,且大多数反演方法只考虑海洋重力场与海底地形之间的线性相关性,却很少顾及两者之间的非线性相关性,而纯数据驱动的深度学习方法可以忽略这种物理联系,为挖掘水深与重力之间的非线性关系提供可能。

研究表明,深度学习能够有效提升海底地形反演精度,但主要是将深度学习算法融合重力异常、重力梯度异常或垂线偏差等数据进行海底地形反演[7-11]。实际上,重力场信号中的短波重力信号与海底地形之间具有强相关性[1],因此本文利用双通道 BP 神经网络,将重力场信号分为长、短波重力信号和残差长、短波重力信号,同时将船载测深数据作为训练样本,训练双通道 BP 神经网络海底地形反演模型,反演几内亚湾海底地形,以期为深度学习在海洋科学领域的应用提供参考。

1 研究区及数据

1.1 研究区概况

本文以几内亚湾(15°S~5°N, 10°W~10°E)海域为研究区(图 1),该区位于大西洋热带地区和非洲板块西端,地形起伏大,发育有海底火山、海沟和较平坦的海底平原等各种海底构造。

1.2 船载测深数据

本文使用的船载测深数据来自于美国国家海洋和大气管理局的国家环境信息中心(https://www.ncei.noaa.gov/maps/geophysics/),几内亚湾

收稿日期:2024-09-05

项目来源:自然资源部海洋环境探测技术与应用重点实验室开放基金(MESTA-2022-B002);安徽理工大学引进人才科研启动基金(2022yjrc66)。

第一作者简介:刘浩,主要研究方向为海底地形反演,E-mail:liuhao20212022@163.com。

通讯作者:袁佳佳,博士,讲师,主要研究方向为卫星测高数据处理及其应用,E-mail:yuanjiajia2008@126.com。

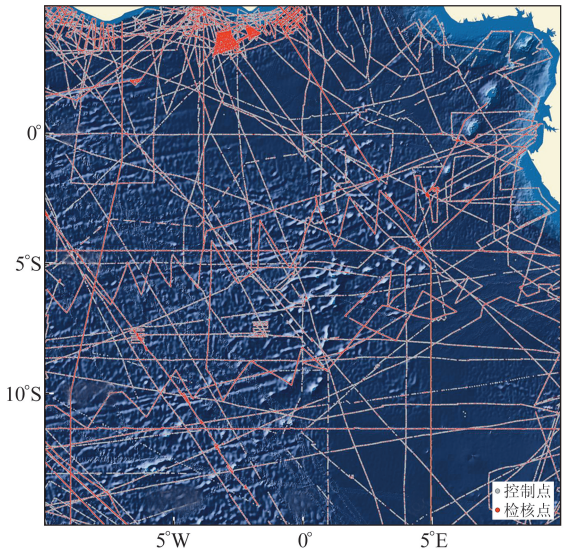


图 1 研究区与船测轨迹分布
Fig. 1 The study area and distribution of shipborne tracks

海域共有 80 条船载测深轨迹(图 1)。由于船载测深数据时间跨度长(1960—2016 年),早期数据精度存在不确定性[3-4,8],为提高船载测深数据的可靠性,按照 3σ 准则剔除船载测深值与 GEBCO_2023 模型海深差值大于 3 倍标准差的数据,最终获得船载测深点数 278 116 个,数据剔除率为0.51%。随机选取 20%的船载测深点作为检核点,检核点不参与神经网络训练,剩余船载测深点作为控制点,用于训练神经网络的各种参数。控制点和检核点在几内亚湾海域的分布情况见图 1。

1.3 重力数据和海底地形模型数据

本文使用的重力数据来自于美国加州大学圣地亚哥分校斯克里普斯海洋研究所(SIO)发布的 32.1 版本重力异常模型(https://topex.ucsd.edu/pub/),在后续的精度评定中引入 GEBCO_2023 和 Topo_25.1 海深模型进行精度验证。GEBCO_2023 是全球海底地形模型的第 5 代全球测深产品,于 2023-05 发布,格网分辨率为 15″,数据获取链接为 https://www.gebco.net/data_and_products/historical_data_sets/#gebco_2023;Topo_25.1 模型由 SIO 于 2023-01 发布,主要覆盖区域为 80°S～80°N,格网分辨率为 1′,数据获取链接为 https://topex.ucsd.edu/pub/。

2 特征数据获取

参照参考文献[10]获取几内亚湾海域船载测深点的长、短波重力异常及残差长、短波重力异常,并将这些重力异常数据作为神经网络学习训练样本中的特征数据。几内亚湾海域船载测深点的重力异常可通过重力异常模型插值得到。

2.1 长、短波重力异常获取

为获取几内亚湾海域的长波重力异常数据,首先利用布格板公式获取控制点 j 处的短波重力异常 $\Delta g_s(j)$:

$$\Delta g_s(j) = 2\pi G\Delta\rho(E(j) - D) \tag{1}$$

式中,D 表示参考海深,取−6 000 m;$E(j)$表示 j 点的船载测深值;G 表示重力常数,取值为 6.572 $\times 10^8$ cm^3/g·s^2;$\Delta\rho$ 表示海水与海底地壳的密度差常数,本文取 1.0 g/cm^3[12]。然后利用控制点处的重力异常 $\Delta g(j)$减去短波重力异常 $\Delta g_s(j)$,得到长波重力异常 $\Delta g_l(j)$:

$$\Delta g_l(j) = \Delta g(j) - \Delta g_s(j) \tag{2}$$

根据获得的控制点处长波重力异常,使用可调节张量连续曲率样条插值法得到预测点 i 处长波重力异常 $\Delta g_l(i)$,最后根据式(3)得到预测点 i 处短波重力异常 $\Delta g_s(i)$:

$$\Delta g_s(i) = \Delta g(i) - \Delta g_l(i) \tag{3}$$

2.2 残差长、短波重力异常获取

将获取的长、短波重力异常数据分别与船载测深数据进行最小二乘拟合,拟合斜率分别为−0.014和 0.038。参照 Annan 等[7,12]的研究方法,将长、短波重力异常数据与船载测深数据拟合的斜率分别乘以船载测深数据,得到参考长、短波重力异常,将长、短波重力异常减去参考长、短波重力异常,得到残差长、短波重力异常。

3 双通道 BP 神经网络原理

如图 2 所示,双通道 BP 神经网络结构中的输入数据包括经度(LON)、纬度(LAT)、短波重力异常(SG)、残差短波重力异常(RSG)、长波重力异常(LG)和残差长波重力异常(RLG)。在利用双通道 BP 神经网络进行海底地形反演时,首先对训练样本数据进行归一化处理,通过去除平均值并除以中误差,减少输入数据之间的差异。神经网络参数以随机值初始化,基本学习率设定为 0.01,训练迭代次数为 40 次,批大小为 128。该网络的核心是 2 个并行的特征提取通道,分别接收不同的输入数据,经过各自的特征提取层来提取关键特征向量;然后将 2 个通道的输出向量进行组合,生成预测值。训练过程中使用 Adam 优化器更新权重向量,并通过 L2 损失函数评估预测值与船载测深值的差异。当迭代次数达到 30 次时,学习率调整为初始值的 10%,并保持至训练结束。经过 40 次迭代后,生成最终的海深预测模型;最后将预测数据进行归一化处理,输入训练好的双通道 BP 神经网络模型,得到精确的海深预测结果。

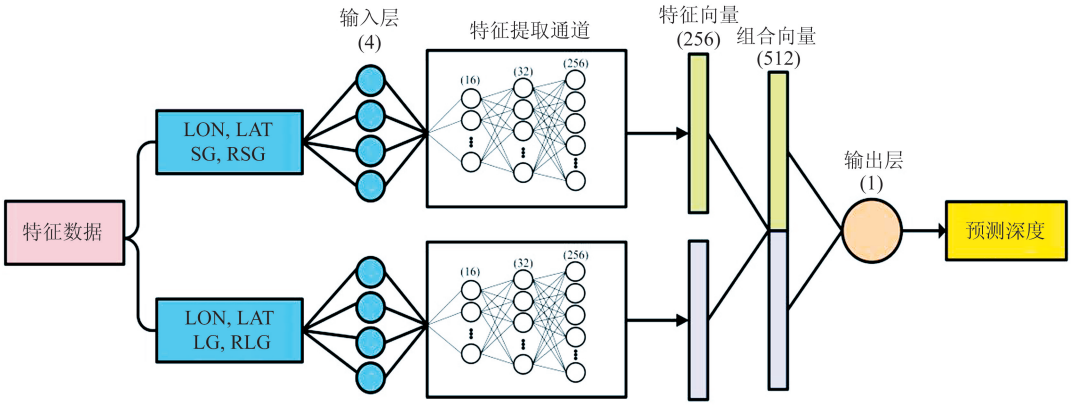


图 2　双通道 BP 神经网络结构

Fig. 2　Structure of the dual-channel BP neural network

双通道 BP 神经网络的 2 个并行通道是由 2 个特征提取层组成;特征提取层由 3 个全连接层组成,分别具有 16、32 和 256 个神经元。输入数据经过特征提取层处理后,生成一个特征向量,用于进一步的深度预测。在训练过程中,每次前向计算之后,神经网络会执行一次反向传播计算,其目的是通过不断调整神经网络的权重来优化模型性能。

在训练开始时,权重和偏置被初始化为初始值;然后神经网络会根据预测深度与船测深度之间的偏差适时调整权重。经过多次迭代调整,当预测深度与船测深度之间的差异达到最小时,对应的权重被认为是最佳值。权重调整公式可表示为:

$$\hat{\omega} = \omega - \alpha \frac{\partial \mathrm{loss}(d, d_0)}{\partial \omega} \tag{4}$$

式中,$\hat{\omega}$ 表示调整后的权重;ω 表示调整前的权重;α 表示学习率;loss 表示基于均方误差的 L2 损失函数;d_0 表示船测水深。

4　结果与分析

为评估预测海深模型的精度,采用 GGM 方法反演几内亚湾海底地形模型,并将基于神经网络海深预测模型得到的海底地形模型分别与 GGM 反演结果及 GEBCO_2023 和 Topo_25.1 模型进行比较。本文采用均方根误差(RMSE)和平均绝对百分比误差(MAPE)2 个指标对预测结果进行精度评定,详细计算方法见参考文献[3-4]。

4.1　几内亚湾海底地形模型

通过上述方法建立双通道 BP 神经网络海底地形反演模型,反演几内亚湾海底地形,结果见图 3。可以看出,几内亚湾海底地形呈现出显著的复杂性和多样性。几内亚湾中央部分主要由深海平原构成,深度在 −10 000～−5 000 m 之间,属于深海盆地。这些区域地形较为平坦,但也存在显著的高耸地形,如海山或海底火山链,形成凸出的海底地貌特征。

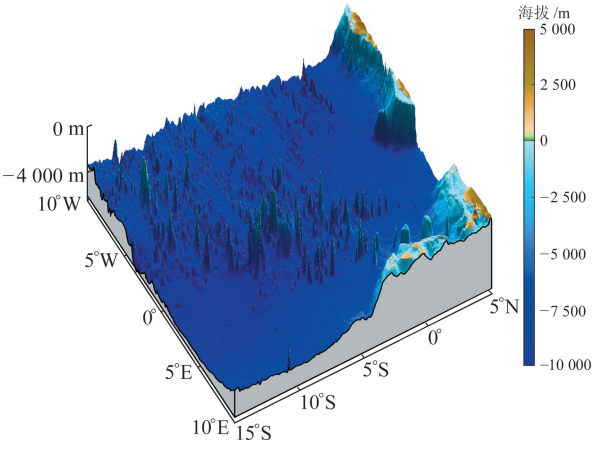


图 3　几内亚湾海深模型

Fig. 3　Bathymetric model of the gulf of Guinea

4.2　与船载测深值比较结果

利用神经网络海底地形反演模型训练得到所有检核点处的海深,标记为 BP 海深,并采用三次样条插值方法得到检核点处的 GGM 反演海深及 GEBCO_2023 和 Topo_25.1 模型海深。在检核点处将 BP、GGM、GEBCO_2023 和 Topo_25.1 四个模型海深值与船载测深值进行比较,结果见表 1。由表可知,检核点处 BP、GGM、GEBCO_2023 和 Topo_25.1 与船载测深值的 RMSE 分别为 26.049 m、42.669 m、41.110 m、44.499 m,MAPE 分别为 0.492%、0.846%、0.890%、0.908%,表明 BP 模型预测海深的精度优于其他模型。

图 4 为检核点处 BP、GGM、GEBCO_2023 和 Topo_25.1 四个模型海深与船载测深的差值分布。可以看出,4 个模型与船载测深的差异主要集中在 0 值附近,呈正态分布。4 个模型与船载测深的差值在 ± 20 m 以内的比例分别约为 83.3%、75.2%、73.3% 和 74.6%,BP 模型差值范围最小,表明其与船载测深的吻合度最高,模型精度和稳定性较高。从差值散点图可以看出,BP

模型差值与水深的关系最为紧密，波动较小，而其他模型差值与水深之间的波动较大，特别是在深水区域，表现出一定的不稳定性，进一步表明 BP 模型精度优于其他模型。

表 1 检核点处 BP、GGM、GEBCO_2023 和 Topo_25.1 与船测海深比较

Tab. 1 Comparison of BP, GGM, GEBCO_2023, and Topo_25.1 with shipborne bathymetry at checkpoints

模型	最大差值/m	最小差值/m	平均差值/m	STD/m	RMSE/m	MAPE/%
BP	590.496	−686.635	0.319	26.047	26.049	0.492
GGM	821.011	−895.369	0.146	42.669	42.669	0.846
GEBCO_2023	377.712	−384.370	−3.472	40.963	41.110	0.890
Topo_25.1	1 854.963	−642.005	−1.675	44.467	44.499	0.908

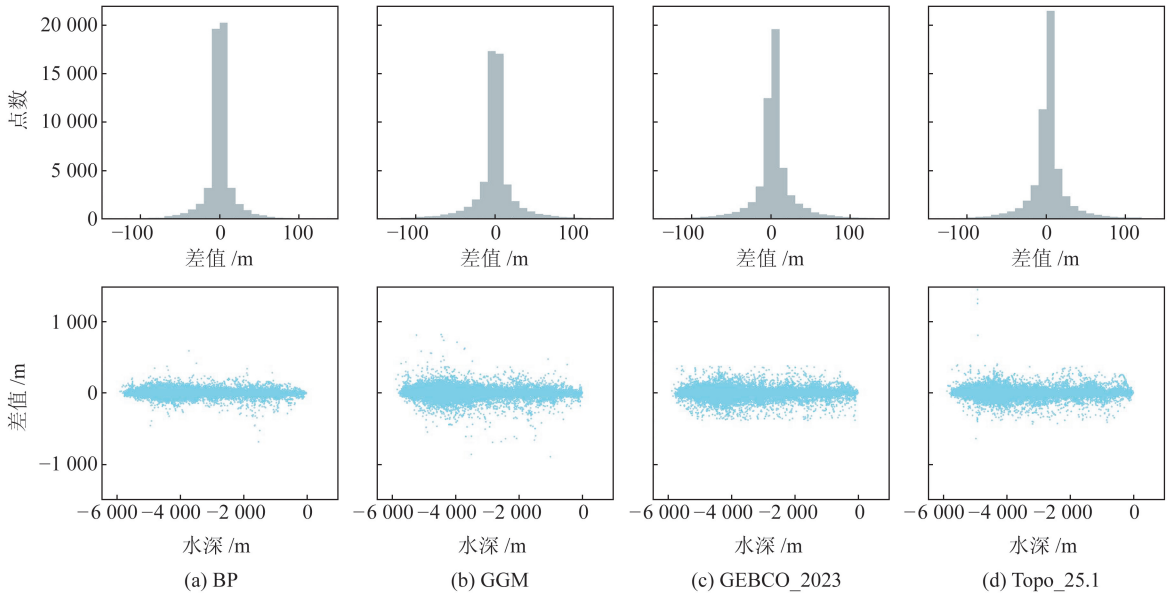


图 4 检核点处 BP、GGM、GEBCO_2023 和 Topo_25.1 与船载测深的差值分布

Fig. 4 Distribution of the differences between BP, GGM, GEBCO_2023, and Topo_25.1 and shipborne bathymetry at checkpoints

4.3 与船载测深值比较结果的空间分布

图 5 为检核点处 BP、GGM、GEBCO_2023 和 Topo_25.1 四个模型海深与船载测深差值的空间分布。可以看出，BP 模型(图 5(a))差值分布较为均匀，整体较小；而 GGM 模型(图 5(b))相较 BP 模型差值分布更加分散，尤其是在南部区域(10°S～15°S)及赤道附近，存在较大范围的差值区域(−100～100 m)；GEBCO_2023 模型(图 5(c))差值空间分布范围较广，部分区域的差值甚至超过±150 m，尤其是在赤道附近，表现出明显偏差；Topo_25.1 模型(图 5(d))与 GEBCO_2023 模型类似，差值分布较广，且多个区域的差值超过±150 m。上述分析表明，BP 模型整体精度最佳，其差值分布最为集中且误差较小，与船载测深的吻合度较高。

4.4 功率谱密度差异

为比较各模型在波数域内的差异，本文以经过几内亚湾海域的观测数据最丰富的一条船载测深轨迹为例，将 4 个模型的海深值插值到该轨迹上，并计算其与船载测深的差值，得到 4 个模型与

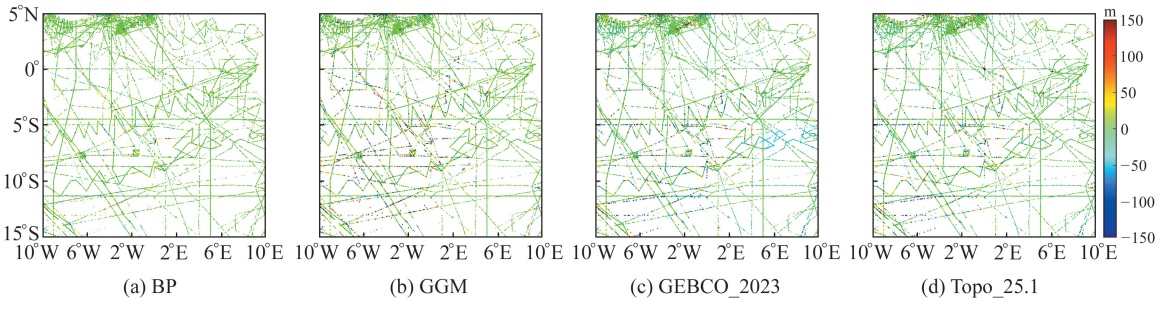


图 5 检核点处 BP、GGM、GEBCO_2023 和 Topo_25.1 与船测海深差值的空间分布

Fig. 5 Spatial distribution of the differences between BP, GGM, GEBCO_2023, and Topo_25.1 and shipborne bathymetry at checkpoints

船载测深差值的功率谱密度(PSD=10×lg$P$,其中 P 为功率),结果见图 6。

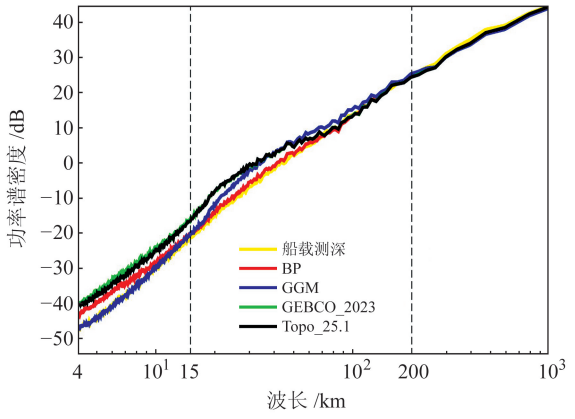


图 6　BP、GGM、GEBCO_2023 和 Topo_25.1 与船测测深差值的功率谱密度对比

Fig. 6　Comparison of power spectral densities of differences between the BP, GGM, GEBCO_2023, and Topo_25.1 models and shipborne bathymetry

图 6 中功率谱密度可反映各模型与船载测深差值的大小。在长波段(波长大于 200 km),4 个模型的功率谱密度随波长变化呈现一致性;在中波段(波长为 15～200 km),BP 模型的功率谱密度明显低于 GGM、GEBCO_2023 和 Topo_25.1 模型;而在短波段(波长小于 15 km),4 个模型的功率谱密度波动较大。因此,BP、GGM、GEBCO_2023 和 Topo_25.1 四个模型在长波段具有较好的一致性,而在中、短波段存在明显差异。

5　结　语

本文采用双通道 BP 神经网络,融合重力异常数据和船载测深数据,反演几内亚湾海底地形,并将反演结果与 GGM、GEBCO_2023 和 Topo_25.1 模型进行比较。结果表明,BP、GGM、GEBCO_2023 和 Topo_25.1 四个模型与船载测深数据的 RMSE 分别为 26.049 m、42.669 m、41.110 m 和 44.499 m,MAPE 分别为 0.492%、0.846%、0.890%和 0.908%。同时,4 个模型与船载测深差值的功率谱密度结果显示,各模型在长波段(波长大于 200 km)具有较好的一致性,而在中波段(波长为 15～200 km)和短波段(波长小于 15 km)存在明显差异。本文研究结果对于拓展深度学习在海洋大地测量学中的应用及提升海底地形反演精度具有重要借鉴意义。

参考文献

[1] 欧阳明达. 测高数据反演海底地形研究进展与展望[J]. 地球物理学进展, 2022, 37(6): 2291-2300(Ouyang Mingda. Research Progress and Prospects of Seabed Topography Inversion from Altimetry Data[J]. Progress in Geophysics, 2022, 37(6): 2291-2300)

[2] Li Q Q, Zhai Z H, Li Q, et al. Improved Bathymetry in the South China Sea from Multisource Gravity Field Elements Using Fully Connected Neural Network[J]. Journal of Marine Science and Engineering, 2023, 11(7)

[3] Zhou S, Liu X, Sun Y, et al. Predicting Bathymetry Using Multisource Differential Marine Geodetic Data with Multilayer Perceptron Neural Network[J]. International Journal of Digital Earth, 2024, 17(1)

[4] 周帅, 刘新, 李真, 等. 融合多源海洋大地测量数据的南海海底地形多层感知机反演[J]. 地球物理学报, 2024, 67(4): 1368-1382(Zhou Shuai, Liu Xin, Li Zhen, et al. Multi-Layer Perceptron Inversion of Seafloor Topography in the South China Sea Using Multi-Source Marine Geodetic Data[J]. Chinese Journal of Geophysics, 2024, 67(4): 1368-1382)

[5] 胡敏章, 李建成, 金涛勇. 应用重力地质方法反演皇帝海山的海底地形[J]. 武汉大学学报:信息科学版, 2012, 37(5): 610-612 (Hu Minzhang, Li Jiancheng, Jin Taoyong. Bathymetry Inversion with Gravity-Geologic Method in Emperor Seamount[J]. Geomatics and Information Science of Wuhan University, 2012, 37(5): 610-612)

[6] Sandwell D T, Müller R D, Smith W H F, et al. New Global Marine Gravity Model from CryoSat-2 and Jason-1 Reveals Buried Tectonic Structure[J]. Science, 2014, 346(6205): 65-67

[7] Annan R F, Wan X Y. Recovering Bathymetry of the Gulf of Guinea Using Altimetry-Derived Gravity Field Products Combined via Convolutional Neural Network[J]. Surveys in Geophysics, 2022, 43(5): 1541-1561

[8] 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

[9] Yang L, Liu M, Liu N, et al. Recovering Bathymetry from Satellite Altimetry-Derived Gravity by Fully Connected Deep Neural Network[J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20

[10] 王怀兵, 万晓云, Richard Fiifi Annan. 基于卷积神经网络预测南海海底地形[J]. 大地测量与地球动力学, 2024, 44(3): 287-292(Wang Huaibing, Wan Xiaoyun, Annan R F. Seafloor Topography Prediction in the South China Sea Based on Convolutional Neural Network[J]. Journal of Geodesy and Geodynamics, 2024, 44(3): 287-292)

[11] Harper H, Sandwell D T. Global Predicted Bathymetry Using Neural Networks[J]. Earth and Space Science, 2024, 11(3)

[12] Annan R F. 基于多源测高卫星数据的几内亚湾海洋重力场和水深反演[D]. 北京:中国地质大学(北京), 2021(Annan R F. Marine Gravity and Bathymetry Inversion Using Observations from Multi-Satellite Altimetry Missions over the Gulf of Guinea[D]. Beijing: China University of Geosciences, 2021)

Application of Dual-Channel BP Neural Network in Bathymetric Prediction in the Gulf of Guinea

LIU Hao[1,2] *YUAN Jiajia*[1,2] *YANG Chen*[1] *DONG Di*[2,3] *YU Daocheng*[4] *WU Zhendong*[5]

1 School ofSpatial Information and Geomatics Engineering, Anhui University of Science and Technology, 168 Taifeng Road, Huainan 232001, China

2 Key Laboratory of Marine Environmental Survey Technology and Application, MNR, 155 West-Xingang Road, Guangzhou 510300, China

3 South China Sea Institute of Planning and Environmental Research, SOA, 353 Mid-Xingang Road, Guangzhou 510300, China

4 School of Geomatics, Liaoning Technical University,88 Yulong Road, Fuxin 123000, China

5 School of Geography and Planning, Chizhou University, 199 Muzhi Road, Chizhou 247000, China

Abstract: We propose a bathymetric prediction method based on a dual-channel BP neural network, integrate gravity anomaly data(including long-wave, short-wave, and residual gravity anomalies) and shipborne bathymetry data to predict seafloor topography in the gulf of Guinea. The prediction results are compared with those obtained from gravity geology methods and the GEBCO_2023 and Topo_25.1 models. The results show that dual-channel BP neural network-based inversion achieves superior accuracy compared to other models. This study can provide new insights into applying deep learning in marine geodesy and enhances the accuracy of seafloor topography inversion.

Key words: BP neural network; seafloor topography; gravity anomalies; GEBCO_2023; Topo_25.1

Foundation support: Open Fund of Key Laboratory of Marine Environmental Survey Technology and Application, MNR, No. MESTA-2022-B002; Science Foundation for High-Level Talents of Anhui University of Science and Technology, No. 2022yjrc66.

About the first author: LIU Hao, majors in seafloor topography inversion, E-mail: liuhao20212022@163.com.

Corresponding author: YUAN Jiajia, PhD, lecturer, majors in satellite altimetry data processing and its application, E-mail: yuanjiajia2008@126.com.

(上接第 996 页)

Uplift Anomaly before Major Earthquake Measured by Leveling: Physical and Geometric Deformation

BO Wanju[1] *ZHANG Licheng*[1] *CHEN Zhaohui*[1] *XU Dongzhuo*[1]

1 The First Monitoring and Application Center, CEA, 7 Naihuo Road, Tianjin 300180, China

Abstract: By collecting achievements in the medium- to long-term prediction of strong earthquakes, an in-depth analysis of the commonalities and differences between vertical deformations observed by the global navigation satellite system(GNSS) and leveling measurements was conducted. The related issues of abnormal uplifts before major earthquakes were explored, including the abnormal fluctuations of leveling and their differences from GNSS observation results. Through the analysis of years of precise leveling data, the abnormal phenomenon of ground uplift before major earthquakes was revealed. Combining this with research findings on gravity anomalies before major earthquakes, a theoretical deduction and analysis of the relationship between the two was conducted. The vertical deformation data obtained from leveling measurements not only includes the effects of point-wise vertical geometric deformation but also contains information about the dynamic bending of the local gravity level surface, with magnitudes reaching 2 mm or more. Based on this, the concepts of physical deformation and geometric deformation were proposed. The research in this paper is of significant theoretical and practical importance for correctly understanding the differences in deformation mechanisms, the medium- to long-term prediction of strong earthquakes, and the formulation of deformation anomaly monitoring plans and decision-making.

Key words: physical deformation; geometric deformation; strong earthquake prediction; level surface; gravity anomaly; gravity potential

Foundation support: Fund of Senior Science and Technology Association of CEA, No. 502237202.

About the first author: BO Wanju, researcher, majors in crustal deformation and earthquake prediction, E-mail: bowanju@163.com.