



陈晨, 李厚朴, 张玉洁, 等. 2026. 基于全局接受卷积的三维重力反演. 地球物理学进展, 41(1):0206-0216, doi:10.6038/pg2026H0530.

CHEN Chen, LI HouPu, ZHANG YuJie, et al. 2026. Three-dimensional gravity inversion based on global receptive convolution. *Progress in Geophysics* (in Chinese), 41(1):0206-0216, doi:10.6038/pg2026H0530.

# 基于全局接受卷积的三维重力反演

## Three-dimensional gravity inversion based on global receptive convolution

陈晨<sup>1,2</sup>, 李厚朴<sup>3\*</sup>, 张玉洁<sup>1</sup>, 江文<sup>1</sup>, 蒋奥飞<sup>1</sup>

CHEN Chen<sup>1,2</sup>, LI HouPu<sup>3\*</sup>, ZHANG YuJie<sup>1</sup>, JIANG Wen<sup>1</sup>, JIANG AoFei<sup>1</sup>

1. 中国地质大学(武汉)数学与物理学院, 武汉 430074

2. 沧州交通学院电子与电气工程学院, 沧州 061199

3. 海军工程大学电气工程学院, 武汉 430033

1. School of Mathematics and physics, China University of Geosciences, Wuhan, 430074, China

2. School of Electronic and Electrical Engineering, Cangzhou Jiaotong College, CangZhou 061199, China

3. College of Electrical Engineering, Naval University of Engineering, Wuhan, 430033, China

**摘要** 三维重力反演是利用地表观测到的重力异常数据获取地下异常源位置、形状以及物性参数的过程。近年来,随着数据驱动方法的快速发展,将深度学习(Deep Learning, DL)方法用于三维重力反演问题也受到广泛关注并取得了一定的成果。基于 U-Net 网络使用注意力特征融合(Attention Feature Fusion, AFF)机制来进行重力三维反演的研究,能够使反演结果具有更高的垂向分辨率,该方法对于更深部位的模型的重建效果仍旧有待提高,在此基础上,使用全局接受卷积(Global Receptive Convolution, GRC)替换部分标准卷积,强制卷积过程满足空间位置与通道索引的条件,旨在将全局特征与局部特征集成到逐像素表示中,进一步学习原始特征,达到提高深部模型重建分辨率的目的。该网络反演结果的垂向分辨率得到进一步的提升,墨西哥圣尼古拉斯矿床的实验结果证明,反演网络能够清晰的预测出硫矿床的基本位置以及大概形状,结果与已知地质资料较为吻合。

**关键词** 三维重力反演;深度学习;全局接受卷积;趋肤效应

中图分类号 P631

文献标识码 A

**Abstract** Three-dimensional gravity inversion is the process of obtaining the location, shape, and physical parameters of underground anomalies using gravity anomaly data observed at the surface. In recent years, the rapid development of data-driven methods has led to widespread interest in applying Deep Learning (DL) techniques to gravity inversion problems, yielding certain results. Research based on the U-Net network that employs an Attention Feature Fusion (AFF) mechanism for three-dimensional gravity inversion enhances the vertical resolution of the inversion results. However, the reconstruction effect for deeper models still needs improvement. Building on this, the use of Global Receptive Convolution (GRC) to replace certain standard convolutions aims to ensure that the convolution process meets the conditions of spatial position and channel indexing. This approach integrates global and local features into a pixel-wise representation, further learning the original features to improve the reconstruction resolution of deeper models. The network's inversion results show enhanced vertical resolution, and experimental results from the San Nicolás deposit in Mexico demonstrate that the inversion network can clearly predict the basic location and approximate shape of the sulfur deposit, aligning well with known geological data.

**Keywords** 3D gravity inversion; Deep learning; Global receptive convolution; Skin effect

收稿日期 2025-03-30; 修回日期 2025-10-12.

投稿网址 <http://www.progeophys.cn>

基金项目 国家自然科学基金(42122025, 42374174)资助.

第一作者简介 陈晨, 女, 1997 年生, 硕士研究生, 主要从事地球物理反演方面的学习和研究. E-mail: 1039287207@qq.com

\* 通讯作者 李厚朴, 男, 博士, 教授, 主要人事海洋大地测量与海洋地球物理方向研究. E-mail: lihoupu1985@126.com

doi:10. 6038/pg2026H0530  
CSTR:32085.14.pg2026H0530

0 引言

重力勘探资料能够用来研究地质构造、圈定地下空洞异常区域和地下成矿带,随着空间探测技术的发展,卫星重力、航空重力和微重力测量得到广泛应用(Nabighian *et al.*, 2005; 张玉洁等, 2024). 其中,三维物性反演是重力异常数据定量解释的重要方法与研究热点. 近年来,深度学习(Deep Learning, DL)方法得到了地球科学界的广泛关注. 卷积神经网络(Convolutional Neural Networks, CNN)已经成功地应用于图像分类问题(Krizhevsky *et al.*, 2017),并且许多尝试发现它也可以处理不适定逆问题(Huang *et al.*, 2021; Lü *et al.*, 2023). 这些成果为解决地球物理问题提供了多种方法,因此许多学者致力于将神经网络应用于地球物理的研究中.

20 世纪 80 年代,卷积神经网络和反向传播算法概念的提出,为深度学习的发展注入了新的活力,也为 DNN 在地球物理领域的应用提供了新的思路. Oh 等(2020)提出了一种基于监督 DL 的协同反演方法用于盐的圈定,张志厚等(2021)提出使用深度学习方法并结合重力异常与重力张量进行联合三维反演,他们展示了利用深度学习技术将地球物理数据与约束相结合的可能性. Yang 等(2022)使用了一种改进的 U-Net 体系进行三维重力反演. Li 等(2023)利用卷积神经网络开发了 GV-Net 用于反演剩余重力异常. 针对地球物理反演中解的不稳定性, Xu 等(2023)人提出了基于 ResUnet 的地下密度模型快速重建方法,使得重建模型具有清晰的物理边界,获得了较稳定的解. 针对卷积神经网络在精准定位地质特征精度低、处理大量高维数据效率低的缺陷, Wang 等(2024)提出使用多尺度功能 MS-UNets 网络来缓解. 针对重力三维反演中数据集多样性不足的问题,这些方法的成功应用说明了作为一种具有自适应学习能力和非线性映射能力的技术,深度学习方法在未来可能成为传统方法的补充或替代.

虽然现今的重力反演技术发展的比较成熟,但由于地球物理场的固有性质,在求解的过程中还存在着一些问题,如趋肤效应,由于浅部的模型单元相较于深部的模型单元给予观测面更大的贡献,当使用训练好的神经网络对测试集进行测试时,往往对

浅部单元展示出更加清晰的轮廓,而对于深部单元,其轮廓就稍显模糊.

在缓解趋肤效应问题上,本文使用注意力特征融合(Attention Feature Fusion, AFF)机制来进行重力三维反演的研究,能够使反演结果具有更高的垂向分辨率,在此基础上,用全局接受卷积(Global Receptive Convolution, GRC)替换部分标准卷积,以求得捕获更多的特征信息,将该网络称为 GRC-UNet. 本文中构建了一个名为 GravInv 的密度模型数据集,该数据集由七种类型的模型组成. 在大量的对比实验中,结果表明使用全局接受卷积模块的神经网络对于地下异常体更深部位的重建精度更高,效果更好.

1 重力正反演模型

1.1 重力异常正演

在计算任意形状、大小的地质体在观测面上引起的重力异常时,通常将该地质体剖分为无数的体积元,假设某一剖分单元的位置为  $Q(\xi, \eta, \zeta)$ , 密度为  $\rho(\xi, \eta, \zeta)$ . 该地质体在测点  $P(x, y, z)$  处产生的重力场可以表示为(Rezaie *et al.*, 2017):

$$F = \gamma \iiint_V \rho(\xi, \eta, \zeta) \frac{1}{r^3} dv, \tag{1}$$

其中,  $V$  代表地质体的体积,  $r$  代表体积元  $Q(\xi, \eta, \zeta)$  到观测点  $P$  的距离,  $\gamma$  代表万有引力常数. 则该地质体的重力异常即为重力场在垂直方向上的分量, 可以表示为:

$$g = \frac{\partial F}{\partial z} = \gamma \iiint_V \rho(\xi, \eta, \zeta) \frac{z - \zeta}{r^3} dv. \tag{2}$$

在实际的重力异常正演过程中,通常将地下异常体划分为如图 1 的若干个长方体单元,然后计算




图 1 模型地下剖分示意图  
(a) 任意地质体; (b) 长方体模型.  
Fig. 1 Schematic diagram of the underground section of the model  
(a) Arbitrary geological body; (b) Rectangular prism model.

每一个长方体单元对测点产生的异常,将所有长方体单元对测点产生的异常求和即为地下半空间整个模型体对观测点产生的异常.当剖分的单元个数足够多,单元体积足够小时,上述方法可以拟合任意形状的地质体,则近似的重力异常计算式可以表示为(Zhang *et al.*, 2022a):

$$\mathbf{d} = \mathbf{G}\mathbf{m}, \quad (3)$$

式中,  $\mathbf{d}$  为各个观测点的重力异常值组成的  $m \times 1$  的向量;  $\mathbf{m}$  为地质体剖分后每个单元的密度组成的  $n \times 1$  的向量;  $\mathbf{G} = [g_{ij}]_{m \times n}$  为灵敏度矩阵,矩阵中的元素  $g_{ij}$  定量的描述了第  $j$  个模型单元对第  $i$  个观测点重力值的贡献.

## 1.2 重力反演

重力反演问题可以理解为正演问题的逆过程,此时式(3)中的  $\mathbf{m}$  是未知的,需要由已知的观测数  $\mathbf{d}$  来反演出地质体在模型空间的密度参数  $\mathbf{m}$ . 但此时却面临一个问题,由于观测点的数量远远少于地质体剖分的数量,即  $\mathbf{d}$  的维数少于  $\mathbf{m}$  的维数,则解重力反演问题即为解欠定的方程组,这时方程组的解是非唯一的,即重力反演领域中的多解性问题.

在反演建模时常用最小二乘法拟合目标函数,可以表示为(张志厚等, 2021):

$$\phi = \|\mathbf{d} - \mathbf{G}\mathbf{m}\|_2. \quad (4)$$

本文聚焦于采用 DL 数据驱动的反演方法,直接从观测重力异常数据推断出密度模型进而刻画具有尖锐边界的地下异常体. CNN 通过一个复杂的非线性网络来表达从数据域到模型域的映射关系(Zhang *et al.*, 2022b),可以表示为:

$$\mathbf{m} = F(\mathbf{d}). \quad (5)$$

不同于正则化反演,将预测异常值与观测异常值之间的误差最小化,而 CNN 反演是将预测密度模型与理论密度模型之间的误差最小化.

## 2 研究方法

本文旨在 AFF-UNet 网络的基础上,使用扩大感受野的方式达到高分辨率反演深部模型的目的. 本文所采用的 GRC 模块(Yu and Koltun, 2016)在网格采样位置上相较于膨胀卷积与可形变卷积,有着更大的采样位置,能够更大程度的扩大感受野,使得神经网络捕获到更多的特征信息.

### 2.1 GRC-UNet 网络结构

为了使得重力三维反演任务更好地重构深度部位密度模型,在垂直方向上达到高分辨率反演. 以 U-Net 捕获上下文的收缩路径和支持精确本地化的

对称扩展路径(Ronneberger *et al.*, 2015)为基础框架,将卷积层替换为  $3 \times 3$  的 GRC 模块,将编码器与解码器之间简单的特征拼接过程替换为注意力特征融合模块,并且对融合后的特征再次进行特征提取. 为了能够得到更好的特征表示,多尺度通道注意力模块(Multi-scale Channel Attention Module, MS-CAM)(Dai *et al.*, 2020)将会进一步聚合全局与局部特征,最后将提取的不同尺度的特征进行特征融合. Ren 等(2025)主张使用 GRC 模块代替标准卷积的过程中,有必要保留一组标准卷积,用以保持局部的像素信息,由于仅采用全局上下文信息仍是不足以获取更准确的分割结果,因此,在保证聚集全局上下文特征的前提下,为了更加充分地发挥局部逐像素信息的作用,本文将残差模块中两个堆叠的标准卷积,其中之一改变为 GRC 模块,另一个标准卷积保持不变, GRC-UNet 网络结构如图 2 所示.

GRC 模块能够使得卷积中网格采样位置同时兼顾空间维度与通道维度的方法,旨在达到扩大感受野的目的. 同时 GRC 能够为滤波器提供全局接受域,并且没有引入额外的参数. 实现这一点的关键在于使滤波器的不同通道在输入特征图上具有不同的网格采样位置.

例如如图 3 中  $1 \times 1$  GRC 模块的示意图,沿通道维度将  $1 \times 1$  卷积核分为两组,即图 3 左上角蓝色立方体与其他颜色的立方体. 浅蓝色立方体所对应的组别对中心像素进行标准卷积以保持原始位置信息;同时将其其他颜色立方体所对应的组别移动到其他空间位置,用以捕获全局上下文信息.

GRC-UNet 网络结构中改进的残差模块如图 4 所示, AFF 模块可以表示为:

$$\mathbf{Z} = \mathbf{M}(\mathbf{X} \oplus \mathbf{Y}) \otimes \mathbf{X} + (1 - \mathbf{M}(\mathbf{X} \oplus \mathbf{Y})) \otimes \mathbf{Y}, \quad (6)$$

其中,  $\mathbf{Z} \in R^{C \times H \times W}$  为融合特征,  $\oplus$  表示初始特征整合. AFF 模块如图 4 所示,特征  $\mathbf{X}$  与  $\mathbf{Y}$  在经过初始特征整合之后,经由 MS-CAM 得到注意力融合权重. 初始特征  $\mathbf{X}$  与  $\mathbf{Y}$  在分别与对应权重做内积后相加得到融合特征  $\mathbf{Z}$ . 在 AFF 模块中,为了简单起见,我们选择特征元素相加作为初始特征整合.

MS-CAM 模块能聚合不同尺度目标的不同感受野的上下文语义特征. 给定全局通道上下文  $\mathbf{G}(\mathbf{X})$  和局部通道上下文  $\mathbf{L}(\mathbf{X})$ ,经过 MS-CAM 可提取到通道数为  $C$ ,大小为  $H \times W$  的特征  $\mathbf{X}' \in R^{C \times H \times W}$ :

$$\mathbf{X}' = \mathbf{X} \otimes \mathbf{M}(\mathbf{X}) = \mathbf{X} \otimes \sigma(\mathbf{L}(\mathbf{X}) \oplus \mathbf{G}(\mathbf{X})), \quad (7)$$

其中,  $\mathbf{M}(\mathbf{X})$  为 MS-CAM 生成的注意力权重.  $\oplus$  表示加法,  $\otimes$  表示内积. MS-CAM 的结构如图 6 所示. 在




图 2 基于 GRC-UNet 网络的重力反演结构示意图

Fig.2 Schematic diagram of gravity inversion structure based on GRC-UNet network




图 3 1×1 GRC 示意图

Fig.3 Diagram of 1×1 GRC




图 4 3×3 GRC 模块改进的基本块结构

Fig.4 Basic block structure improved with 3×3 GRC module




图 5 AFF 结构

Fig.5 AFF structure




图 6 MS-CAM 结构

Fig.6 MS-CAM structure

MS-CAM 聚合局部与全局上下文信息的过程中,局部通道上下文  $L(X)$  与输入特征具有相同的形状,可以保留和突出底层特征中的细微细节。

## 2.2 损失函数

在深度神经网络的训练过程中,一般通过最小化损失函数来解决优化问题。对于图像回归和重建问题,  $L_1$  或  $L_2$  范数通常是定义损失函数最常用的度量。但是考虑到我们假设重力三维反演问题中解具有稀疏性 (Li *et al.*, 2018), 即重力三维反演关注的部分只是地下空间中很小的一部分, 这就会使网络在梯度下降的过程中收敛到局部最小值, 导致网络预测结果偏向于背景。为了能够更加清晰的刻画地质体边缘轮廓, 选择能够在目标体与背景体素数量不平衡时, 依旧可以清晰刻画小目标体形状与位置信息的 Dice 损失函数作为反演网络的损失函数, Dice 系数具体可以表示为 (Milletari *et al.*, 2016):

$$\text{DiceCoefficient} = \frac{2 \sum_{i=1}^N m_i^T \hat{m}_i}{\sum_{i=1}^N m_i^T m_i + \sum_{i=1}^N \hat{m}_i^T \hat{m}_i}, \quad (8)$$

其中,  $m_i$  和  $\hat{m}_i$  分别表示第  $i$  个真实密度模型和重建密度模型,  $N$  表示密度模型的总数。

本文在网络训练过程中所用到的损失函数, 即 Dice 损失等于  $1 - \text{Dice 系数}$ :

$$\begin{aligned} \text{DiceLoss} &= 1 - \text{DiceCoefficient} \\ &= 1 - \frac{2 \sum_{i=1}^N m_i^T \hat{m}_i}{\sum_{i=1}^N m_i^T m_i + \sum_{i=1}^N \hat{m}_i^T \hat{m}_i}, \quad (9) \end{aligned}$$

Dice 损失的取值范围在  $0 \sim 1$  之间, 取值越小表示网络的反演结果与真实标签之间的误差越小, 模型的性能越好。

## 3 数值试验

### 3.1 仿真数据集的构建

在 DL 反演方法中, 除了设计合适的网络, 构建大量并多样的仿真数据来训练网络是很有必要的。本文将地表边长为 1600 m 的正方形观测区域划分为  $32 \times 32$  网格, 采样间隔 50 m; 将地下长宽分别为 1600 m, 深度为 800 m 的区域均匀划分为  $16 \times 32 \times 32$  的长方体, 边长为 50 m。设置地质体的密度值为  $1 \text{ g/cm}^3$ , 背景密度为  $0 \text{ g/cm}^3$ , 将三维反演问题近似看作三维立体分割问题, 即将地下空间划分为背景区域 ( $0 \text{ g/cm}^3$ ) 和地质体区域 ( $1 \text{ g/cm}^3$ )。

构建包含六种常规模型的仿真数据集, 同时考虑到地质体的多样性, 为了使网络具有一定泛化性, 使用随机游走 (Huang *et al.*, 2021) 的方式生成随机模型。本文使用六种常规模型和随机模型及其对应的异常数据共同构成的仿真数据集对神经网络进行训练, 将该数据集命名为 GravInv 数据集。GravInv 数据集由一个训练集和一个测试集组成, 训练集中有随机模型 10000 个和常规模型各 2000 个, 总共 22000 个样例; 测试集包括 100 个随机模型和常规模型各 100 个, 总共 700 个样例。六种常规模型和随机模型如图 7 所示。

### 3.2 试验细节

在训练阶段, 我们将迭代次数设置为 150 个 epoch, 批大小设置为 32, 学习率设置为  $3 \times 10^{-4}$ , 采用 Adam 算法优化网络参数 (PC 配置: 11th Gen Intel(R) Core(TM) i5-11320H@3.20GHz, RAM: 16GB, 下同)。

### 3.3 评价指标

本文使用以下指标来评价重力三维反演模型重建的准确性:

$$\text{MAE} = \frac{1}{q} \sum_{i=1}^q |\tilde{m}(i) - m(i)|, \quad (10)$$

$$E_m = \frac{1}{q} \sum_{i=1}^q \frac{\|\tilde{m}(i) - m(i)\|_2}{\|m(i)\|_2}, \quad (11)$$

$$E_{\text{acc}} = \frac{C(|\tilde{m}(i) - m(i)| < t)}{q}, \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^p (\tilde{d}(i) - \bar{d})^2}{\sum_{i=1}^p (d(i) - \bar{d})^2}, \quad (13)$$

其中,  $\tilde{m}(i)$  和  $m(i)$  分别表示预测模型向量和理论模型向量中的第  $i$  个元素,  $p$  和  $q$  分别表示向量  $d$  和  $m$  的维度。MAE 为平均绝对误差, 反映重构模型与理论模型之间的平均误差;  $E_m$  为平均相对误差, 基于  $L_2$  范数反映真实密度模型与预测模型之间的相对误差。  $E_{\text{acc}}$  用来衡量地下区域的反演精度, 表示阈值,  $\tilde{m}(i)$  当和  $m(i)$  误差的绝对值小于阈值时, 则认为预测正确, 使用表示正确预测模型的计数, 将正确预测的个数除以异常体网格剖分总数以获得精度值。在本研究中, 值选取 0.01。  $R^2$  是决定系数, 体现预测重力异常数据和观测重力异常数据之间的拟合程度,  $\tilde{d}(i)$  表示预测的重力异常值,  $d(i)$  表示观测的重力异常值,  $\bar{d}(i)$  表示观测异常值的均值。

### 3.4 仿真数据集试验

#### 3.4.1 三维反演对比实验

本节在测试集上评估了 GRC-UNet 网络的可行




图7 GravInv 数据集  
(a) 单立方体模型;(b)单阶梯状模型;(c)垂直模型;(d)双立方体模型;(e)交叉双阶梯模型;(f)同向双阶梯模型;  
(g)单个随机模型;(h)组合随机模型。

Fig.7 GravInv dataset

(a) Single cube model; (b) Single step model; (c) Dipping dike model; (d) Double cube model; (e) Cross double step model;  
(f) Same-direction double step model; (g) The single random model; (h) Two random model.

性和有效性. 使用经过 50 轮训练的神经网络重构三维密度模型,网络训练达到 15 轮时,损失趋于稳定. 图 8 展示了 GRC-UNet 网络的损失曲线,图中显示反演网络的训练在 15 轮左右达到收敛.




图8 反演网络的训练损失曲线

Fig.8 Training loss curve of the inversion network

为便于观察异常体反演的形状,所有的 3D 视图均只显示剩余密度值大于 0.3 g/cm<sup>3</sup> 的部分. 以下我们将从测试集中随机选取几个常规模型来展示一下 GRC-UNet 网络三维重建的效果.

本文中提出的 GRC-UNet 网络是在 AFF-UNet 网络的基础上,改变了部分卷积的方式以达到扩大感受野、捕获更多原始特征的目的,因此从理论上来看,获得更多的原始特征后地下异常体的反演效果会得到相应提升,所以在本文中将比较 GRC-UNet 网络与 AFF-UNet 网络的反演结果,用以验证 GRC-UNet 网络能够在一定程度上使得反演结果得到提升.

使用 GravInv 数据集分别对 GRC-UNet 网络与 AFF-UNet 网络进行训练与测试,将两种网络的反演结果进行比较. 随机选取的几个经典模型的对比如图 9 和图 10 所示.

从图 9 中可以看出,观察(b)和(c)所展示的预测模型的 3D 视图,所预测的地质体模型无论是形状还是位置信息均与理论模型较为吻合,整体来看地质体重建的效果还是 GRC-UNet 网络更胜一筹.从(e)和(f)可以较为明显地看出,AFF-UNet 网络反演的预测剖面图有许多杂质分布在地质体周围,模糊了地质体与背景体的边界,相比较来看,虽然 GRC-UNet 预测结果也存在部分杂质,但综合来说反演结果仍是优于 AFF-UNet 网络.

从图 10 中可以看出,观察(b)和(c)所展示的预测模型的 3D 视图,两种网络基本上可以反演出该模型的大致形状及位置信息,但是随着深度的加深,模型存在部分信息的缺失.对比(e)和(f)可以看出,可以看出两种网络的预测模型在浅部位置有着较为清晰的轮廓,但是随着深度的增加,模型的边界不可避免的变得模糊,但对于异常体密度值的预测 GRC-UNet 预测的结果更加精确.

根据 4.3 中的评价指标,GRC-UNet 网络实验的误差如表 1 所示.从表 1 中可以看出,本文中所提出的 GRC-UNet 网络相较于 AFF-UNet 网络占据着更小的模型相对误差,对重力数据的拟合效果要更加的贴近理论数据.

表 1 GRC-UNet 与 AFF-UNet 平均反演误差

Table 1 The average inversion errors between GRC-UNet and AFF-UNet

|       | GRC-UNet | AFF-UNet |
|-------|----------|----------|
| MAE   | 0. 0069  | 0. 0072  |
| $E_m$ | 0. 3337  | 0. 3620  |
| $R^2$ | 0. 9873  | 0. 9813  |

表 2 GRC-UNet 与 AFF-UNet 平均反演精度  $E_{acc}$   
(单位: %)

Table 2 The average inversion accuracy  $E_{acc}$  between GRC-UNet and AFF-UNet(unit: %)

| 模型       | GRC-UNet | AFF-UNet |
|----------|----------|----------|
| 矩形棱镜模型   | 97. 51   | 96. 67   |
| 倾斜堤模型    | 96. 50   | 96. 43   |
| 垂向尖灭模型   | 96. 30   | 94. 35   |
| 向斜模型     | 96. 57   | 96. 47   |
| 垂直平行棱镜模型 | 97. 09   | 92. 80   |
| 断层模型     | 96. 61   | 95. 70   |
| 随机模型     | 94. 27   | 92. 71   |

从表 2 中可以看出,GRC-UNet 网络在六种常规模型以及随机模型上的平均反演精度都在 AFF-UNet 网络的基础上有着明显地提高,因此可以认为本文中使用 GRC 模块对 AFF-UNet 网络进行的改进是成功的,能够在一定程度上进一步提高模型的重建分辨率.

综上七种模型 GRC-UNet 网络与 AFF-UNet 网络的反演结果对比,七种模型均显示出 GRC-UNet 网络无论是在形状、位置还是密度值预测的优越性;通过  $\overline{E}_{acc}$  的对比可以看出,GRC-UNet 网络精度要优于 AFF-UNet 网络,并且预测误差以及重力数据拟合效果均优于 AFF-UNet,因此整体来看,GRC-UNet 网络是能够在 AFF-UNet 的基础上进一步提高神经网络反演精度.

针对随机模型 3D 视图与剖面图效果较差的问题有如下猜测:所添加的 GRC 模块本质上是为了捕获更多的特征在对原始信息进行卷积的过程中对不同通道采取了不同的采样位置,这便增加了所捕获信息的随机性,在此基础上,由于随机模型生成的特殊性,模型本身就具有着一定的随机性,在二重随机性的叠加下使得神经网络的预测效果产生些许的波动.但此猜测还需未来进行相关实验进行佐证.

3. 4. 2 不同深度下重建效果对比

在上一小节中,本文对 GRC-UNet 网络与 AFF-UNet 网络反演的结果进行了较为整体的比较,在重力三维反演问题中,一直较为困扰的便是趋肤效应的问题,本文提出 GRC-UNet 网络的出发点也是希望能够扩大特征提取的感受野,使得神经网络学习到更多的特征,包括更深部位信息的特征,以此来缓解趋肤效应的影响,因此在本小节中将比较 GRC-UNet 网络与 AFF-UNet 网络反演结果在 400 m 及以下的  $xoy$  剖面图,以此来观察 GRC-UNet 网络是否能够在 AFF-UNet 网络的基础上,进一步达到缓解趋肤效应的目的.

从图 11 中可以看出,当深度处于 400 m 位置时 GRC-UNet 网络与 AFF-UNet 的反演异常体周围均围绕着一一些低密度的杂质,这导致其反演的边界不够清晰,异常体形状不明确,但两个网络相比较来说,GRC-UNet 网络所预测的异常体周围杂质较少,物体形状以及物理边界相较于 AFF-UNet 网络要更加清晰;当深度处于 600 m 位置时,二者反演结果中的密度参数均较为贴近理论模型,但是 AFF-UNet 网络反演结果存在更多低密度杂质.




图9 规则模型 GRC-UNet 与 AFF-UNet 反演结果的比较

(a) 规则密度模型;(b)GRC-UNet 反演结果;(c)AFF-UNet 反演结果;(d) 真实密度模型  $xoz$  剖面图;  
(e)GRC-UNet 反演模型  $xoz$  剖面图;(f) AFF-UNet 反演模型  $xoz$  剖面图.

Fig. 9 Comparison of inversion results of GRC-UNet and AFF-UNet

(a)Rule density model;(b) Inversion results by GRC-UNet;(c) Inversion results by AFF-UNet;(d)  $xoz$  section of the true density model;  
(e)  $xoz$  section of (b);(f)  $xoz$  section of (c).




图10 随机模型 GRC-UNet 与 AFF-UNet 反演结果的比较.

(a)随机密度模型;(b)GRC-UNet 反演结果;(c)AFF-UNet 反演结果;(d) 真实密度模型  $xoz$  剖面图;  
(e)GRC-UNet 反演结果  $xoz$  剖面图;(f) AFF-UNet 反演结果  $xoz$  剖面图.

Fig. 10 Comparison of inversion results of GRC-UNet and AFF-UNet

(a) Random density model;(b) Inversion results by GRC-UNet;(c)Inversion results by AFF-UNet;(d)  $xoz$  section of the true density model;  
(e)  $xoz$  section (b);(f)  $xoz$  section of (c).

3.5 真实矿场上的应用

为了验证本文反演网络在处理实际资料时是具有意义的,将反演网络应用于圣尼古拉斯矿床的野外实际重力异常数据. 钻探资料表明,硫化矿体的顶

部位于地表下 150 ~ 220 m,矿体底部延伸至地表以下 400 ~ 450 m,厚度约为 280 m (Phillips *et al.*,2001; Johnson *et al.*,2000). 研究区域与文献 (Phillips *et al.*, 2001) 中剩余重力异常图一致. 该区域中心的重力




图 11 不同深度下 GRC-UNet 与 AFF-UNet 反演剖面的比较

(a) 真实模型在 400 m 处剖面图;(b)GRC-UNet 反演模型在 400 m 处剖面图;(c)AFF-UNet 反演模型在 400 m 处剖面图;  
(d) 真实模型在 600 m 处剖面图;(e)GRC-UNet 反演模型在 600 m 处剖面图;(f) AFF-UNet 反演模型在 600 m 处剖面图。

Fig. 11 Comparison of inversion sections of GRC-UNet and AFF-UNet at different depths

(a) True model section at 400 m;(b) GRC-UNet inversion model section at 400 m;(c) AFF-UNet inversion model section at 400 m;  
(d) True model section at 600 m;(e) GRC-UNet inversion model section at 600 m;(f) AFF-UNet inversion model section at 600 m.




图 12 圣尼古拉斯矿床反演结果

(a) GRC-UNet 反演结果;(b) U-Net 反演结果. 上一行: Easting = -1700 m; 下一行: Northing = -400 m. 黑线为矿体实际轮廓。

Fig. 12 The inversion result of the St. Nicholas

(a) The inversion sections of GRC-UNet;(b) The inversion sections of AFF-UNet. The above line; Easting = -1700 m;  
The next line; Northing = -400 m. The black line is the actual contour.

异常是由块状硫化物引起的,其他异常则是由铁镁质火山岩引起,剩余重力异常至最高达 2.2 mGal. 从表 3 可以看出,硫化物的密度值为 3.5 g/cm<sup>3</sup>,围岩的密度值分布在 2.3 g/cm<sup>3</sup> 至 2.7 g/cm<sup>3</sup> 之间 (Vassallo *et al.*,2015),因此研究区域的剩余密度值约为 1.1 g/cm<sup>3</sup>.

表 3 圣尼古拉斯矿床主要岩石单元的物理性质  
(Vassallo *et al.*,2015)

| Table 3 Physical properties of the main rock units of the St. Nicholas(Vassallo <i>et al.</i> ,2015) |                         |
|------------------------------------------------------------------------------------------------------|-------------------------|
| 岩石类型                                                                                                 | 密度/(g/cm <sup>3</sup> ) |
| 第三纪角砾岩                                                                                               | 2.3                     |
| 镁铁质火山岩                                                                                               | 2.7                     |
| 硫化物                                                                                                  | 3.5                     |
| 石英流纹岩                                                                                                | 2.4                     |
| 石墨质泥岩                                                                                                | 2.1                     |

设置密度先验信息为 1.1 g/cm<sup>3</sup>,为了使得反演网络能够更加准确的反演出圣尼古拉斯矿区地下硫化物的形状、位置及物性参数,重新生成模型密度为 1.1 g/cm<sup>3</sup> 数据集对反演网络进行训练.图 12 展示了重新训练的反演网络对圣尼古拉斯矿床实测数据的预测结果,(a)和(b)分别是矿体在 Northing = -400 m 和 BB'在 Easting = -1700 m 的垂向剖面,黑线为矿体实际轮廓.从图 12 中可以看出本文所提出的 GRC-UNet 网络其预测的分布是聚焦的,预测结果的位置信息与钻井信息基本吻合,预测模型反演出的异常源形状以及物理边界也与实际情况较为吻合.而 U-Net 网络反演出的结果虽位置信息与实际较为吻合,但是物理边界的反演相对模糊,尤其在深度加深时,预测结果分辨率开始下降,异常源底部的预测与实际情况有着较大的差异.因此在圣尼古拉斯实际地址资料的场景下,本文提出的 GRC-UNet 网络在预测深部异常体上有着更为明显的优势.

4 结 论

在本文中,我们使用 GRC 模块来代替 AFF-UNet 网络中的标准卷积,GRC 模块通过强制卷积过程中的网格采样位置同时满足空间位置和通道索引的条件,达到扩大感受野的目的,以获得更好的密集预测结果.与 AFF-UNet 网络的反演结果相比,GRC-UNet 在垂直方向上具有更高的分辨率,并且预测误差要小于 AFF-UNet;不同深度下的对比实验表明,对于地质体深部的模型,GRC-UNet 网络的重建效果基本上是优于 AFF-UNet. GRC-UNet 网络能够在 AFF-UNet 的基础上更大程度的缓解趋肤效应带来的影响,这将为获取地下异常体更深部位的高分辨率重建模型提供可行的途径.将本文所提出的反演网络用于预测墨西哥圣尼古拉斯矿床的实验结果证明了,反演网络能够基本圈定硫矿床的基本位置与

形状,网络具有一定的泛化性能,是一种很有前途的地下密度估算工具.

更进一步的,针对数值实验中随机模型 3D 视图与剖面图效果较差的问题有如下猜测:所添加的 GRC 模块本质上是为了捕获更多的特征在对原始信息进行卷积的过程中对不同通道采取了不同的采样位置,这便增加了所捕获信息的随机性,在此基础上,由于随机模型生成的特殊性,模型本身就具有着一定的随机性,在二重随机性的叠加下使得神经网络的预测效果产生些许的波动,但此猜测还需未来进行相关实验进行佐证.

致 谢 感谢审稿专家提出的修改意见和编辑部的大力支持!

References

Dai Y M, Gieseke F, Oehmcke S, *et al.* 2020. Attentional feature fusion. //2021 IEEE Winter Conference on Applications of Computer Vision. Waikoloa, HI, USA: IEEE, 3559-3568.

Huang R, Liu S, Qi R, *et al.* 2021. Deep learning 3D sparse inversion of gravity data. *Journal of Geophysical Research: Solid Earth*, 126 (11): e2021JB022476, doi: 10.1029/2021JB022476.

Johnson B J, Montante-Martinez A, Canela-Barboza M, *et al.* 2000. *Geology of the San Nicolas deposit, Zacatecas, Mexico*. VMS Deposits of Latin America: Geological Association of Canada, Mineral Deposits Division Special Publication, 2: 71-85.

Krizhevsky A, Sutskever I, Hinton G E. 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6): 84-90, doi: 10.1145/3065386.

Li Y B, Chen S, Zhang B, *et al.* 2023. Fast imaging for the 3D density structures by machine learning approach. *Frontiers in Earth Science*, 10: 1028399, doi: 10.3389/feart.2022.1028399.

Li Z L, Yao C L, Zheng Y M, *et al.* 2018. 3D magnetic sparse inversion using an interior-point method. *Geophysics*, 83(3): J15-J32, doi: 10.1190/GEO2016-0652.1.

Lü M, Zhang Y, Liu S. 2023. Fast forward approximation and multitask inversion of gravity anomaly based on UNet3+. *Geophysical Journal International*, 234(2): 972-984, doi: 10.1093/gji/ggad106.

Milletari F, Navab N, Ahmadi S A. 2016. V-Net: Fully convolutional neural networks for volumetric medical image segmentation. //2016 Fourth International Conference on 3D Vision. Stanford, CA, USA: IEEE, 565-571, doi: 10.1109/3DV.2016.79.

Nabighian M N, Ander M E, Grauch V J S, *et al.* 2005. Historical development of the gravity method in exploration. *Geophysics*, 70 (6): 63ND-89ND, doi: 10.1190/1.2133785.

Oh S, Noh K, Seol S J, *et al.* 2020. Cooperative deep learning inversion of controlled-source electromagnetic data for salt delineation. *Geophysics*, 85(4): E121-E137, doi: 10.1190/GEO2019-0532.1.

Phillips N, Oldenburg D, Chen J P, *et al.* 2001. Cost effectiveness of geophysical inversions in mineral exploration: Applications at San Nicolas. *The Leading Edge*, 20(12): 1351-1360, doi: 10.1190/1.1487264.

Ren X Y, Deng Z Y, Ye J, *et al.* 2025. FCN+: Global receptive convolution makes FCN great again. *arXiv*: 2303.04589, doi: 10.48550/arXiv.2303.04589.

Rezaie M, Moradzadeh A, Kalate A N, *et al.* 2017. Fast 3D focusing inversion of gravity data using reweighted regularized Lanczos bidiagonalization method. *Pure and Applied Geophysics*, 174(1):

- 359-374, doi: 10.1007/s00024-016-1395-8.
- Ronneberger O, Fischer P, Brox T. 2015. U-Net: Convolutional networks for biomedical image segmentation. //18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich, Germany: Springer, 234-241, doi: 10.1007/978-3-319-24574-4\_28.
- Vassallo L F, Aranda-Gómez J J, Solorio-Munguía J G. 2015. Hydrothermal alteration of volcanic rocks hosting the Late Jurassic-Early Cretaceous San Nicolas VMS deposit, southern Zacatecas, Mexico. *Revista Mexicana De Ciencias Geológicas*, 32(2): 254-272.
- Wang R, Ding Y M, Xu Z W, *et al.* 2024. Employing MS-UNets networks for multiscale 3-D gravity data inversion: A case study in the Nordkapp Basin, Barents Sea. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 4502813, doi: 10.1109/TGRS.2024.3362070.
- Xu Z W, Wang R, Zhdanov M S, *et al.* 2023. Inversion of the gravity gradiometry data by ResUnet network: An application in Nordkapp Basin, Barents Sea. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 4502410, doi: 10.1109/TGRS.2023.3271606.
- Yang Q G, Hu X Y, Liu S, *et al.* 2022. 3-D gravity inversion based on deep convolution neural networks. *IEEE Geoscience and Remote Sensing Letters*, 19: 3001305, doi: 10.1109/LGRS.2020.3047131.
- Yu F, Koltun V. 2016. Multi-scale context aggregation by dilated convolutions. //4th International Conference on Learning Representations. San Juan, Puerto Rico.
- Zhang L Z, Zhang G B, Fan Z Y, *et al.* 2022a. A multitask deep learning for simultaneous denoising and inversion of 3-D gravity data. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5923117, doi: 10.1109/TGRS.2022.3220437.
- Zhang L Z, Zhang G B, Liu Y, *et al.* 2022b. Deep learning for 3-D inversion of gravity data. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5905918, doi: 10.1109/TGRS.2021.3110606.
- Zhang Y J, Li H P, Qiu M X. 2024. 3D gravity anomaly forward and inversion algorithm based on improved LinkNet. *Progress in Geophysics (in Chinese)*, 39(6): 2219-2231, doi: 10.6038/pg2024HH0411.
- Zhang Z H, Liao X L, Cao Y Y, *et al.* 2021. Joint gravity and gravity gradient inversion based on deep learning. *Chinese Journal of Geophysics (in Chinese)*, 64(4): 1435-1452, doi: 10.6038/cjg202100151.

## 附中文参考文献

- 张玉洁, 李厚朴, 邱梦欣. 2024. 基于 LinkNet 网络的三维重力异常正反演算法研究. *地球物理学进展*, 39(6): 2219-2231, doi: 10.6038/pg2024HH0411.
- 张志厚, 廖晓龙, 曹云勇, 等. 2021. 基于深度学习的重力异常与重力梯度异常联合反演. *地球物理学报*, 64(4): 1435-1452, doi: 10.6038/cjg202100151.