

doi:10.3969/j.issn.2097-0013.2025.01.020

基于 U-Net 卷积神经网络的直流电阻率法数据重构

李泽扬¹, 马欢^{1,2*}, 张浩楠³, 代一龙¹, 李阳¹, 杨瀛彧¹

LI Ze-Yang¹, MA Huan^{1,2*}, ZHANG Hao-Nan³, DAI Yi-Long¹, LI Yang¹, YANG Ying-Yu¹

1. 防灾科技学院地球科学学院, 河北 三河 065201; 2. 河北省地震动力学重点实验室, 河北 廊坊 065000;
3. 防灾科技学院信息工程学院, 河北 三河 065201

1. School of Geoscience, Institute of Disaster Prevention, Sanhe 065201, Hebei, China; 2. Institute of Disaster Prevention, Langfang 065000, Hebei, China; 3. School of Information Engineering, Institute of Disaster Prevention, Sanhe 065201, Hebei, China

摘要: 本文针对地球物理电阻率法实测数据采集中因人文噪声引起的数据突变问题, 提出了一种基于卷积神经网络(CNN)的数据重构算法。鉴于电阻率法控制方程的非线性特征, 传统的线性插值技术可能导致反演结果精度下降。本研究首先构建了 CNN 模型, 并通过三维有限差分法进行电阻率法正演数值模拟, 生成训练集和测试集。利用训练集对 CNN 模型进行训练, 并基于损失函数结果优化 U-Net 网络参数。通过对比线性插值技术和 CNN 重构合成突变数据的反演结果, 验证了 CNN 在数据重构中的有效性和优越性。研究结果表明, U-Net-CNN 可以有效重构非线性直流电阻率法数据, 为提高地球物理数据采集精度和反演结果的可靠性提供了新的技术途径。

关键词: 卷积神经网络; 直流电阻率法; 数值模拟; 数据重构

中图分类号: P3

文献标识码: A

文章编号: 2097-0013(2025)-01-0240-09

Li Z Y, Ma H, Zhang H N, Dai Y L, Li Y and Yang Y Y. 2025. Data Reconstruction of Direct Current Resistivity Method Based on U-Net Convolutional Neural Network. *South China Geology*, 41(1): 240–248.

Abstract: In this paper, a data reconstruction algorithm based on Convolutional Neural Networks (CNN) is proposed for the issue of data mutation caused by humanistic noise in the geophysical resistivity method data acquisition. Given the nonlinear characteristics of the resistivity method control equation, the traditional linear interpolation techniques may lead to a decline in the accuracy of the inversion results. In this study, a CNN model is first constructed and numerical simulation of the resistivity method inversion is carried out by the three-dimensional finite difference method to generate a training dataset and a test dataset. The CNN model is trained using the training set and the U-Net network parameters are optimized based on the loss function results. By comparing the inversion results of data reconstructed with linear interpolation technique and CNN reconstruction of synthetic mutant data, the effectiveness and superiority of CNN in data reconstruction are verified. The results demonstrate that U-Net-CNN can effectively reconstruct nonlinear direct current

收稿日期: 2024-11-15; 修回日期: 2024-11-26

基金项目: 中央高校科研业务费专项(ZY20240305)、廊坊市青年拔尖人才项目(XY202304)、廊坊市科学技术研究与发展计划自筹经费项目(NO.2023013173)

第一作者: 李泽扬(2000—), 男, 硕士研究生, 从事地球物理电法数值模拟计算方面的研究, E-mail: lzy_522@126.com

通讯作者: 马欢(1988—), 男, 博士, 副教授, 从事地球物理电法和磁法勘探及其数值模拟高性能并行计算方面的研究, E-mail: xiongha@hotmail.com

resistivity method data, providing a new technical approach to improve the accuracy of geophysical data acquisition and the reliability of inversion results.

Key words: Convolutional Neural Network; direct current resistivity method; numerical simulation; data reconstruction

在电子数字计算机技术的诞生及其迅猛发展背景下,结合正演理论与反演理论的深入研究,地球物理电阻率法的数据处理、正演计算及反演计算领域取得了显著进展,特别是在三维反演方法的精确度和可靠性方面(陶涛等, 2024)。然而,由于人为噪声的干扰以及数据采集过程中地形环境的限制,部分测量点的数据出现了缺失或异常变化,这增加了反演过程中的多解性问题,对地下电阻率模型的准确反演成像造成了显著影响,进而对地质解释的准确性带来了挑战。因此,迫切需要开发一种高效的数据重构技术,以优化电阻率法数据的完整性和可靠性。

在地球物理电阻率法的数据处理领域,控制方程通常表现为非线性泊松方程。针对该方程的数据重构问题,本质上是一个非线性问题。传统的线性插值法在分辨率和精度上存在局限性,其有效性依赖于线性假设的满足(邵才瑞等, 2005; 俞建宝等, 2009; 吴佳伟, 2023)。邢强和韩爱香(2013)通过压缩感知技术实现了过套管电阻率数据的重构。他们利用测点深度与缺失数据深度之间的匹配关系构建观测矩阵,并采用正交匹配追踪(OMP)算法来解决 L1 范数最小化问题,从而获得重构数据,尽管这种方法在非线性数据处理上取得了一定成效,但其并不适用于地表直流电阻率法数据的重构。因此,探索适用于电阻率法突变数据的非线性重构方法成为了该领域的研究重点。

在近年来的研究中,人工智能(AI)与深度学习技术在多个学科领域展现出了显著的活跃性(李明等, 2023; 何睿等, 2024; 王方等, 2024)。深度学习技术通过构建深层非线性网络结构,已被证实能够有效逼近复杂函数,并在输入数据的分布式表示中捕捉其本质特征。特别是深度学习技术已展现出从有限样本集中提取数据集核心特征的强大能力。在直流电阻率法探测领域,众多学者已经进行了系统的探索。例如,部分研究者采

用人工神经网络(ANN)算法、免疫遗传算法优化的 BP 神经网络算法(颜钟, 2012; 张喆等, 2024),以及自适应神经网络算法(Jiang F B et al., 2018),实现了地面直流电阻率探测的反演。此外,还有研究利用多种群遗传优化的 ANN 神经网络算法,成功实现了井孔直流电阻率法探测的反演。Lecun et al.(1998)提出的卷积神经网络(CNN)是首个真正意义上的多层结构学习算法,这一算法在处理非线性地下情况时显示出了其独特的优势,无需特定约束条件,能够直接通过各层网络进行特征训练,以达到理想的反演结果。

在众多神经网络模型中,U-Net 在图像分割领域扮演着举足轻重的角色。该网络框架在处理非线性数据时展现出了卓越的特征提取能力、上下文信息保留、灵活的网络结构设计、有效的上采样技术以及稳健的性能。自 U-Net 被提出以来,其迅速获得了广泛的关注和认可,尤其在生物医学研究领域表现突出(唐云飞等, 2024; 齐琪等, 2024; 张瀚文等, 2024)。在地震领域,众多学者对 U-Net 网络进行了定制化改进,以解决地震成像问题(胡阳等, 2022; 张岩等, 2023)。改进后的网络模型对特征的感知更为敏锐,能够更有效地还原有效信号的细节信息,实现高度准确的重建。因此,本研究采用基于 U-Net 的卷积神经网络对电阻率法数据进行数据重构,旨在减少突变数据造成的反演多解性问题,为后续的处理和解释工作奠定基础。

1 方法原理

1.1 电阻率法正演

电阻率法的基本方程和边界条件可表示为:

$$\nabla \cdot (\sigma \nabla \varphi) = -I\delta, \quad (1)$$

$$\frac{\partial \varphi}{\partial n} = 0, \quad (2)$$

$$\frac{\partial \varphi}{\partial n} + \frac{\cos \theta}{r} = 0, \quad (3)$$

其中式(1)为三维地电场电位满足的泊松方程 (Loke et al., 2013), σ 为电导率, φ 为电位向量, δ 为狄拉克函数, I 为供电电流强度。第二类边界条件通常用于描述绝缘边界(没有电流通过边界)或电流通过边界的情况。在地表与空气分界面采用第二类边界条件, 见式(2); 第三类边界条件可能涉及到边界上电势和电流的关系, 常用于描述导电性、边界电流源或复杂边界条件的情况。在无穷远处采用第三类边界条件, 见式(3), r 为点电源与边界点的距离, θ 为边界点外法向向量与 r 的夹角。

直流电阻率法正演的核心挑战在于应用数值技术来解决给定电阻率和场源分布条件下的稳定电流场的边界值问题。存在多种数值模拟技术, 包括但不限于有限差分法 (Wu X P et al., 2003)、有限元法 (Ren Z Y and Tang J T, 2010) 和有限体积法 (Du H K et al., 2016)。在本研究中, 选用有限差分法, 在求解方程时应用迭代技术, 确保数值模拟在计算时间和内存需求上的可行性。利用有限差分网格, 离散泊松方程(1)和其边界条件(2)和(3), 形成了一个大型的线性方程组:

$$A\varphi = b, \quad (4)$$

其中 A 为系数矩阵, b 为含有场源信息的向量。

再采用预处理共轭梯度法求解线性方程组, 获得电位, 进而利用 MN 之间的电位差求得正演结果(视电阻率)。视电阻率不是岩石的真电阻率, 是地下电性不均匀体和地形起伏的一种综合反映, 其公式如下所示:

$$\rho_a = K \frac{\Delta U_{MN}}{I}, \quad (5)$$

其中 ρ_a 为视电阻率, ΔU_{MN} 则是地表 M 、 N 两测点之间的电位差, I 是供电电流强度, K 是装置系数。本文采用的是温纳装置, 其装置系数为 $2\pi a$, a 为装置的电极距。

1.2 U-Net 网络

在本项研究中, 我们对 U-Net 架构进行了特定的优化调整, 具体结构详见图 1。U-Net 网络采用了编码-解码结构, 其结构形态类似于字母"U", 因而得名。在编码阶段, U-Net 与标准卷积神经网络相似, 均采用 3×3 卷积核进行卷积运算, 并在卷积后引入激活函数及批量归一化层, 其中激活函数选用 ReLU 函数。随后, 通过 2×2 的最大池化操作, 步长设置为 2, 该过程重复三次, 网络的通道数从初始的 64 增加至 1024, 同时图像尺寸在下采样过程中逐渐减小, 特征信息得以逐步提取。在解码阶段, 首先执行 2×2 的转置卷积操作, 使图像尺寸扩大四倍, 逐步恢复压缩后的图像。




图 1 U-Net 网络结构图

Fig. 1 U-Net Network Architecture

随后,将解码阶段的当前层与编码阶段对应的特征层进行拼接,确保即使在深层网络中,浅层网络提取的特征信息得以保留。通过浅层与深层信息的融合,有效保留了边缘和细节信息,防止其丢失。接着,通过 3×3 卷积核减少通道数,最终通过输出层输出网络信息。此外, U-Net 网络中还引入了 Dropout 层,特别是在编码的最后一层和全连接层中应用了该结构。Dropout 层在训练过程中随机丢弃部分信息,有助于减轻网络的过拟合现象。

U-Net 的核心优势在于其独特的特征复制和拼接机制。在网络的中间阶段,编码过程中通过卷积和池化提取的图像特征会被复制,并与解码过程中的卷积和上采样结果进行拼接。这种设计使得在解码阶段的上采样过程中,网络能够同时保留深层和浅层的特征信息。通过这种方式, U-Net 不仅能够捕捉到图像中的大尺度结构信息,还能够保留小尺度的细节信息。在网络训练过程中,训练参数的调整对于实现数据重构的最佳效果至关重要,为了使网络模型达到最佳的重构性能,对学习次数、批次大小、学习误差、步长和超参数等训练参数进行了调整和优化。通过不断的实验和迭代,确定了各参数的最佳组合,从而使模型在数据重构任务中展现出优越性。

2 实验结果

2.1 模型建立及网络训练

本文构建了 20 套用于训练的二维电阻率理论模型,其中包括水平层状介质、阶梯层状介质、倾斜脉状介质、球形介质及不规则状介质等,多套模型侧重于水平层状介质。图 2 为本文使用的数据集示例图,其观测系统采用温纳装置,测线长度为 220.5 m,电极距 a 为 3.5 m,共布设电极 64 个。图 2a 是地电模型,图 2b 是正演视电阻率数据拟断面图,图 2c 是根据实际数据采集过程中可能出现的问题,对视电阻率(b)的某一道数据进行突变处理。地电模型共设置了 20 套,每一套做出 61 组突变数据,共形成 1220 组突变数据作为数据集,其中训练集 1219 组,预测集 1 组。

在本研究中,为了优化 U-Net 模型性能,设置模型批次大小为 64 个,进行了 5 次超参数调整实验,其超参数包括:学习次数、学习误差、步长和超参数 β_1 ,如表 1 所示。5 次超参数调整实验遵循单一变量原则,即在每次实验中仅改变一个超参数,以此来观察其对模型损失值的影响。

图 3a、3b 表明,第二次测试(图 3b)所采用的参数配置,不仅损失值较小,而且在训练过程中显




图 2 数据集构建示例图

Fig. 2 Example of dataset construction

a.地电模型; b.正演视电阻率数据拟断面图; c.做突变处理的视电阻率拟断面图

表 1 U-Net 模型的 5 次超参数调整设置

Table 1 5 hyperparameter adjustment settings for the U-Net model

调整次数(次)	学习次数(次)	学习误差	步长	超参数 $\beta 1$
1	1000	0.001	10	0.9
2	800	0.001	10	0.9
3	1000	0.001	20	0.9
4	600	0.001	20	0.9
5	600	0.000 1	20	0.9

示出更好的稳定性。这表明所选参数在促进模型收敛方面具有显著效果。基于这些观察和分析,最终确定使用第二组训练参数,以实现最佳的模型性能。这些超参数的选择旨在平衡模型的学习能力、泛化能力以及训练效率。

2.2 预测集数据结果与分析

在对网络性能的测试方面准备了三个地电模型,分别是水平层状介质,倾斜脉状介质和不规则状介质,由其构成预测集。之后使用 U-Net 卷积神经网络与线性插值重构技术在预测集数据上的应用进行了对比分析。

2.2.1 水平层状介质模型

图 4 所示,地电模型中存在三个形态为矩形的二维异常体。背景场的电阻率对数值为 3。低阻异常体的电阻率对数值为 2.84,其中异常体 1 的顶部距地面 2.8 m,长度为 182 m,厚度为 9 m;异常体 2 的顶部距地面 13.6 m,长度为 185.5 m,厚度为 6.1 m;异常体 3 的电阻率对数值为 3.20,其顶部距地面 26.7 m,长度为 140 m,厚度为 8.7 m。




图 3 不同超参数配置下 U-Net 模型的损失值

Fig. 3 The loss value of the U-Net model under different hyperparameter configurations

a.第 1、2、3、4、5 次的超参数配置;b.第 2、5 次的超参数配置




图 4 水平层状介质地电模型

Fig. 4 Horizontal stratified medium geoelectric model

突变数据导致反演模型的几何形态出现严重畸变(图 5b),从而增加了反演过程中的多解性。在视电阻率值的重构效果方面,U-Net 网络重构的数据(图 5c)与无突变数据(图 5a)在背景场和异常体的视电阻率值上保持了较好的一致性。相比之下,线性插值重构数据(图 5d)在深度 30 m 附近的视电阻率数据与无突变数据(图 5a)差异较大,这可能导致反演结果的不准确,并使异常体的形态发生变化。进一步分析,U-Net 网络重构数据的视电阻率拟断面图(图 5c)与无突变的合成数




图 5 水平层状介质视电阻率拟断面图

Fig. 5 Apparent resistivity pseudo-section diagrams of horizontal layered media

a. 无突变的合成视电阻率拟断面图; b. 突变的合成视电阻率拟断面图; c. 基于 U-Net 卷积神经网络重构后的计算视电阻率拟断面图; d. 基于线性插值法重构后的计算视电阻率拟断面图

据视电阻率拟断面图(图 5a)在异常体形态上十分接近, 均保持了异常体形态特征。而线性插值重构数据的视电阻率拟断面图(图 5d)中, 异常体形态呈现模糊状, 这表明传统的线性数据重构方法在保持数据的原始特征方面存在不足。

2.2.2 倾斜脉状介质模型

由图 6 可知, 地电模型中存在一个形态为矩形的二维异常体。该异常体的背景场电阻率对数值为 3。异常体的电阻率对数值为 3.17, 其顶部距地面 2.8 m, 长度为 140 m, 厚度为 19.5 m。异




图 6 倾斜脉状介质地电模型

Fig. 6 Inclined vein-like medium geoelectric model

常体内部被一条倾斜脉状介质分隔, 该脉状介质的电阻率对数值为 2.68。

突变数据(图 7b)导致反演模型的几何形态出现严重畸变, 进而增加了反演过程中的多解性问题。在视电阻率值的重构效果方面, U-Net 网络重构的数据(图 7c)与无突变数据(图 7a)在背景场和异常体的视电阻率值上保持了较好的一致性。而线性插值重构数据(图 7d)在多处与原模型的视电阻率存在较大差异, 这可能导致反演结果的不准确, 并使异常体的形态发生变化。进一步分析, U-Net 网络重构数据的视电阻率拟断面图(图 7c)与无突变的合成数据视电阻率拟断面图(图 7a)在异常体形态上非常接近, 保持了异常体的原有特征。相比之下, 线性插值重构数据的视电阻率拟断面图(图 7d)中异常体的形态发生了变化, 虽然大致可以看出异常体的位置, 但其形态与原模型存在巨大差别。




图 7 倾斜脉状介质视电阻率拟断面图

Fig. 7 Apparent Resistivity Pseudo-Section Diagram of Inclined Vein-Like Media

a. 无突变的合成视电阻率拟断面图; b. 突变的合成视电阻率拟断面图; c. 基于 U-Net 卷积神经网络重构后的计算视电阻率拟断面图; d. 基于线性插值法重构后的计算视电阻率拟断面图

2.2.3 不规则状介质模型

根据图 8 所示, 地电模型中存在一个不规则形态的二维异常体。该异常体的背景场电阻率对

数值为 3, 异常体的电阻率对数值为 3.17, 其顶部距地面 5 m, 底部距地面 22.3 m。




图 8 不规则状介质地电模型

Fig. 8 Irregular-shaped medium geoelectric model

突变数据(图 9b)导致反演模型的几何形态出现严重畸变, 增加了反演过程中的多解性。在视电阻率值的重构效果方面, U-Net 网络重构的数据(图 9c)与无突变数据(图 9a)在背景场和异常体的视电阻率值上保持了较好的一致性。相比之下, 线性插值重构数据(图 9d)导致异常体形态发生变形, 与原模型存在较大差异, 这可能会导致反演结果的不准确; U-Net 网络重构数据的视电阻率拟断面图(图 9c)与无突变的合成数据视电阻率拟断面图(图 9a)在异常体形态上十分接近, 保持了异常体的原有特征。而线性插值重构数据的视电阻率拟断面图(图 9d)中, 背景场及异常体中的视电阻率值在多处偏高, 这表明传统的线性数据重构方法不足以保持数据的原始特征。

2.3 实测数据结果与分析实例

在北京市平谷区纪太务村的农田区域, 我们布置了一条基于直流电阻率法的地球物理观测剖面。该观测系统的配置严格遵循了既定的理论模型, 具体参数如下: 测线总长度为 220.5 m, 电极间距设定为 3.5 m, 沿东西方向共布置了 64 根电极。在电极布置过程中, 由于一个较大的碎石堆的存在, 导致了显著的接地电阻增加, 进而在观测数据中引发了数据突变现象(图 10a)。这一突变在反演结果(图 10b)中表现为第十道和第十四道数据处电阻率为异常高峰值, 该现象可能被误判为高阻地质体的顶部, 从而掩盖了该区域的实际地质特征, 增加了反演过程中的多解性, 导致反演模型无法与观测数据实现良好的拟合, 进而影响




图 9 不规则状介质视电阻率拟断面图

Fig. 9 Apparent Resistivity Pseudo-Section Diagram of Irregular Media

a. 无突变的合成视电阻率; b. 突变的合成视电阻率; c. 基于 U-Net 卷积神经网络重构后的计算视电阻率; d. 基于线性插值法重构后的计算视电阻率

了资料的处理与解释。

为了有效解决上述问题, 本研究采用了 U-Net 卷积神经网络技术对突变的视电阻率数据进行重构处理。重构后的数据(图 10c)在数据突变处显示出了恢复正常的趋势, 避免了对实际异常体的覆盖, 有效恢复了视电阻率数据的连续性, 并减少了反演过程中的多解性。进一步的反演结果(图 10d)显示, 几何形态已恢复正常, 原先的高阻异常高峰和深部低阻异常均已消失, 使得模型更加符合实际的地质结构。重构数据为反演过程提供了精确和可靠的结果, 并且与观测数据的拟合程度较好, 成功恢复了地下介质的电性结构。

综上所述, 本研究通过应用 U-Net 卷积神经网络技术, 有效地解决了由于接地电阻增加导致的视电阻率数据突变问题, 提高了直流电阻率法在地质结构探测中的准确性和可靠性。

3 讨论

我们构建了如图 2a 所示的地电模型, 其目的




图 10 实测、重构数据视电阻率拟断面图 (a、c) 与反演模型电阻率断面 (b、d)

Fig. 10 Comparison of measured reconstructed data apparent resistivity pseudo-section (a, c) and inversion model resistivity section (b, d)

a. 实测数据视电阻率拟断面图; b. 实测数据反演模型电阻率断面; c. 基于 U-Net 卷积神经网络重构后的计算视电阻率拟断面图; d. 基于 U-Net 卷积神经网络重构后的反演模型电阻率断面

在于对实测数据中的突变部分进行有效重构。通过分析实测数据, 观察到地下结构呈现出一定的层状特征。为了捕捉这些特征并增强 U-Net 网络对突变数据的重构能力, 在构建地电模型时侧重于对层状结构的模拟。地下结构的真实形态是未知且可能极为复杂的, 这要求我们在地电模型构建过程中不仅要考虑单一的层状模型, 还需要考虑多种可能的地质模型。因此提高该网络的泛化能力可以从两个方面进行入手。

首先是对超参数的调整方法, 在本研究的实验环节中, 对超参数进行精确调整是实现模型最优性能的核心过程。超参数的最优值需要通过实验和迭代过程来确定。通过系统地调整表 1 中的各个超参数, 并观察其对训练结果的影响, 识别出最佳的超参数组合。这一过程涉及到对每个超参数单独进行微调, 同时综合考量其他超参数的设置, 以实现整体训练效果的最优化。比如我们将探索多种策略以优化超参数配置, 确保模型性能达到最佳。这些策略包括但不限于网格搜索、随机搜索、交叉验证, 以及贝叶斯优化等先进的超参数调整方法。通过这些方法, 我们旨在系统地遍历超参数空间, 识别出能够提高模型泛化能力和准确性的最佳超参数组合。

其次是突变数据与训练集的关系, 针对突变数据占比的增加, 是否需要扩充训练集? 如果突变数据占比上升, U-Net 网络难以捕捉数据的完整模式, 而训练集的完整性对网络的学习至关重要。然而, 单纯增加训练集的数量并非总是最佳

方法, 应提升训练集的质量和多样性; 如果维持训练集的大小不变, 突变数据占比增加, 这可能会导致该网络因训练不充分而对视电阻率数据过度拟合, 从而降低其泛化能力。这种过度拟合可能会在测试集或实际应用中导致网络训练效果降低, 进而增加数据重构的偏差。

虽然本研究主要集中于使用 U-Net 卷积神经网络与线性插值法的比较, 但我们也认识到了探索其他数据重构方法的重要性。未来的工作将包括与多项式插值法、最小二乘法和趋势面分析法等传统和现代重构技术的对比实验。通过这些比较, 我们期望进一步细化和完善基于卷积神经网络的数据重构方法, 以实现更高的重构精度和效率。

4 结论

本文开发了一种基于 U-Net 卷积神经网络的直流电阻率法数据重构算法, 该技术通过将突变的视电阻率数据输入网络, 利用网络的预测能力重构数据。

(1) 在处理直流电阻率法数据重构的非线性问题时, 实验结果表明, 采用 U-Net 卷积神经网络的方法在直流电阻率法数据重构效果较好, 其不仅可以为反演提供可靠的结果, 也表现了网络具有较好的鲁棒性和稳定性。

(2) 基于 U-Net 卷积神经网络的直流电阻率法数据重构算法为反演减少了多解性, 凸显了深度学习技术在地球物理领域数据重构任务中的应

用潜力,为未来的研究和应用提供了重要的理论基础和实践参考。

参考文献:

- 何睿,王润,徐航,刘帅,李彧磊,张硕,陈琨,蔡宇,陈梦源.2024.基于 U-Net 的湖北省露天矿山土地损毁信息提取应用[J].资源环境与工程,38(1):100-110.
- 胡阳,汪玲玲,陈海洋,杜子豪.2022.基于 SE V-Net 的三维地震数据断层识别方法[C].2022 年中国石油物探学术年会论文集(下册),514-517.
- 李明,蒋委君,董佳慧,金少锋,张宸伟,牛瑞卿.2023.基于机器学习的滑坡灾害易发性评价——以三峡库区为例[J].华南地质,39(3):413-427.
- 齐琪,苏英峰,王晶.2024.基于 U-net 上气道流体力学分析研究[J].医用生物力学,39(S1):422.
- 邵才瑞,关丽,张福明.2005.基于测井数据的地质曲面插值重构方法比较[J].测井技术,29(4):311-315+388.
- 唐云飞,但志平,洪郑天,陈永麟,程沛霖,成果,刘芳婷.2024.CAMU-Net:基于 Attention U-Net 的视网膜血管分割改进模型[J].中国医学物理学杂志,41(8):960-968.
- 陶涛,韩鹏,马欢,谭捍东.2024.时移电阻率法三维反演研究[J].地球物理学报,67(10):3973-3988.
- 王方,熊杰,田慧潇,李思平,康佳帅.2024.基于深度学习的大地电磁二维反演方法[J].地质科技通报,43(2):344-354.
- 吴佳伟.2023.基于径向基函数的大地电磁数据重构[D].中国地质大学(北京)硕士学位论文.
- 邢强,韩爱香.2013.基于压缩感知的过套管电阻率数据重构方法研究[J].石油仪器,27(1):46-48+9.
- 颜钟.2012.基于 BP 人工神经网络的高密度电法反演理论应用研究[D].长江科学院硕士学位论文.
- 俞建宝,陈高,李正文,张杨.2009.基于双谱信号重构的物探数据插值方法[J].勘探地球物理进展,32(5):326-329+307.
- 张岩,周一帆,宋利伟,董宏丽.2023.基于物理约束 U-Net 网络的地震数据低频延拓[J].石油地球物理勘探,58(1):31-45.
- 张喆,马福恒,霍吉祥.2024.基于 BP 神经网络的高密度电法在水库清淤扩容坝后排泥区围堰探测中的应用[J].水电能源科学,42(5):174-178.
- 张瀚文,曹维娟,罗刚银,江浩,邱香,许杰,史蓉蓉,郑然.2024.基于改进型 U-Net 的变色油墨血浆判别模型[J].南京医科大学学报(自然科学版),44(9):1179-1189.
- Du H K, Ren Z Y, Tang J T. 2016. A finite-volume approach for 2D magnetotellurics modeling with arbitrary topographies[J]. Studia Geophysica et Geodaetica, 60(2): 332-347.
- Jiang F B, Dong L, Dai Q W. 2018. Electrical resistivity imaging inversion: An ISFLA trained kernel principal component wavelet neural network approach[J]. Neural Networks, 104: 114-123.
- Lecun Y, Bottou L, Bengio Y, Haffner P. 1998. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 86(11): 2278-2324.
- Loke M H, Chambers J E, Rucker D F, Kuras O, Wilkinson P B. 2013. Recent developments in the direct-current geoelectrical imaging method[J]. Journal of Applied Geophysics, 95: 135-156.
- Ren Z Y, Tang J T. 2010. 3D direct current resistivity modeling with unstructured mesh by adaptive finite-element method[J]. Geophysics: Journal of the Society of Exploration Geophysicists, 75(1): H7-H17.
- Wu X P, Xiao Y F, Qi C, Wang T T. 2003. Computations of secondary potential for 3D DC resistivity modelling using an incomplete Choleski conjugate - gradient method[J]. Geophysical Prospecting, 51(6): 567-577.