

# 遗传算法在瞬变电磁深度学习反演中的优化策略\*

吴文宇, 张莹莹<sup>†</sup>, 吴新宇, 谢斌

(新疆大学 地质与矿业工程学院, 新疆 乌鲁木齐 830017)

**摘要:** 瞬变电磁一维反演技术已在地质工程中得到了广泛应用, 但是该方法较为依赖初始模型, 抗噪能力较差, 难以实现实时反演. 针对上述问题, 采用卷积长短期记忆(CNN-LSTM)混合神经网络, 利用回线源瞬变电磁一维正演程序得到的采样时间-衰减电压作为网络输入数据, 同时采用Adam优化器与ReduceLRonPlateau学习率调度器相结合的优化策略自适应调整学习率. 针对网络结构超参数设置依赖经验值、缺乏科学性导致的算力以及时间浪费问题, 在模型训练阶段采用遗传算法(GA)对神经网络结构进行超参数寻优, 提高模型性能. 最终, 在输出层得到与输入的电磁响应数据对应的深度-电阻率数据, 实现瞬变电磁数据深度学习反演. 利用训练后的GA-CNN-LSTM网络对随机生成的3层模型以及5层模型进行实时预测, 测试集评价指标 $R^2 > 0.9$ , 验证了所提算法的可靠性. 进一步对加噪数据进行反演, 完成训练的神经网络对4种常见模型的平均反演用时为0.13 s, 平均反演结构相似度达90.138%, 两项指标均优于Occam以及LSTM反演方法. 进一步对三维正演模型进行数据反演, 验证了所提算法的泛化能力. 最后, 对实测数据分别进行了Occam反演和神经网络反演, 在保证反演精度的同时, 完成训练的神经网络仅用时0.73 s, 表明所提算法具有实用性.

**关键词:** 瞬变电磁法; 深度学习; 遗传算法; 超参数优化

**DOI:** 10.13568/j.cnki.651094.651316.2025.03.31.0005

**中图分类号:** P631 **文献标识码:** A **文章编号:** 2096-7675(2025)03-0280-020

**引文格式:** 吴文宇, 张莹莹, 吴新宇, 谢斌. 遗传算法在瞬变电磁深度学习反演中的优化策略[J]. 新疆大学学报(自然科学版中英文), 2025, 42(3): 280-299.

**英文引文格式:** WU Wenyu, ZHANG Yingying, WU Xinyu, XIE Bin. Optimization strategy of genetic algorithm in transient electromagnetic deep learning inversion[J]. Journal of Xinjiang University(Natural Science Edition in Chinese and English), 2025, 42(3): 280-299.

## Optimization Strategy of Genetic Algorithm in Transient Electromagnetic Deep Learning Inversion

WU Wenyu, ZHANG Yingying, WU Xinyu, XIE Bin

(School of Geology and Mining Engineering, Xinjiang University, Urumqi Xinjiang 830017, China)

**Abstract:** Transient electromagnetic (TEM) 1D inversion has been widely applied in geological engineering, yet these conventional methods remain constrained by strong dependence on initial models, limited noise resistance, and inefficiency in achieving real-time inversion. To address these challenges, we propose a convolutional neural network-long short-term memory hybrid architecture tailored to the inherent characteristics of TEM inversion. Using loop-source TEM 1D forward modeling, we generate training data comprising sampling time-decay voltage pairs as network inputs. An optimization strategy combining the Adam optimizer with the ReduceLRonPlateau learning rate scheduler is implemented to adaptively adjust learning rates during parameter updates. In view of the problem that the hyper-parameter setting of the current network structure depends on the empirical value and lacks scientificity, which leads to the waste of computing power and time, the genetic algorithm is proposed to optimize the hyper-parameters of the neural network structure in the model training stage to reduce the training cost and improve the model performance. The output layer provides subsurface resistivity-depth profiles corresponding

\* 收稿日期: 2025-03-31

基金项目: 新疆维吾尔自治区重点研发计划“新疆天山及邻区早二叠世金镍重大成矿事件与找矿评价关键技术开发”(2024B03005-3).

作者简介: 吴文宇(1998—), 男, 硕士生, 从事计算电磁地球物理的研究, E-mail: Wuwenyu@163.com.

<sup>†</sup> 通讯作者: 张莹莹(1989—), 女, 博士, 副教授, 主要从事瞬变电磁场理论与应用的研究, E-mail: zhanggy19890423@163.com.

to input electromagnetic responses, enabling deep learning-based TEM inversion. The trained GA-CNN-LSTM network demonstrates robust performance in real-time predictions for randomly generated three-layer and five-layer models, with validation metrics yielding  $R^2 > 0.9$ . Further evaluation using noise-contaminated data reveals that the optimized network achieves an average inversion time of 0.13 s and a structural similarity index of 90.138% across four common models, outperforming both Occam and LSTM inversion methods. Generalization capability is validated through successful inversion of 3D forward modeling data. These results demonstrate the algorithm's reliability, computational efficiency, and practical utility in complex geological scenarios. Finally, Occam inversion and neural network inversion are carried out on the measured data respectively. The trained neural network only take 0.73 s to complete the inversion accuracy, which verifies the practicability of the algorithm in this paper.

**Key words:** transient electromagnetic method; deep learning; genetic algorithm; hyper-parameter optimization

## 0 引言

随着我国对矿产资源需求的不断提升,特别是在工业和基础设施建设的背景下,一些埋藏较浅的矿床已经面临过度开采而逐渐枯竭的局面<sup>[1]</sup>.这不仅加剧了我国矿产资源的紧张局势,也使得国际矿产资源市场的竞争变得更加激烈.深部隐伏矿产资源的勘查开发工作已上升至国家资源安全战略高度,国际矿业界公认的“第二找矿空间”正成为新一轮找矿突破的主战场<sup>[2]</sup>.深部探测面临以下技术瓶颈:其一,目标体埋深增大导致地球物理场响应信号呈指数级衰减,常规观测系统信噪比显著降低;其二,复杂地质构造产生的多源干扰场与目标信号形成混叠效应,地表环境噪声干扰严重;其三,现有地球物理方法的分辨率随深度增加急剧下降;这些技术障碍严重制约着深部成矿信息的有效提取与精准解译.提升传统地球物理勘查方法的探测精度、抗噪能力以及反演效率<sup>[3-5]</sup>成为当务之急.瞬变电磁法是一种以电磁感应为基础的时间域电磁勘查方法<sup>[6]</sup>,具有分辨率高、施工成本低、探测深度大、对良导体探测能力强<sup>[7]</sup>等优势,在矿产资源勘探<sup>[8-12]</sup>、水文地球物理勘探<sup>[13-15]</sup>、工程地质调查<sup>[16-18]</sup>等领域得到了广泛应用.

瞬变电磁法工作原理是通过不接地回线或接地长导线向地下供以脉冲电流,当回线中的稳定电流被突然切断后,地下介质因电磁感应产生二次感应电磁场<sup>[19]</sup>.通过接收线圈测量二次场信号,并分析其随时间变化的衰减特性,可以推断地下介质的电性结构,从而解决相关地质问题<sup>[20]</sup>.解析瞬变电磁二次场信号最有效的手段是反演.反演不仅能够还原地下介质的物理特性(如电阻率分布等),还能实现结果的可视化,为后续地质解释和工作设计提供直观依据.传统的线性化反演方法虽然计算效率较高,但其基于模型参数与数据之间线性关系的假设,导致反演效果依赖初始模型的选择<sup>[21]</sup>.实际地质环境中,地下介质的电性分布往往具有强烈的非线性特征,使得基于线性假设的反演方法容易产生偏差,难以实现高精度反演.

尽管高精度的三维反演方法能够更好地刻画复杂的地质结构,但受限于庞大的计算量和复杂的三维正演过程,反演效率较低<sup>[22]</sup>,且难以在实际生产中大规模应用.相比之下,完全非线性反演方法不需要计算雅可比矩阵,能够有效避免陷入局部最优解,因而在理论上更具优势.国内外学者已成功将多种非线性优化算法应用于瞬变电磁反演,如遗传算法<sup>[23]</sup>、粒子群算法<sup>[24-26]</sup>、模拟退火算法<sup>[27]</sup>等.这些方法在处理非线性问题时表现出较强的鲁棒性,但面对大规模数据时,由于正反演理论和数据处理过程复杂<sup>[28]</sup>,该类方法仍面临计算效率和稳定性挑战.基于神经网络的反演方法通过模型训练建立地电模型物性参数和电磁响应之间的矩阵映射关系<sup>[29]</sup>,如BP神经网络<sup>[30-31]</sup>、遗传神经网络<sup>[32]</sup>等模型,已被成功应用于瞬变电磁的数据处理问题.

基于深度神经网络的深度学习反演以及成像方法近年也得到广泛研究.Colombo等<sup>[33]</sup>将物理驱动的反演方法与深度学习相结合,形成了一种耦合的物理驱动/深度学习反演方案.该方法通过惩罚函数的方式将深度学习网络的预测结果用于约束最小二乘反演,同时将反演的部分结果反馈给深度学习网络进行重新训练.Puzryev等<sup>[34]</sup>将卷积神经网络(Convolutional Neural Network, CNN)用于瞬变电磁反演,该方法可直接从时域瞬变电磁信号反演一维电阻率模型,通过使用多个网络并结合不同训练时期的输出来提供电阻率异常区域不确定性的分布信息.洗锦炽等<sup>[35]</sup>采用CNN与长短期记忆(Long Short-Term Memory, LSTM)网络组合架构,通过B样条插值生成训练数据集,实现了对大规模地面拖拽式瞬变电磁数据的快速成像.范涛等<sup>[36]</sup>将LSTM网络与编码器-解码器结构结合,实现了瞬变电磁数据的端到端反演,还引入深度损失函数优化地层位置预测.三维模型测试显示,该方法显著提升异常体边界分辨率,并且反演速度基本实现实时水平.Asif等<sup>[37]</sup>提出了一种基于深度卷积自编码器的专家系统,引入卷积自编码器以识别数据中的耦合异常,用于自动处理地面和航空瞬变电磁数据中的电磁耦合问题.燕帅等<sup>[38]</sup>将CNN引入时间域瞬变电磁成像研究中,对比传统Occam反演,该算

法成像更加迅速灵活. 程久龙等<sup>[39]</sup>基于钻孔瞬变电磁数据, 提取感应电动势、视电阻率、衰减速率等特征, 结合Archie公式和Kozeny-Carman公式建立电阻率与富水性等级的映射关系, 并将该方法成功应用于煤矿水力压裂效果评估. 古瑶等<sup>[40]</sup>结合CNN和双向LSTM网络(BiLSTM), 利用CNN提取空间特征, BiLSTM捕捉时间依赖性, 并引入Attention机制动态加权关键信息. 通过扩充已有的钻孔数据进行了6层模型的深度学习训练, 仿真结果证明混合神经网络的反演效果优于单一神经网络. 王云宏<sup>[41]</sup>利用Transformer神经网络结合自注意力机制实现瞬变电磁响应的高效预测, 为深度学习反演提供了高质量的训练数据基础. Kang等<sup>[42]</sup>开发了一个集成的算法流程, 使用基于深度学习的方法处理和反演机载瞬变电磁(Airborne Transient Electromagnetic, ATEM)数据.

神经网络结构中的超参数设置依赖经验值, 缺乏针对性与科学性. 瞬变电磁数据既有空间相关性又具备指数衰减形式的时间序列特征, 因此, 单一的神经网络结构对于瞬变电磁数据的特征提取能力稍显逊色. 本文基于回线源瞬变电磁一维正演程序得到的数据集训练CNN-LSTM深度神经网络, 将采样时间-衰减电压作为网络输入数据, 同时采用Adam优化器与ReduceLRonPlateau学习率调度器相结合的优化策略自适应调整学习率, 更新模型参数. 训练过程中将卷积层的输出通道数以及LSTM的隐藏层大小作为超参数, 利用遗传算法(Genetic Algorithm, GA)对超参数进行优化是解决该问题的常用策略. 最终, 在输出层得到与输入的电磁响应数据对应的深度-电阻率地层电性结构特征, 实现对瞬变电磁数据的深度学习反演.

## 1 深度学习反演基本理论

### 1.1 深度学习反演基本原理

瞬变电磁正演通过汉克尔变换建立地电模型, 得到中心点观测的磁场分量. 理想状态下假设用一个函数代表该过程:

$$d = f(m), \quad (1)$$

式中:  $d$ 表示观测时刻的衰减电压;  $m$ 表示与此对应的地电模型. 那么瞬变电磁反演可以表示为其反函数:

$$m = g(d). \quad (2)$$

传统的反演方法需要借助大量复杂的数学方法建立地层电阻率分布与电磁场之间的物理联系, 而引入神经网络可以将复杂的反函数求解过程转化为矩阵映射关系<sup>[38]</sup>:

$$T_\theta: \mathbf{D} \rightarrow M, \quad (3)$$

式中:  $\mathbf{D}$ 为神经网络输入, 由于各测点之间有紧密的空间相关性, 所以 $\mathbf{D}$ 可以表示为一个形状为时间道数 $\times$ 测点个数的二维矩阵, 第 $n$ 个测点处的响应数据便可以表示为 $\mathbf{D} = [d_n^1, d_n^2, \dots, d_n^t]$ , 其中 $d_n^t$ 为该测点对应的第 $t$ 个时间道的衰减电压;  $M$ 是对应的地层分布情况<sup>[40]</sup>;  $\theta$ 为训练后的CNN-LSTM神经网络的超参数设置以及网络结构信息. 实际操作时, 使用离线训练的神经网络瞬变电磁反演模型接收实测数据 $\mathbf{D}_x$ , 预测得到最接近真实地层分布情况的 $M_x$ .

### 1.2 CNN-LSTM反演原理

输入数据归一化以后的输入序列 $D$ 包含多维时间序列:

$$D \in R^{N \times F \times T}, \quad (4)$$

式中:  $N$ 为正演生成的数据集样本数量;  $F$ 为每个时间步的特征数量;  $T$ 为每个样本序列的时间步长度. 进行卷积操作前, 需要将输入数据转换为适合卷积处理的格式<sup>[33]</sup>:

$$D_{\text{permute}} = D_{\text{orig}} \cdot \text{permute}(0, 2, 1) \in R^{N \times F \times T}, \quad (5)$$

式中: permute操作代表重排数据维度, 以便进行一维卷积处理.

GA-CNN-LSTM神经网络包括卷积层和LSTM层, 其中卷积层为:

$$C_{\text{out}} = \text{Conv1D}(D_{\text{permute}}, K) \in R^{N \times C \times L}, \quad (6)$$

式中: Conv1D代表卷积神经网络中的一维卷积操作, 专门用于处理一维序列数据;  $K$ 为卷积核的大小;  $C$ 为卷积层的输出通道数, 决定了提取特征的能力;  $L$ 为经过卷积和池化后的序列长度. 经过ReLU激活和最大池化后的输出为:

$$C_{\text{final}} = \text{MaxPool1D}(\text{ReLU}(C_{\text{out}})) \in R^{N \times C \times L}. \quad (7)$$

卷积层输出经过LSTM进行时间序列建模, 将时间步的维度设为第二个维度, 以适应LSTM的输入格式<sup>[40]</sup>:

$$L_{\text{input}} = C_{\text{final}} \cdot \text{permute}(0, 2, 1) \in R^{N \times L \times C}. \quad (8)$$

LSTM层的输出为:

$$L_{\text{out}} = \text{LSTM}(L_{\text{input}}) \in R^{N \times L \times H}, \quad (9)$$

式中:  $H$ 为LSTM的隐藏层大小. 最终, 通过全连接层生成反演结果:

$$Y_{\text{pred}} = W_{\text{fc}} \times L_{\text{last}} + b_{\text{fc}} \in R^{N \times O}, \quad (10)$$

式中:  $W_{\text{fc}}$ 为全连接层的权重矩阵;  $b_{\text{fc}}$ 为偏置项;  $O$ 为模型的输出维度. 定义均方根误差 (RMSE) 作为损失函数, 用于评估模型输出的准确性:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{\text{true}}^{(i)} - Y_{\text{pred}}^{(i)})^2}, \quad (11)$$

式中:  $Y_{\text{true}}$ 为真实的地层模型;  $Y_{\text{pred}}$ 为深度学习模型的反演结果. 反演原理如图1所示.

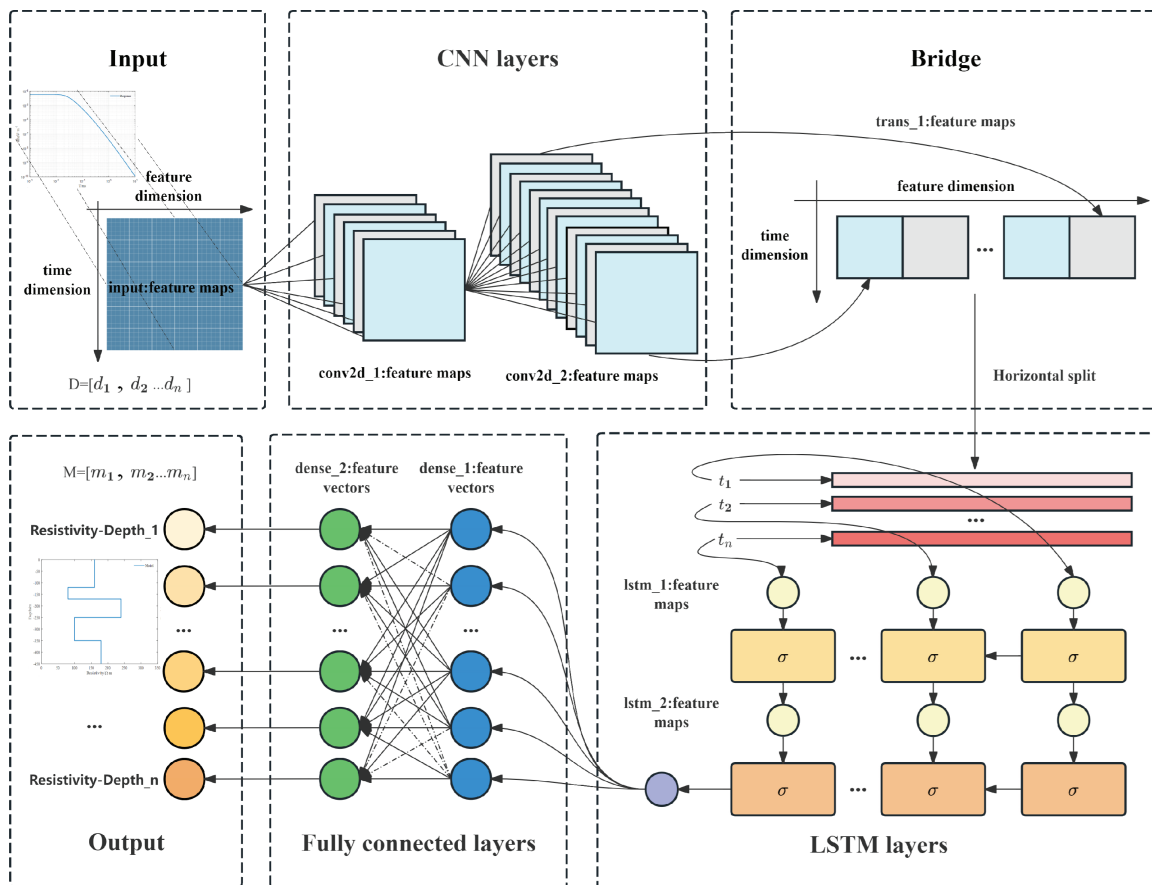


图 1 瞬变电磁CNN-LSTM反演算法原理

### 1.3 遗传算法优化策略

遗传算法作为进化算法的分支, 其设计灵感来源于生物遗传与自然选择机制, 基本原理如图2所示. 自1975年由Holland<sup>[43]</sup>提出以来, 该算法已被广泛应用于最优化问题. 算法的核心优势在于能够有效处理高维度、非线性的复杂优化问题, 尤其适用于目标函数不可微或搜索空间广阔的应用场景. 本文采用遗传算法对最能影响神经

网络训练速度以及泛化能力的超参数组合进行空间寻优, 结合自适应调整学习率方法在训练过程中对神经网络模型进行整体性结构优化, 大大降低了主观性误差, 并且使得模型更适应瞬变电磁法数据反演问题.

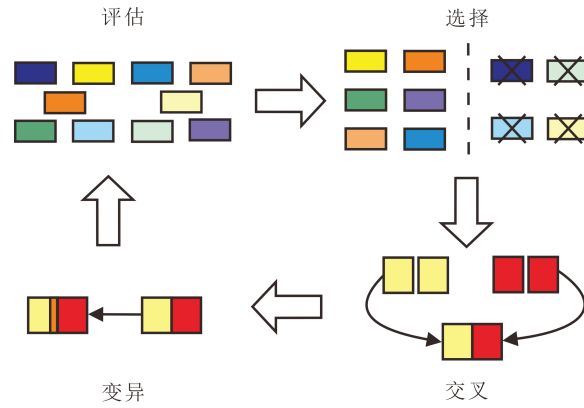


图 2 遗传算法原理

遗传算法优化过程中, 首先定义CNN-LSTM的关键超参数向量:

$$\varphi = [out\_channels, hidden\_size], \quad (12)$$

式中:  $out\_channels$ 为卷积层的输出通道数 $C$ , 决定了模型特征的提取能力;  $hidden\_size$ 为LSTM层的隐藏层大小 $H$ , 影响模型对时间序列的信息提取能力. 超参数的取值范围为 $\varphi \in [16, 512]$ . 不论是输出通道数亦或隐藏层大小, 低于16时, 神经网络复杂度过低、提取特征能力不足; 高于512时, 模型的精度得到了提升, 但指数级增长的空间复杂度大大提高了训练的成本以及难度. 因此,  $[16, 512]$ 是一个较为合适的取值空间.

初始化种群, 随机生成一定数量的候选解 $P_t^{j,k}$ , 即上文定义的经过随机赋值的超参数向量组 $\varphi$ , 对每个候选解计算适应度值:

$$F_j = obj\_func(P_t^{j,k}) = RMSELoss(model(D_{train}; P_t^{j,k}), Y_{train}), \quad (13)$$

式中:  $F_j$ 为候选解的适应度值, 表示神经网络在特定超参数配置下的性能;  $obj\_func(P_t^{j,k})$ 为定义的适应度函数, 用于评估给定超参数组合的性能<sup>[44]</sup>;  $model$ 为定义后的GA-CNN-LSTM神经网络;  $RMSELoss$ 表示均方根误差损失函数;  $D_{train}$ 和 $Y_{train}$ 分别代表训练集的特征和标签.

选择操作根据适应度值从当前种群中选择优秀个体作为父代. 常用的轮盘赌选择方法中, 第 $t$ 个个体被选中的概率 $P_t$ 为:

$$P_t = \frac{F_t^{-1}}{\sum_{k=1}^N F_k^{-1}}, \quad (14)$$

式中:  $N$ 为种群大小;  $F_t^{-1}$ 为适应度值的倒数, 适应度值越小性能越好.

交叉操作从父代中选择两个个体 ( $Parent_1$ 和 $Parent_2$ ), 通过交叉操作生成子代 ( $Child_1$ 和 $Child_2$ ). 以单点交叉为例:

$$Child_1 = Parent_1[:c] + Parent_2[c:], \quad (15)$$

$$Child_2 = Parent_2[:c] + Parent_1[c:], \quad (16)$$

式中:  $c$ 是随机选择的交叉点;  $Parent_1[:c]$ 表示 $Parent_1$ 前 $c$ 个基因;  $Parent_2[c:]$ 表示 $Parent_2$ 第 $c$ 个基因后的部分.

对子代个体进行随机变异以增加种群的多样性<sup>[45]</sup>. 以二进制编码为例, 设第 $i$ 个基因发生变异的概率为 $p_m$ , 则:

$$Child_i = \begin{cases} 1 - Child_i, & \text{if } rand() < p_m, \\ Child_i, & \text{else,} \end{cases} \quad (17)$$

式中:  $rand()$ 是 $[0, 1]$ 区间内的随机数. 用新生成的子代替换当前种群中的部分或全部个体, 形成新一代种群.

然后在每一轮迭代中,更新当前的最优解 $P_t^{\text{best}}$ 和最差解 $P_t^{\text{worst}}$ ,当前候选解的适应度 $F_i$ 大于最大的适应度值 $F_{\text{max}}$ 时,候选解向全局最优解 $P_t^{\text{best}}$ 移动.如果当前解的适应度等于最大的适应度值,则其位置会根据最差解 $P_t^{\text{worst}}$ 进行局部搜索,以增强搜索多样性<sup>[46]</sup>.遗传算法的迭代过程在满足以下条件之一时终止:1)达到最大迭代(MaxIter)次数;2)最优解的适应度值收敛(变化小于阈值 $\epsilon$ );3)计算资源耗尽.

每次迭代中,通过评估适应度并更新解的位置,直至达到收敛标准或迭代次数上限.最优超参数选择经过多次迭代后,遗传算法会得到适应度值最佳的解:

$$P^* = P_t^{\text{best}}, \quad (18)$$

最终选择的超参数组合 $P^*$ 为种群中性能最优的配置.

模型使用最终确定的超参数配置 $P^*$ 构建GA-CNN-LSTM神经网络:

$$Y_{\text{pred}} = \text{model}(X_{\text{train}}; P^*). \quad (19)$$

产生的预测结果用于后续模型性能评估,以确认GA-CNN-LSTM神经网络在实际应用中的有效性和鲁棒性.

## 2 超参数设置

### 2.1 损失函数设置

深度学习模型需要大量的数据样本进行离线训练.本文以天然岩石的电阻率范围和地层分布的深度特征为约束条件,设计了相应的地电模型.保持参数不变,通过一维正演建模程序得到相应的瞬态电磁响应数据.将前向建模得到的采样时间-衰减电压响应数据作为输入数据.数据集被分为训练集、验证集和测试集,以7:2:1的比例进行数据分配以测试网络性能.本文选择标记数据的真实值(即设置的地电模型地层厚度分布以及电阻率分布)与相应反演预测值之间(即反演得到的地电模型地层厚度分布以及电阻率分布)的均方根误差作为损失函数.同时,在损失函数中添加L1正则项对权重绝对值求和,促进稀疏性以防止模型复杂度过高.

本文采用结构相似度指标定量评估预测地层结构与目标地层结构之间的吻合程度.该指标的计算方法为:

$$\text{Similarity} = 1 - \frac{1}{N} \sum_{i=1}^N \frac{|p_i - t_i|}{t_i} \times 100\%. \quad (20)$$

首先,从两条地层结构折线上分别等间隔选取 $N$ 个对应点, $p_i$ 表示预测地层结构折线上的第 $i$ 个点, $t_i$ 表示目标地层结构折线上的对应点;然后,计算这些对应点之间的相对误差;最终,取所有点相对误差的平均值作为结构相似度的量化指标.

### 2.2 学习率设置

学习率是深度学习中调节参数、更新步长的关键超参数,直接影响模型的训练效率与收敛稳定性.设置值过小会导致收敛速度缓慢,可能陷入局部最优;设置值过大则容易引发振荡,导致训练发散<sup>[47]</sup>.合理选择学习率初始值(lr)能在保证收敛精度的同时提升训练效率,是优化模型性能的重要环节.

图3为不同学习率初始值的损失函数下降曲线.学习率初始值为0.1时,出现梯度爆炸,网络无法正常收敛;学习率初始值为0.01以及0.001时,损失函数早期轮次快速下降,前者收敛效果更佳;学习率初始值为0.0001以及0.00001时,最终误差较小,但损失函数下降缓慢.综合以上结果,本文最终选择学习率初始值为0.01.




图3 不同学习率初始值误差对比

目前,等间隔调整法(StepLR)、指数衰减调整法(ExponentialLR)、余弦退火调整法(CosineAnnealingLR)等有序调整策略是较为常见的学习率衰减方法,但在处理瞬变电磁反演这种非线性问题时可能存在局限性,而自适应学习率调整法(ReduceLRonPlateau)可以更好适应损失函数的动态变化,避免过早衰减或过晚衰减.图4(a)刻画了上述4种方法的学习率调整方式,StepLR以及CosineAnnealingLR均是根据人为设定的固定变换周期进行学习率调整,ExponentialLR则是通过设置指数衰减因子实现学习率调整,相比以上3种方法,ReduceLRonPlateau在固定的训练轮次监测周期patience内发现损失函数曲线出现振荡难以收敛时,会给当前学习率乘以一个衰减因子factor,从而更好平衡收敛速度和精度.由图4(b)可知,StepLR、ExponentialLR、CosineAnnealingLR 3种方法在优化过程中,损失函数值相较于ReduceLRonPlateau的振荡幅度更大,说明这些方法难以适应当前网络的计算复杂度.因此,本文最终选择ReduceLRonPlateau为学习率衰减方法.

训练初期,采用Adam优化算法自适应调整每个参数的学习率,有效处理稀疏梯度和非平稳目标函数,快速降低损失函数值,加速收敛.训练后期,损失函数值下降缓慢或出现振荡时,ReduceLRonPlateau能够自动调整学习率,避免损失函数值振荡或陷入平台期,提高收敛精度,提升收敛速度.




图 4 学习率调整策略实验

注:(a)为不同学习率调整方式;(b)为不同学习率调整方法误差对比

### 2.3 网络结构设置

隐藏层节点数以及卷积层输出通道数取值范围一般为 $2^3 \sim 2^9$ 之间的2的指数幂,在控制变量的前提下增加隐藏层节点数以及卷积层输出通道数,可以在一定程度上提高网络的性能.但节点数过多时,网络空间复杂度增加,计算复杂度提高,性能的提升效果可能不再显著,甚至可能导致过拟合.

针对两个参数的最优取值,本文分别进行了3次独立重复实验.由图5(a)可知,随着卷积层输出通道数的增加,模型在测试阶段的均方根误差不断下降.第一次实验的通道数为128时,取得最小均方根误差为10.004;第二次实验的通道数为512时,取得最小均方根误差为9.546;第三次实验的通道数为256时,取得最小均方根误差为8.885.由图5(b)可知,第一次实验隐藏层节点数为64时,取得最小均方根误差为14.128;第二次实验隐藏层节点数为256时,取得最小均方根误差为12.947;第三次实验隐藏层节点数为128时,取得最小均方根误差为14.332.




图 5 超参数取值对网络性能的影响

注:(a)为不同卷积层输出通道数测试误差对比;(b)为不同LSTM隐藏层节点数测试误差对比

上述实验验证了本文采用GA进行超参数寻优的必要性和有效性.实验结果表明,即便是完全相同的数据集,在不同的设备配置、运行环境以及训练轮次下,模型的最佳超参数组合也会有所不同.这种差异性主要源

于以下两个方面: 首先, 设备配置的差异直接影响模型的训练效率和性能, 如GPU和CPU的计算能力不同, 可能导致模型的训练速度存在显著差异. 其次, 运行环境的差异也会对模型的训练结果产生影响, 如不同版本的深度学习框架(如TensorFlow或PyTorch)可能在底层实现上存在细微差异, 从而导致相同的超参数组合在不同环境下表现不一致. 本文采用GA进行超参数寻优, 通过模拟自然选择和遗传机制, 能够在全局范围内搜索最优超参数组合, 避免陷入局部最优解. 同时, GA的搜索能力和适应性使其能够在不同的设备配置和运行环境下快速找到适合的超参数组合.

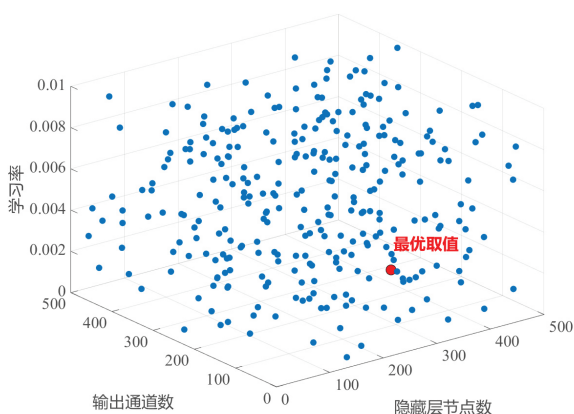


图 6 超参数空间寻优示意图




图 7 遗传算法寻优适应度曲线

本文中超参数自适应寻优结果的三维示意图如图6所示, 根据本节所述深度学习模型的构建、优化策略以及超参数取值的选择, 最终采用表1所示的超参数组合以实现模型性能与训练效率的平衡. 模型采用双层长短期记忆神经网络结构以捕捉瞬变电磁响应数据指数衰减形式的深层时间序列特征, 其隐藏层节点数以及卷积层输出通道数基于遗传算法进行全局优化, 满足特征提取过程与任务需求的高匹配性. 优化过程选用具有自适应学习率特性的Adam算法, 设置初始学习率为0.01, 批处理规模为64. 采用ReduceLROnPlateau动态调节机制, 即验证集损失在连续10个训练轮次内未下降时, 学习率将乘以0.1的衰减因子. 这种混合策略有效平衡了训练初期快速收敛需求与后期参数微调精度的矛盾.

经实验, GA设置种群大小为50, 迭代次数为100, 交叉概率为0.8, 变异概率为0.01. 变异方法采用随机扰动法, 使用部分训练数据进行测试. 由图7可知, 适应度曲线快速下降直至收敛, 表明算法性能良好. 通过多次仿真实验发现, 优化过程在第20代前均已完成收敛. 考虑最优化算力配置原则, 后续实验中将GA迭代次数设置为25.

表 1 模型训练超参数设置

超参数设置	数值
LSTM层数	2
LSTM隐藏层节点数	GA自适应寻优
卷积层输出通道数	GA自适应寻优
批大小 (batch_size)	64
优化函数	Adam
	ReduceLROnPlateau
学习率	lr=0.01
	patience=10
	factor=0.1

### 3 仿真实验

本文所有算例均在1台搭载英特尔至强处理器 (Inter Xeon W9 3495X)、2张英伟达显卡 (Nvidia Geforce RTX 4090)、4根32 GB DDR4内存条以及1块2 TB M.2 SSD硬盘的深度学习工作站上实现.

### 3.1 随机模拟数据训练

根据表2的参数设置,生成3层地电模型的正演模拟数据.采样时间起点设置为 $10^{-3}$  ms,终点为10 ms;时间测道数 $Nt$ 设置为60,采用等对数间隔分布;地层电阻率的取值范围为40~500  $\Omega\cdot\text{m}$ ,且相邻地层的电阻率差异大于2%;地层厚度的取值范围为30~300 m,层间差异同样大于2%,进一步增强了模型的多样性;地层模型层数 $Np$ 固定为3层,在简化模型结构的同时,仍能反映多层地层的基本特征.模型训练用时为329 min.

表 2 3层模型训练集参数设置

参数	数值	设置
采样时间起点/ms	$10^{-3}$	
采样时间终点/ms	10	
发射电流/A	1	
时间测道数 $Nt$	60	等对数间隔
地层电阻率/ $\Omega\cdot\text{m}$	[40, 500]	相邻地层电阻率差异大于2%
地层厚度/m	[30, 300]	层间差异大于2%
地层模型层数 $Np$	3	
生成数据量	45 000	

图8 (a) 为遗传算法在3层模型生成的数据集训练时的超参数组合寻优结果.适应度函数值早期快速下降,迭代到第11代后收敛,此时最佳适应度值为1 056.180 3,最优超参数组合取值为[127.250 98, 88.523 74],即卷积层输出通道数为128, LSTM隐藏层节点数为89.由图8 (b) 可知,损失函数值早期快速下降,后续没有出现过拟合现象,说明设计的GA-CNN-LSTM神经网络反演模型测试集表现良好,对3层地电模型具备突出的学习能力.

从测试集随机选取8组测试数据,反演结果如图9所示.8组样本都准确反映了地层模型的电阻率和地层厚度信息,绝大部分的曲线形态高度吻合,少部分存在一定的拟合误差,但不影响对地层结构的判断,表明本文设计的神经网络对3层地电模型具有良好的学习能力.




图 8 3层模型遗传算法寻优适应度图以及损失函数图

注:(a) 为3层模型参数寻优适应度曲线;(b) 为3层模型误差下降趋势曲线

将地层层数增加到5层,模型的空间复杂度增加,神经网络的训练难度提高,故需要根据表3中的设置扩充数据量并重新调整参数.地层电阻率的取值范围为50~500  $\Omega\cdot\text{m}$ ,且相邻地层的电阻率差异大于5%,这一设置模拟了实际地层中电阻率的显著变化情况,增强了模型的复杂性和真实性;地层厚度的取值范围为40~400 m,层间差异同样大于5%,进一步提高了模型的多样性和代表性;地层模型层数 $Np$ 设置为5层,增加了模型的复杂度,能够更好模拟多层地层结构.模型训练用时为477 min.

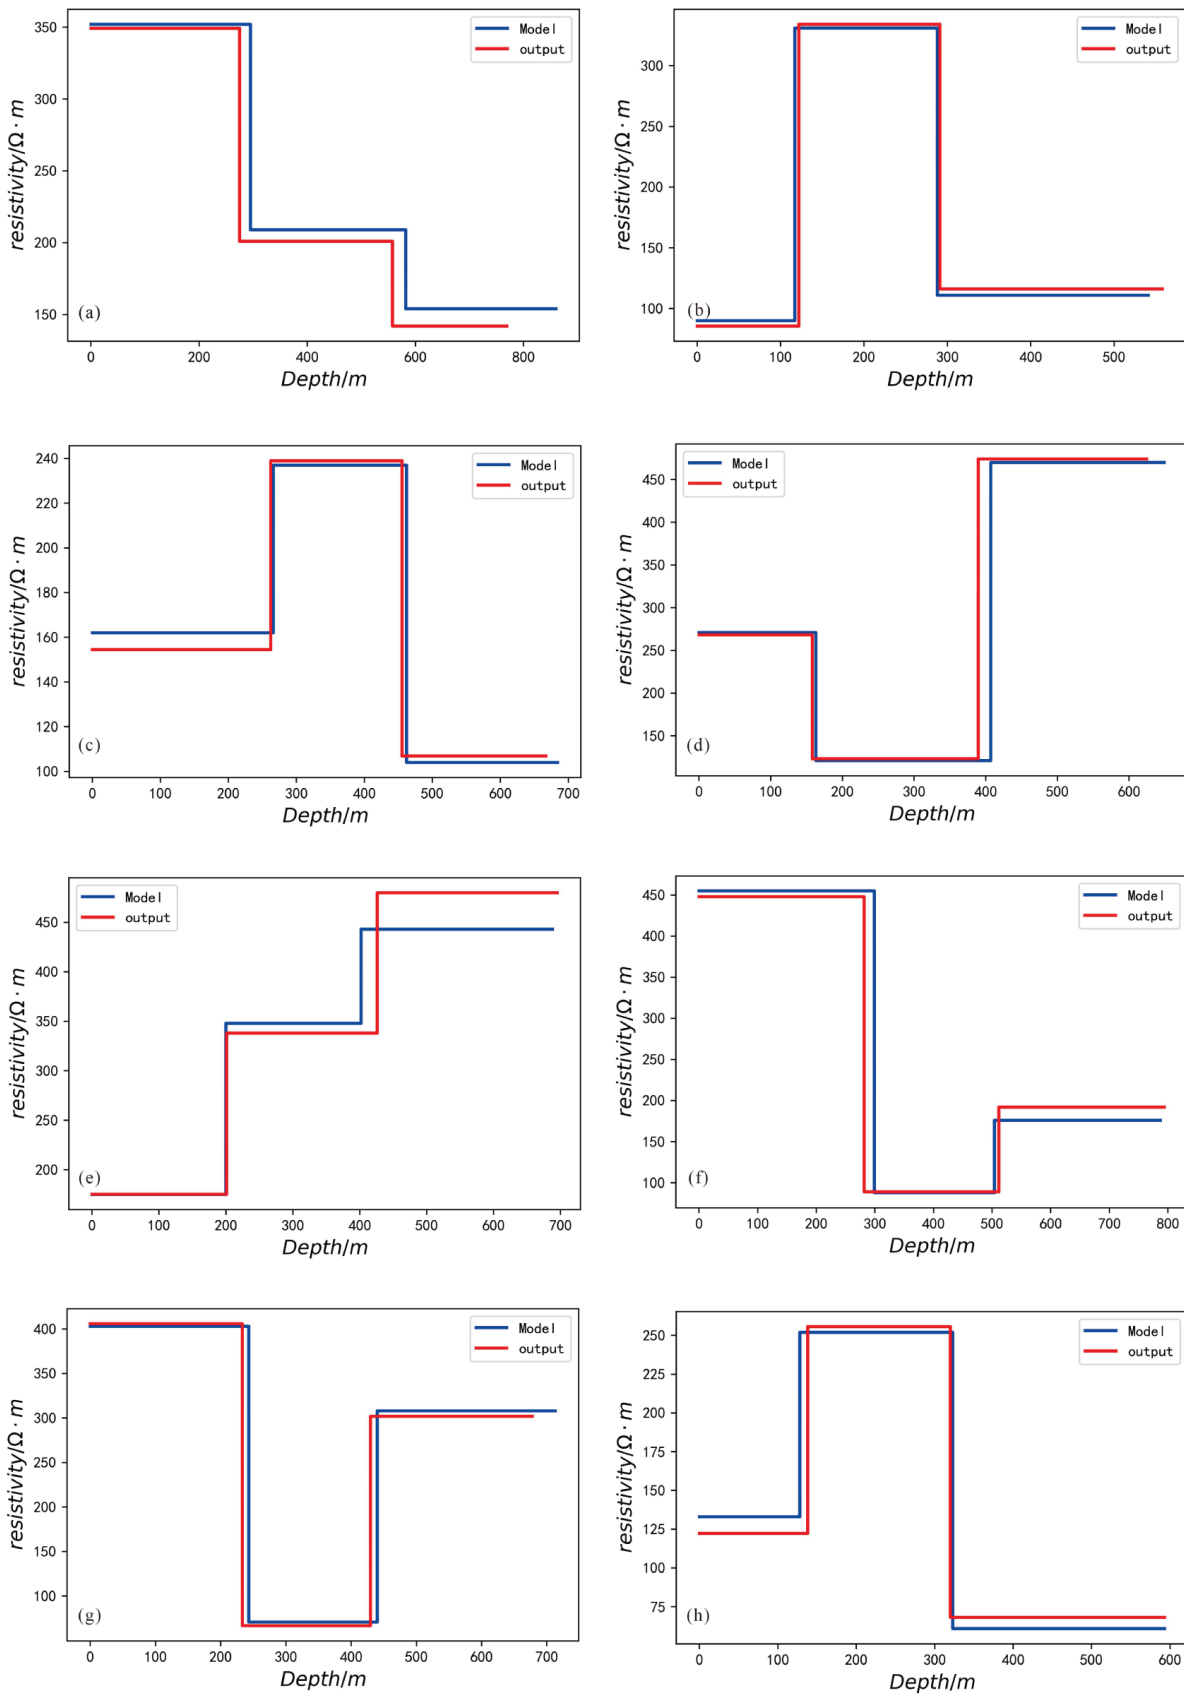


图 9 3层模型部分反演结果对比

注:(a)为模型71;(b)为模型314;(c)为模型722;(d)为模型927;(e)为模型1556;(f)为模型2660;(g)为模型2885;(h)为模型3194

图10(a)为遗传算法在5层模型生成的数据集训练时的超参数组合寻优结果. 可知适应度函数值早期快速下降, 迭代到第5代后收敛, 此时最佳适应度值为 $5\ 541.829\ 3$ , 最优超参数组合取值为 $[251.447\ 29, 137.476\ 27]$ , 即卷积层输出通道数为252, LSTM隐藏层节点数为138.

表 3 5层模型训练集参数设置

参数	数值	设置
采样时间起点/ms	$10^{-3}$	
采样时间终点/ms	10	
发射电流/A	1	
时间测道数 $Nt$	60	等对数间隔
地层电阻率/ $\Omega\cdot\text{m}$	[50, 500]	相邻地层电阻率差异大于5%
地层厚度/m	[40, 400]	层间差异大于5%
地层模型层数 $Np$	5	
生成数据量	100 000	

由图10(b)可知, 测试集损失函数值不断下降至最终收敛, 但是相比3层模型有一定的过拟合现象, 说明地层数量的增加会影响网络的训练效果. 然而, GA-CNN-LSTM神经网络反演结果依然可以较好还原地层电性结构, 虽然神经网络模型对5层地层的数据反演精度有一定程度下降, 但其仍具备较强的拟合能力. 通过测试数据的随机抽样分析(图11)可知, GA-CNN-LSTM神经网络在5层地层反演中表现出明显的性能特征变化: 其一, 相较于3层地层模型, 该网络对5层结构的拟合能力呈现系统性下降, 尤其在电阻率突变区域(如22号模型340~490 m、4764号模型575~785 m等高阻层段)出现结构性失真, 其中第22、1758、4764号测试模型的高阻层(大于300  $\Omega\cdot\text{m}$ )反演误差显著高于低阻地层, 最大相对误差达28.6%; 其二, 模型反演精度呈现显著的空间分层特征, 浅层(小于500 m)地层电阻率与界面反演结果与真实值吻合度较高( $R^2 > 0.91$ ), 而深层(大于500 m)虽能保持地层形态的整体重构(结构相似度大于85%), 但绝对电阻率数值偏差增大, 这种深度相关误差特征对实际电性结构解释的影响有限, 揭示了晚期时间道信号衰减是反演问题固有的瓶颈.




图 10 5层模型遗传算法寻优适应度图以及损失函数图

注:(a)为5层模型参数寻优适应度曲线;(b)为5层模型误差下降趋势曲线

### 3.2 加噪数据反演

训练深度学习模型的最终目标是实现对全新、未知数据的准确预测. 本节使用一维噪声数据作为额外的测试数据集来模拟真实世界的应用场景, 并评估模型的泛化能力. 建立了典型的3层和5层地电模型, 并结合1996年Munkholm等<sup>[48]</sup>提出的基于对数门控和门叠加的瞬变电磁数据加噪方法, 在响应数据中加入5%和10%的高斯噪声, 以模拟现场数据采集过程中的噪声干扰.

#### 3.2.1 G型模型

图12(a~b)为不同噪声量级响应数据的反演结果, 图12(c)展示了模型示意图以及当正演响应数据存在5%以及10%高斯噪声的模型反演结果. 反演模型较为准确地刻画出地层的厚度、上下界面以及电阻率的分布情况, 可以很好还原整体的电性结构及地层形态特征(结构相似度大于95%).

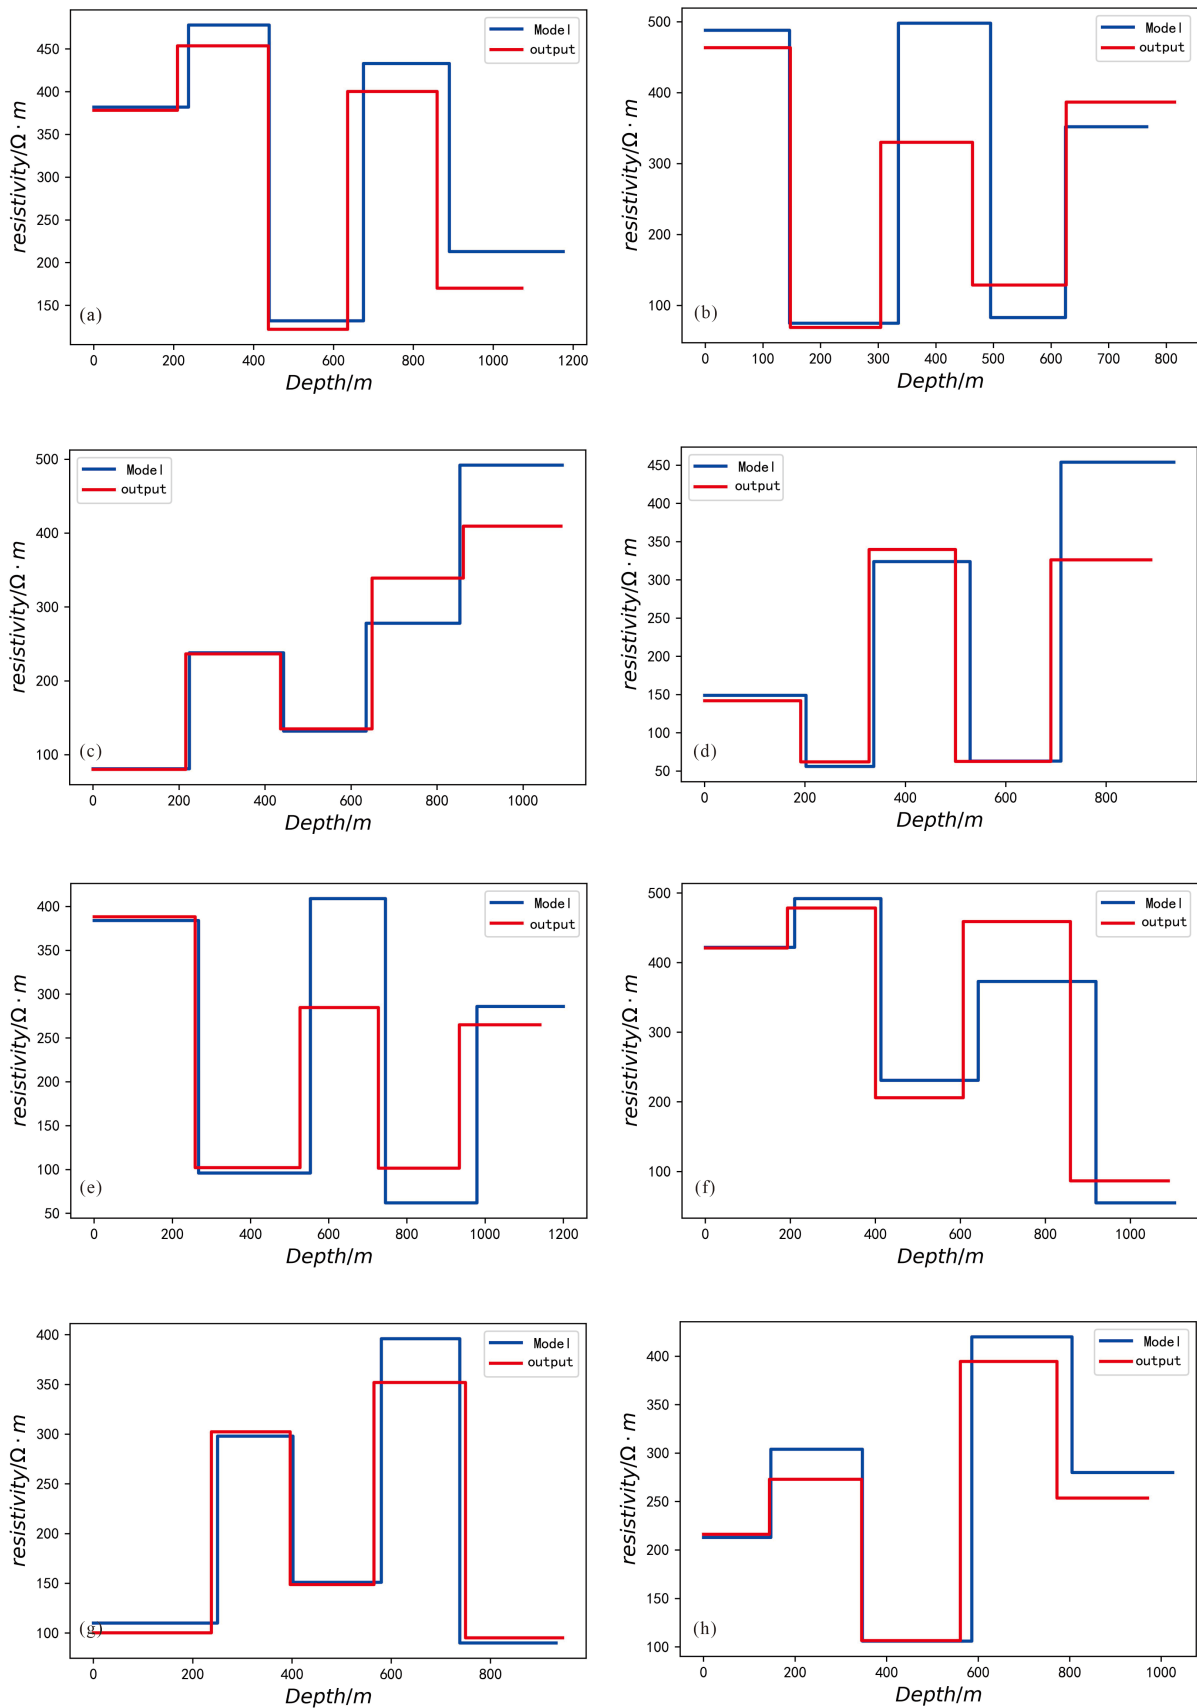


图 11 5层模型部分反演结果对比

注:(a)为模型19;(b)为模型22;(c)为模型626;(d)为模型1758;(e)为模型4764;(f)为模型8667;(g)为模型8979;(h)为模型9180




图 12 G型模型反演结果对比

注:(a)为含5%噪声响应数据反演结果;(b)为含10%噪声响应数据反演结果;(c)为含噪声模型反演结果

### 3.2.2 D型模型

由图13可知,神经网络模型对D型模型低阻层的拟合能力优于高阻层,不论是5%还是10%的噪声干扰,整体的反演结构相似度均大于91%,响应数据的反演效果较为良好.




图 13 D型模型反演结果对比

注:(a)为含5%噪声响应数据反演结果;(b)为含10%噪声响应数据反演结果;(c)为含噪声模型反演结果

### 3.2.3 K型模型

由图14可知,在5%高斯噪声干扰条件下,神经网络对K型地电模型的反演结果能准确重构地层厚度(平均误差小于8%)、界面位置(最大误差小于25 m)以及电阻率分布( $R^2 > 0.82$ ).当噪声水平提升至10%时,反演精度呈现一定程度的下降,其中电阻率重构误差增加至15%左右,界面定位精度降低.尽管如此,神经网络仍能保持对整体电性结构和地层形态特征的有效重构,展现出较强的抗噪能力和鲁棒性.这一系列数据表明,本文设计的神经网络在复杂噪声环境下仍具有可靠的地电参数反演能力.




图 14 K型模型反演结果对比

注:(a)为含5%噪声响应数据反演结果;(b)为含10%噪声响应数据反演结果;(c)为含噪声模型反演结果

### 3.2.4 Q型模型

Q型地电模型的反演结果如图15所示,神经网络同样表现出优异的性能.在5%高斯噪声条件下,Q型模型的地层厚度重构平均误差小于7%,界面位置最大误差小于20 m,电阻率分布的重构精度( $R^2 > 0.89$ )优于K型模型.当噪声水平增至10%时,Q型模型的反演结果显示类似趋势,电阻率重构误差增加至12%左右,界面定位精度略有下降,但仍能较好保持地层形态特征.值得注意的是,Q型模型的反演结果在高噪声条件下对低阻层的刻画更为准确,可能是由于Q型模型的电性结构变化更为平缓,使得神经网络更容易捕捉其电性特征.此外,Q型

模型的反演结果在垂向分辨率上表现出更高的稳定性,特别是在深层低阻层的识别中,其误差较K型模型降低了约3.8%。

进一步分析表明,神经网络对Q型模型的反演性能提升可能与其电性梯度变化较小有关。相较于K型模型的急剧电性变化,Q型模型的电阻率分布更为平滑,使得神经网络在训练过程中更容易学习到其内在规律。此外,Q型模型的反演结果在横向连续性上也表现出更好的稳定性,特别是在噪声水平较高时,其横向电性变化的连续性保持较好。




图 15 Q型模型反演结果对比

注:(a)为含5%噪声响应数据反演结果;(b)为含10%噪声响应数据反演结果;(c)为含噪声模型反演结果

### 3.2.5 HKH型模型

HKH型地电模型的反演结果如图16所示,在5%高斯噪声条件下, HKH型模型的地层厚度重构平均误差达到10%以上,电阻率分布的重构精度( $R^2 < 0.75$ )明显低于前文列举的实验模型。当噪声水平增至10%时,反演结果进一步恶化,电阻率重构误差增加至35%左右,界面定位精度有所下降,地层形态特征的失真程度加剧。这种失真主要是由于HKH型模型的电性结构复杂,包含多个高阻层和低阻层的交替分布,导致神经网络在训练过程中难以准确捕捉其非线性特征。尽管如此,神经网络在复杂地电模型反演中仍具有显著优势。首先,即便在10%的高噪声干扰下,神经网络反演结果整体上依然能够清晰反映地层的宏观走向以及电阻率的分布特征,表明其对地层结构的整体刻画能力较强,如高阻层和低阻层的位置和趋势在反演结果中得到了较好保留,地层界面的连续性也未受到严重破坏。其次,神经网络在处理复杂非线性关系时表现出较强的适应性,尽管HKH型模型的电性结构复杂,但神经网络仍能捕捉到其主要特征,为后续优化提供了良好基础。




图 16 HKH型模型反演结果对比

注:(a)为含5%噪声响应数据反演结果;(b)为含10%噪声响应数据反演结果;(c)为含噪声模型反演结果

### 3.3 不同算法反演效果对比

使用同样的方法建立A型、K型、H型、Q型地电模型,在响应数据中添加15%高斯噪声,分别引入Occam反演、LSTM反演,与本文GA-CNN-LSTM神经网络反演效果进行对比(LSTM与GA-CNN-LSTM训练集相同),测试3种方法的抗噪性能以及反演效果优劣。

由图17可知,3种方法在噪声干扰下都可以反映地电模型的宏观分布特征。由表4可知,GA-CNN-LSTM在4种地电模型上的结构相似度均显著高于Occam反演和LSTM反演:在A型模型中,GA-CNN-LSTM的结构相似度达到91.83%,高于LSTM的87.22%和Occam的81.74%;在K型模型中,GA-CNN-LSTM的结构相似度为84.69%,明显优于LSTM的73.16%和Occam的69.55%;在H型和Q型模型中,GA-CNN-LSTM的结构相似度分别为91.47%和

92.56%，均显著高于其他两种方法。表明GA-CNN-LSTM方法在复杂条件的反演中具有更高精度，尤其是在噪声干扰下，仍能保持对地层结构和电阻率分布的准确刻画。

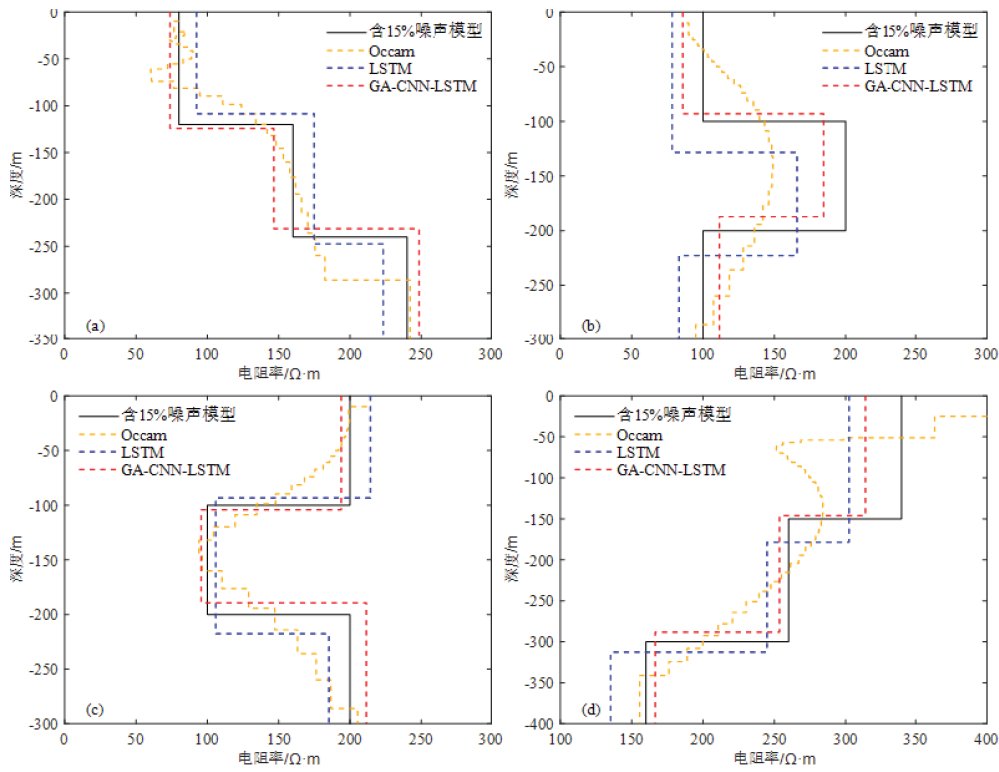


图 17 不同方法反演结果对比

注:(a)为A型模型反演结果;(b)为K型模型反演结果;(c)为H型模型反演结果;(d)为Q型模型反演结果

Q型模型的Occam反演结果中,浅层高阻异常体的边界被模糊化,出现了明显的低阻假异常.相比之下,GA-CNN-LSTM方法通过结合遗传算法、卷积神经网络和长短期记忆网络,能够更好捕捉地电模型的非线性特征,有效抑制噪声干扰,减少假异常的出现.计算效率方面,GA-CNN-LSTM方法表现出显著优势:在A型模型中,GA-CNN-LSTM的反演用时仅为0.13 s,低于Occam的9.85 s和LSTM的0.24 s;在K型模型中,GA-CNN-LSTM的反演用时为0.19 s,低于Occam的15.46 s和LSTM的0.39 s;在H型和Q型模型中,GA-CNN-LSTM的反演用时分别为0.11 s和0.09 s,均低于其他两种方法.这表明GA-CNN-LSTM方法不仅精度高、抗噪能力强,而且计算效率显著优于传统方法,适合大规模数据处理和实时反演任务.

表 4 反演衡量指标

正演模型	反演方法	结构相似度/%	反演用时/s
A	Occam	81.74	9.85
	LSTM	87.22	0.24
	GA-CNN-LSTM	91.83	0.13
K	Occam	69.55	15.46
	LSTM	73.16	0.39
	GA-CNN-LSTM	84.69	0.19
H	Occam	80.41	12.53
	LSTM	84.27	0.22
	GA-CNN-LSTM	91.47	0.11
Q	Occam	73.41	8.92
	LSTM	84.99	0.19
	GA-CNN-LSTM	92.56	0.09

### 3.4 三维正演数据反演

本节基于时间域有限元三维正演程序<sup>[49]</sup>模拟中心回线源瞬变电磁响应, 验证本文设计的神经网络反演模型对三维数据的泛化能力, 评估反演效果。

首先, 设计一个较为简单的地电模型, 具体参数设置如图18 (a) 所示, 背景均匀半空间的电阻率为 $200\ \Omega\cdot\text{m}$ , 中间含有断层的含水层, 层位电阻率为 $50\ \Omega\cdot\text{m}$ 。发射线框尺寸为 $200\ \text{m}\times 200\ \text{m}$ , 共布置11个观测点, 测点间距为 $50\ \text{m}$ 。对观测数据进行反演, 得到如图18 (b) 所示的结果。对比真实模型可知, 神经网络的反演结果清晰刻画了异常体的横向边界, 上边界基本与设置值一致, 下边界有轻微失真, 异常体的空间位置准确, 断层形态完整。反演的电阻率值略高于设置值, 没有出现电阻率突变地层, 连续性良好, 可以直观反映地层构造变化区域的细节特征。




图 18 构造模型神经网络反演结果

注:(a) 为构造模型设置示意图;(b) 为构造模型反演结果

为进一步验证本文设计的神经网络在复杂地质环境下的适用性, 设置了一个较为复杂的多异常体模型, 具体设计如图19 (a) 所示。该模型中, 背景均匀半空间的电阻率为 $200\ \Omega\cdot\text{m}$ 。左侧的低阻异常体埋深为 $100\ \text{m}$ , 宽度为 $120\ \text{m}$ , 厚度为 $80\ \text{m}$ , 距离测线原点 $60\ \text{m}$ ; 而右侧的高阻异常体埋深同样为 $100\ \text{m}$ , 厚度和宽度均为 $120\ \text{m}$ , 距离测线原点 $320\ \text{m}$ 。发射线框尺寸为 $200\ \text{m}\times 200\ \text{m}$ , 共布置11个观测点, 测点间距为 $50\ \text{m}$ 。

由图19 (b) 的反演结果可以明显看出低阻异常体与高阻异常体的存在。异常体的反演结果在空间位置上与理论模型大致相符, 低阻异常体的横向和纵向边界清晰可辨, 而高阻异常体的深部边界与设定值之间出现了一定差异。总体来看, 反演得到的电阻率值与设定值基本一致。两个异常体之间地层对应测点的电阻率值与背景值存在一定差异, 但并未影响对异常体边界及电阻率值的判断。表明本文设计的神经网络在复杂地质环境下具有良好的适应性和准确性。




图 19 多异常体模型神经网络反演结果

注:(a) 为多异常体模型设置示意图;(b) 为多异常体模型反演结果

## 4 实测数据反演

工作区位于中国新疆维吾尔自治区和静县北山凹陷谷地, 该区地层连续性较好, 分层特征明显。地层上部为第四系洪积砂卵石加漂石层 $Q_3^{pl}$ , 下部为新近系钙质砾岩夹砂岩 $N_2$ 。本次采用中心回线瞬变电磁装置, 开展寻找地下承压水工作。整个工作区布置了5条测线, 测线线距为 $100\ \text{m}$ , 测点间距为 $5\ \text{m}$ , 发射线框尺寸为 $300\ \text{m}\times 300\ \text{m}$ ; 采用PROTEM57-MK2瞬变电磁探测系统, 采样叠加次数为24, 供电电压为 $220\ \text{V}$ , 供电频率为 $60\ \text{Hz}$ ; 发射电流为 $10\ \text{A}$ , 时间测道为60, 数据采集延时介于 $36\sim 2\ 525\ \mu\text{s}$ 。该测线呈现近SN向展布, 剖面全长 $120\ \text{m}$ 。选取5条测线其中1条采集数据进行Occam反演以及GA-CNN-LSTM神经网络反演。

Occam反演迭代次数设置为26, 初始模型层数设置为40. 该区域地层分界清晰, 地质情况较好, 使用训练后的5层模型深度学习神经网络进行反演, 结果如图20所示. 可知Occam与GA-CNN-LSTM神经网络反演的结果剖面整体形态基本一致, 总体呈现中部高阻、上下低阻的特征. 地下50~160 m深度范围内观察到具有良好延续性的高阻覆盖层, 该高阻层下方存在连续低阻致密地层, 基于此, 推测该高阻层可能为承压水的顶板. 此外, 在地下230~250 m深度附近, 可以观察到条带状的连续低阻地层. 结合上方的高阻致密层, 推断该区域极有可能是承压水层. GA-CNN-LSTM神经网络的反演结果还显示, 含水层在距离测线原点60~90 m范围内呈现向深部延伸的走向, 推测此区域存在构造变化. GA-CNN-LSTM神经网络反演的含水层低阻带纵向连续性相比Occam反演有明显增强, 针对构造变化区域, 不论是纵向还是横向细节都表现得更好. 后期通过钻探进行验证, 同推断结果基本相符. 本次作业GA-CNN-LSTM神经网络反演用时为0.73 s, Occam反演用时为61.86 s.




图 20 和静县实测数据Occam反演以及GA-CNN-LSTM神经网络反演结果对比

注:(a)为Occam反演结果;(b)为神经网络反演结果

## 5 结论

1) 本文提出的基于GA-CNN-LSTM神经网络的瞬变电磁深度学习反演模型, 在经过离线训练后可以达到实时反演程度. 测试集评估结果表明, 该模型可以有效拟合3层以及5层地电模型的电性结构特征. GA的引入大大降低了网络训练的算力损耗、调参所需时间以及人为干预, 确保可以在模型训练过程中取得最优超参数组合, 从而提升模型性能.

2) 数值模拟结果表明, GA-CNN-LSTM反演模型具有良好的泛化性能和抗噪性能, 相比Occam反演方法在速度以及精度方面均具有明显优势, 反演效果和速度略优于LSTM反演方法. 与此同时, GA-CNN-LSTM反演模型可以快速反演三维正演数据, 并准确区分异常体电阻率差异以及地层边界.

3) 本研究为瞬变电磁深度学习反演提供了新的优化策略, 但仍存在以下待优化方向: 其一, 极端电阻率差异( $\Delta\rho > 50\%$ )地层的反演精度需通过特征增强训练集进一步改善; 其二, 可结合注意力机制强化晚期时间道信号的弱特征提取能力.

## 参考文献:

- [1] 滕吉文. 强化开展地壳内部第二深度空间金属矿产资源地球物理找矿、勘探和开发[J]. 地质通报, 2006, 25(7): 767-771.  
TENG J W. Strengthening geophysical exploration and exploitation of metallic minerals in the second deep space of the crustal interior[J]. Geological Bulletin of China, 2006, 25(7): 767-771. (in Chinese)

- [2] 董树文,李廷栋,高锐,等. 地球深部探测国际发展与我国现状综述[J]. 地质学报, 2010, 84(6): 743-770.  
DONG S W, LI T D, GAO R, et al. International progress in probing the earth's lithosphere and deep interior: A review[J]. *Acta Geologica Sinica*, 2010, 84(6): 743-770. (in Chinese)
- [3] 刘光鼎. 推动地球物理方法创新, 引领探测仪器技术未来[J]. 地球物理学报, 2017, 60(11): 4145-4148.  
LIU G D. Promote the innovation of geophysical methodology, and lead the future of exploration apparatus technology[J]. *Chinese Journal of Geophysics*, 2017, 60(11): 4145-4148. (in Chinese)
- [4] 底青云,朱日祥,薛国强,等. 我国深地资源电磁探测新技术研究进展[J]. 地球物理学报, 2019, 62(6): 2128-2138.  
DI Q Y, ZHU R X, XUE G Q, et al. New development of the electromagnetic(EM) methods for deep exploration[J]. *Chinese Journal of Geophysics*, 2019, 62(6): 2128-2138. (in Chinese)
- [5] 滕吉文. 高精度地球物理学是创新未来的必然发展轨迹[J]. 地球物理学报, 2021, 64(4): 1131-1144.  
TENG J W. High-precision geophysics: The inevitable development track of the innovative future[J]. *Chinese Journal of Geophysics*, 2021, 64(4): 1131-1144. (in Chinese)
- [6] NABIGHIAN M N. *Electromagnetic methods in applied geophysics*[M]//NEITZEL E B. *Investigations in geophysics*. Tulsa: Society of Exploration Geophysicists, 1987.
- [7] 李貅. 瞬变电磁测深的理论与应用[M]. 西安: 陕西科学技术出版社, 2002.  
LI X. *Theory and application of transient electromagnetic sounding*[M]. Xi'an: Shaanxi Science and Technology Press, 2002. (in Chinese)
- [8] STRACK K M. *Exploration with deep transient electromagnetics*[M]//SHARMA P V. *Methods in geochemistry and geophysics*. Amsterdam: Elsevier, 1992.
- [9] OLDENBURG D W, LI Y G, FARQUHARSON C G, et al. Applications of geophysical inversions in mineral exploration[J]. *The Leading Edge*, 1998, 17(4): 461-465.
- [10] GUO Z W, XUE G Q, LIU J X, et al. Electromagnetic methods for mineral exploration in China: A review[J]. *Ore Geology Reviews*, 2020, 118: 103357.
- [11] CHANG J H, SU B Y, MALEKIAN R, et al. Detection of water-filled mining goaf using mining transient electromagnetic method[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(5): 2977-2984.
- [12] 薛国强,武欣,陈卫营,等. 接地源短偏移瞬变电磁法理论及其在深部矿产勘探中的应用[J]. 中国科学:地球科学, 2025, 55(2): 642-654.  
XUE G Q, WU X, CHEN W Y, et al. Grounded-source short offset transient electromagnetic method: Theory and applications in deep mineral exploration[J]. *Science China: Earth Sciences*, 2025, 55(2): 642-654. (in Chinese)
- [13] DANIELSEN J E, AUKEN E, JORGENSEN F, et al. The application of the transient electromagnetic method in hydrogeophysical surveys[J]. *Journal of Applied Geophysics*, 2003, 53(4): 181-198.
- [14] 于景邨,刘志新,刘树才,等. 深部采场突水构造矿井瞬变电磁法探查理论及应用[J]. 煤炭学报, 2007, 32(8): 818-821.  
YU J C, LIU Z X, LIU S C, et al. Theoretical analysis of mine transient electromagnetic method and its application in detecting water burst structures in deep coal stope[J]. *Journal of China Coal Society*, 2007, 32(8): 818-821. (in Chinese)
- [15] 姚伟华,王鹏,李明星,等. 三分量地-孔瞬变电磁法积水采空区探测试验[J]. 煤田地质与勘探, 2019, 47(5): 54-62.  
YAO W H, WANG P, LI M X, et al. Experimental study of three-component down-hole TEM for detecting water-filled goaf[J]. *Coal Geology & Exploration*, 2019, 47(5): 54-62. (in Chinese)
- [16] AUKEN E, VIOLETTE S, D'OZOUVILLE N, et al. An integrated study of the hydrogeology of volcanic islands using helicopter borne transient electromagnetic: Application in the Galápagos Archipelago[J]. *Comptes Rendus Géoscience*, 2009, 341(10/11): 899-907.
- [17] FINN C A, BEDROSIAN P A, HOLBROOK W S, et al. Geophysical imaging of the Yellowstone hydrothermal plumbing system[J]. *Nature*, 2022, 603(7902): 643-647.
- [18] LIN J, CHEN J, ZHANG Y. Rapid and high-resolution detection of urban underground space using transient electromagnetic method[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(4): 2622-2631.
- [19] 方文藻,李予国,李貅. 瞬变电磁测深法原理[M]. 西安: 西北工业大学出版社, 1993.  
FANG W Z, LI Y G, LI X. *Principle of transient electromagnetic sounding method*[M]. Xi'an: Northwestern Polytechnical University Press, 1993. (in Chinese)
- [20] KELLER G V, PRITCHARD J I, JACOBSON J J, et al. Megasource time-domain electromagnetic sounding methods[J]. *Geophy-*

- sics, 1984, 49(7): 993-1009.
- [21] 薛国强, 李貅, 底青云. 瞬变电磁法理论与应用研究进展[J]. 地球物理学进展, 2007, 22(4): 1195-1200.  
XUE G Q, LI X, DI Q Y. The progress of TEM in theory and application[J]. Progress in Geophysics, 2007, 22(4): 1195-1200. (in Chinese)
- [22] OLDENBURG D W, HABER E, SHEKHTMAN R. Three dimensional inversion of multisource time domain electromagnetic data[J]. Geophysics, 2013, 78(1): E47-E57.
- [23] 万玲, 林婷婷, 林君, 等. 基于自适应遗传算法的MRS-TEM联合反演方法研究[J]. 地球物理学报, 2013, 56(11): 3728-3740.  
WAN L, LIN T T, LIN J, et al. Joint inversion of MRS and TEM data based on adaptive genetic algorithm[J]. Chinese Journal of Geophysics, 2013, 56(11): 3728-3740. (in Chinese)
- [24] 李明星, 肖林通, 张倚瑞, 等. 瞬变电磁粒子群优化反演研究[J]. 煤炭技术, 2014, 33(9): 302-304.  
LI M X, XIAO L T, ZHANG Y R, et al. Research on particle swarm optimization inversion of transient electromagnetic method[J]. Coal Technology, 2014, 33(9): 302-304. (in Chinese)
- [25] 程久龙, 李明星, 肖艳丽, 等. 全空间条件下矿井瞬变电磁法粒子群优化反演研究[J]. 地球物理学报, 2014, 57(10): 3478-3484.  
CHENG J L, LI M X, XIAO Y L, et al. Study on particle swarm optimization inversion of mine transient electromagnetic method in whole-space[J]. Chinese Journal of Geophysics, 2014, 57(10): 3478-3484. (in Chinese)
- [26] LI R Y, ZHANG H Q, YU N, et al. A fast approximation for 1-D inversion of transient electromagnetic data by using a back propagation neural network and improved particle swarm optimization[J]. Nonlinear Processes in Geophysics, 2019, 26(4): 445-456.
- [27] 孙怀凤, 张诺亚, 柳尚斌, 等. 基于L1范数的瞬变电磁非线性反演[J]. 地球物理学报, 2019, 62(12): 4860-4873.  
SUN H F, ZHANG N Y, LIU S B, et al. L1-norm based nonlinear inversion of transient electromagnetic data[J]. Chinese Journal of Geophysics, 2019, 62(12): 4860-4873. (in Chinese)
- [28] XUE G Q, LI H, HE Y M, et al. Development of the inversion method for transient electromagnetic data[J]. IEEE Access, 2020, 8: 146172-146181.
- [29] 胡琪鑫, 徐亚. 地球物理信号特征识别与解释的机器学习方法及应用综述[J]. 地球物理学进展, 2022, 37(6): 2395-2407.  
HU Q X, XU Y. Review of machine learning and application of geophysical signal feature recognition and interpretation[J]. Progress in Geophysics, 2022, 37(6): 2395-2407. (in Chinese)
- [30] 李创社, 张彦鹏, 李实, 等. 瞬变电磁勘探中的人工神经网络反演法[J]. 西安交通大学学报, 2001, 35(6): 604-607+615.  
LI C S, ZHANG Y P, LI S, et al. New inversion method of artificial neural network in transient electromagnetic inversion[J]. Journal of Xi'an Jiaotong University, 2001, 35(6): 604-607+615. (in Chinese)
- [31] 王秀臣. 基于人工神经网络的瞬变电磁反演解释及应用研究[D]. 西安: 西北大学, 2006.  
WANG X C. Study on inversion and interpretation of the transient electromagnetic method based on artificial neural network and its applications[D]. Xi'an: Northwest University, 2006. (in Chinese)
- [32] 秦善强, 付志红, 朱学贵, 等. 遗传神经网络的瞬变电磁视电阻率求解算法[J]. 电工技术学报, 2017, 32(12): 146-154+250.  
QIN S Q, FU Z H, ZHU X G, et al. Genetic neural network for apparent resistivity solution of transient electromagnetic[J]. Transactions of China Electrotechnical Society, 2017, 32(12): 146-154+250. (in Chinese)
- [33] COLOMBO D, TURKOGLU E, LI W C, et al. Physics-driven deep-learning inversion with application to transient electromagnetics[J]. Geophysics, 2021, 86(3): E209-E224.
- [34] PUZYREV V, SWIDINSKY A. Inversion of 1D frequency- and time-domain electromagnetic data with convolutional neural networks[J]. Computers & Geosciences, 2021, 149: 104681.
- [35] 洗锦焯, 蔡红柱, 熊咏春, 等. 基于深度学习的拖曳式瞬变电磁快速成像方法[J]. 工程地球物理学报, 2022, 19(4): 536-545.  
XIAN J C, CAI H Z, XIONG Y C, et al. Ground-based towed transient electromagnetic imaging method based on deep learning[J]. Chinese Journal of Engineering Geophysics, 2022, 19(4): 536-545. (in Chinese)
- [36] 范涛, 薛国强, 李萍, 等. 瞬变电磁长短期记忆网络深度学习实时反演方法[J]. 地球物理学报, 2022, 65(9): 3650-3663.  
FAN T, XUE G Q, LI P, et al. TEM real-time inversion based on long-short term memory network[J]. Chinese Journal of Geophysics, 2022, 65(9): 3650-3663. (in Chinese)
- [37] ASIF M R, MAURYA P K, FOGED N, et al. Automated transient electromagnetic data processing for ground-based and airborne systems by a deep learning expert system[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5919814.
- [38] 燕帅, 殷长春, 苏扬, 等. 基于卷积神经网络的瞬变电磁数据快速成像算法研究[J]. 地球物理学报, 2023, 66(10): 4290-4300.

- YAN S, YIN C C, SU Y, et al. Fast imaging of transient electromagnetic data based on convolutional neural network[J]. *Chinese Journal of Geophysics*, 2023, 66(10): 4290-4300. (in Chinese)
- [39] 程久龙, 王慧杰, 徐忠忠, 等. 基于全卷积神经网络的钻孔瞬变电磁法岩层富水性预测研究[J]. *煤田地质与勘探*, 2023, 51(1): 289-297.
- CHENG J L, WANG H J, XU Z Z, et al. Research on aquifer water abundance evaluation by borehole transient electromagnetic method based on FCNN[J]. *Coal Geology & Exploration*, 2023, 51(1): 289-297. (in Chinese)
- [40] 古瑶, 解海军, 周子鹏, 等. 基于Attention机制的CNN-BiLSTM瞬变电磁实时反演方法[J]. *煤田地质与勘探*, 2023, 51(10): 134-143.
- GU Y, XIE H J, ZHOU Z P, et al. An attention mechanism-based CNN-BiLSTM real-time transient electromagnetic method[J]. *Coal Geology & Exploration*, 2023, 51(10): 134-143. (in Chinese)
- [41] 王云宏. 基于Transformer神经网络的瞬变电磁法数值模拟[J]. *煤田地质与勘探*, 2024, 52(11): 151-159.
- WANG Y H. Transient electromagnetic numerical simulation based on the Transformer neural network[J]. *Coal Geology & Exploration*, 2024, 52(11): 151-159. (in Chinese)
- [42] KANG H, BANG M, SEOL S J, et al. Deep-learning-based airborne transient electromagnetic inversion providing the depth of investigation[J]. *Geophysics*, 2024, 89(2): E31-E45.
- [43] HOLLAND J H. *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*[M]. Cambridge: MIT Press, 1992.
- [44] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504-507.
- [45] JONG K A. *An analysis of the behavior of a class of genetic adaptive systems*[D]. Ann Arbor: University of Michigan, 1975.
- [46] SRINIVAS M, PATNAIK L M. Genetic algorithms: A survey[J]. *Computer*, 1994, 27(6): 17-26.
- [47] 蒋文斌, 彭晶, 叶阁焰. 深度学习自适应学习率算法研究[J]. *华中科技大学学报(自然科学版)*, 2019, 47(5): 79-83.
- JIANG W B, PENG J, YE G Y. Research on adaptive learning rate algorithm in deep learning[J]. *Journal of Huazhong University of Science and Technology(Natural Science Edition)*, 2019, 47(5): 79-83. (in Chinese)
- [48] MUNKHOLM M S, AUKEN E. Electromagnetic noise contamination on transient electromagnetic soundings in culturally disturbed environments[J]. *Journal of Environmental and Engineering Geophysics*, 1996, 1(2): 119-127.
- [49] 齐彦福, 智庆全, 李貅, 等. 考虑关断时间的地面瞬变电磁三维带地形反演[J]. *地球物理学报*, 2021, 64(7): 2566-2577.
- QI Y F, ZHI Q Q, LI X, et al. Three-dimensional ground TEM inversion over a topographic earth considering ramp time[J]. *Chinese Journal of Geophysics*, 2021, 64(7): 2566-2577. (in Chinese)

责任编辑: 张自强