

DOI:10.13409/j.cnki.jdpme.20250417002

# 基于DL-ERT模型的地下水渗透系数 预测方法研究\*

梁越<sup>1,2,3</sup>, 舒云林<sup>1</sup>, 刘港庆<sup>4</sup>, 许彬<sup>1,2,3</sup>, 赵硕<sup>1</sup>, 杨晓霞<sup>1</sup>

(1. 重庆交通大学河海学院, 重庆 400074; 2. 重庆交通大学国家内河航道整治工程技术研究中心, 重庆 400074;  
3. 重庆交通大学水利水运工程教育部重点实验室, 重庆 400074; 4. 重庆市综合交通运输研究所有限公司, 重庆 401121)

**摘要:** 针对传统方法刻画地下水含水层非均质性时面临的精度不足、预测成本高等问题, 基于数值模拟和室内砂箱试验, 通过残差网络优化集成卷积门控循环单元(CNN-GRU)的强大数据学习能力和电阻率层析成像法(ERT)运用物理先验信息的优势, 提出一种融合物理机理的深度学习算法—DL-ERT模型。将其对比多个传统反演模型, 探讨融合算法在地下水含水层的渗透系数刻画精度。结果表明:(1)模型的训练损失和验证损失都快速下降并趋近于零, 且两者的收敛几乎同步, 表明DL-ERT模型的构建策略优秀, 能快速有效的学习数据特征;(2)以某一测试集样本为例, 对比ERT、CNN-GRU和DL-ERT对该样本的渗透系数反演云图, 发现单一的算法模型均不能同时注重左右两侧的高渗区域刻画, 而DL-ERT则对高渗区域表现出极大的预测潜力, 其拟合精度达到了0.906;(3)制作室内砂箱试验, 将融合算法与传统的克里金插值法、CNN-GRU以及ERT作对比运用, 得到各模型的拟合精度值分别为0.895、0.707、0.760和0.836。可以发现, DL-ERT确实一定程度上弥补了单一算法的不足, 相比于单一的CNN-GRU和ERT, 其结果的预测精度提升了7%~17%, 表明了该模型在工程运用方面的潜力。

**关键词:** 渗透系数; 电阻率层析; 卷积门控循环单元; 物理规律; 反演预测

**中图分类号:** TU411 **文献标识码:** A **文章编号:** 1672-2132(2025)05-1032-10

## Research on Prediction Method for Groundwater Permeability Coefficient Based on DL-ERT Model

LIANG Yue<sup>1,2,3</sup>, SHU Yunlin<sup>1</sup>, LIU Gangqing<sup>4</sup>, XU Bin<sup>1,2,3</sup>, ZHAO Shuo<sup>1</sup>, YANG Xiaoxia<sup>1</sup>

(1. The College of River and Ocean Engineering, Chongqing Jiaotong University, Chongqing 400074, China;  
2. National Engineering Research Center for Inland Waterway Regulation, Chongqing Jiaotong University, Chongqing 400074, China; 3. Key Laboratory of Hydraulic and Waterway Engineering of Ministry of Education, Chongqing Jiaotong University, Chongqing 400074, China; 4. Chongqing Comprehensive Transportation Research Institute Co., Ltd., Chongqing 401121, China)

**Abstract:** To address the issues of insufficient accuracy and high prediction costs faced by conventional methods in characterizing the heterogeneity of groundwater aquifers, this study proposed a physics-

\* 收稿日期: 2025-04-17; 修回日期: 2025-06-14

**基金项目:** 国家自然科学基金面上项目(52379097)、广西科技计划项目(桂科AA23062023)、重庆市水利科技重点项目(CQSLK-2024005)、重庆市研究生联合培养基地建设项目(JDLHPYJD2021004)、重庆交通大学研究生科研创新项目(2024S0049)资助

**作者简介:** 梁越(1985—), 男, 教授, 博士。主要从事水利工程灾害形成机理及防治方面的研究。

E-mail: liangyue2560@163.com

**通信作者:** 舒云林(2001—), 男, 硕士研究生。主要从事水工建筑物健康智能诊断研究。E-mail: syl110427@163.com

informed deep learning algorithm—the DL-ERT model—based on numerical simulations and laboratory sandbox experiments. The model integrated the powerful data learning capability of a convolutional gated recurrent unit (CNN-GRU) optimized by residual networks with the advantage of physical prior information from electrical resistivity tomography (ERT). The DL-ERT model was compared with multiple traditional inversion models to examine the accuracy of the fusion algorithm in characterizing the permeability coefficient of groundwater aquifers. The results showed that: (1) the training and validation losses of the DL-ERT model rapidly decreased and approached zero, and their convergence was almost synchronous, indicating that the construction strategy of the DL-ERT model was excellent and that data features could be quickly and effectively learned. (2) Taking a sample from the test set as an example, the inversion cloud maps of the permeability coefficient obtained by ERT, CNN-GRU, and DL-ERT were compared. It was found that individual algorithm models could not simultaneously capture the high-permeability zones on both sides, while DL-ERT demonstrated remarkable predictive potential for high-permeability zones, achieving a fitting accuracy of 0.906. (3) Laboratory sandbox experiments were conducted, and the fusion algorithm was compared with traditional Kriging interpolation, CNN-GRU, and ERT, yielding fitting accuracies of 0.895, 0.707, 0.760, and 0.836, respectively. It is evident that the DL-ERT model compensates for the limitations of individual algorithms to some extent, with prediction accuracy improved by 7%-17% compared with the individual CNN-GRU and ERT models, indicating the potential of the model for engineering applications.

**Keywords:** permeability coefficient; resistivity tomography; convolutional gated recurrent unit; physical laws; inversion prediction

## 0 引 言

渗透系数作为表征地下水运动的重要水力参数之一,其准确刻画对水资源评价、污染物运移模拟等具有极其重要的意义<sup>[1-3]</sup>。目前渗透率的测算方法主要有试验法、经验法和数值模拟方法等<sup>[4-7]</sup>。试验法主要是通过现场钻探取样来进行实验测量,这种方式虽然有较高的准确度,但是费力又耗时。经验法是一类比实验测量法效率更高且成本更低的方法,其通过已有的地质资料,利用经验公式或相关数据推导渗透率。常用模型包括 Hazen 公式<sup>[8]</sup>、Kozeny-Carman 公式<sup>[9]</sup>和 Terzaghi 公式<sup>[10]</sup>等,但是这些模型通常具有大量假设条件,精度有限,只适用快速估算的情况。数值模拟法则是借助计算机的数值计算能力反演或预测渗透率分布,因其可以处理复杂的地质结构和多层含水层系统而被广泛运用于地下水系统的渗透率估算。

随着计算机技术的快速发展,结合机器学习的多孔材料渗透率快速预测方法被不断提出。目前基于深度学习的多孔材料渗透率预测建模方法更受国内外学者的关注。根据已有的神经网络理

论<sup>[11-12]</sup>,当人工神经网络具有足够数量的神经元时,它可以作为一种“万能”的逼近器有能力回归出任何期望的渗透率曲线。N.Srisutthiyakorn<sup>[13]</sup>便证明使用卷积神经网络(Convolutional Neural Networks, CNN)来从岩石图像预测渗透率的可能性,但其需要大量真实标签的网络预训练,而实际工程对真实值的获取极为困难。Z.Zhong 等<sup>[14]</sup>将 CNN 应用于渗透率的回归预测问题,得到了优于传统神经网络模型的渗透率预测分布结果,但是其对输入数据的复杂预处理难以适用于其他工况。Y.Tian 等<sup>[15]</sup>在此基础上引入门控循环单元(Gated Recurrent Unit, GRU)与 CNN 结合形成卷积门控循环单元 CNN-GRU,从空间和时间的尺度信息上提高了模型的鲁棒性,但是对地质特征图像的运用缺乏明确的物理解释。因此,目前神经网络自身的“黑箱”属性使其过于关注输入与输出之间的映射关系,忽略了状态变量到响应数据的物理过程及规律,造成了其先验信息的利用不足和内部解释性差的难点,且网络的训练过程一直是一个难以量化的难题。

而针对物理先验信息的运用,基于层析理念衍生出的电阻率层析成像法作为一种非侵入式的地球物理探测技术,近年来也被广泛运用于地下探测

领域<sup>[16-17]</sup>。其原理是通过向地下注入电流,利用电阻率与地质介质的物理特性规律来测量电位进而反演地下结构的图像。S.Perdomo等<sup>[18]</sup>和J.A.M.González等<sup>[19]</sup>以及刘征宇等<sup>[20-21]</sup>众多学者的研究成果已经表明了ERT在地下水渗透系数预测方面的有效性和成熟性。但是,由于地层的复杂性和不同电极布设形式所造成的电阻率噪声问题,以及探测深度不足与不完整边界的难题还制约着电法探测的发展。X.Liu等<sup>[22]</sup>也指出ERT对电阻率解译的非唯一性和不稳定性问题在反演过程中还有待证实。因此,联合多方法解译的模型成为了目前的研究热点之一。E.Cromwell等<sup>[23]</sup>便表明深度学习的最新进展在反演高维空间中具有庞大的运用前景。

综上所述,本文提出一种融合物理机理的深度学习方法,即DL-ERT模型,该模型结合了ERT反演电势信号过程中的物理规律以及CNN-GRU在时序数据特征提取方面的优势。通过地下水数值模拟软件Vsaft构建网络训练集,利用残差网络将CNN-GRU和ERT各自所得的渗透系数预测结果进行优化集成,引入残差块的跳跃式连接来弥补两个算法的不足,确保模型在复杂数据集上依然能够保持良好的训练表现,最后得到联合多方法解译的融合算法DL-ERT。再对其开展室内砂箱试验,将该方法与其它传统方法都运用于同一区域的渗透系数刻画研究,对比各模型的反演精度,探讨融合算法在地下水含水层渗透系数刻画方面的优劣。

## 1 方法原理

在ERT解译电势信号的众多反演算法中,连续线性估计算法(Successive Linear Estimator, SLE)是一种基于贝叶斯统计学的层析扫描数据解译算法<sup>[24]</sup>,在国际上得到了广泛的应用。但是其在处理较为复杂的非线性问题时会耗费较高成本的算力,而CNN-GRU强大的数据处理能力可以很好缓解此问题。因此,本文基于二者提出一个DL-ERT模型,以期克服单一算法的局限性。现对各算法的原理介绍如下。

### 1.1 连续线性估计算法

SLE是基于贝叶斯模型原理,观测参数的协相关关系作为主要依据更新参数后验均值和协方差,可以吸收各种类型的数据。其以迭代的方法对数

据的信息进行线性化,迭代过程中,时间上采用同时吸收模式,以有效解决非线性问题,避免传统数据同化算法等可能出现的参数-观测不一致问题。在迭代过程中,用Levenberg-Marquardt算法动态控制迭代的稳定性和速度,避免结果陷入局部最优解。通过伴随方程方法高效准确地计算敏感度矩阵,基于随机一阶近似计算不同尺度、不同精度观测数据的协方差。在稳定的直流电场条件下,SLE具有式(1)的形式:

$$\begin{aligned} \hat{f}^{(r+1)}(x_m) &= \hat{f}^{(r)}(x_m) + \\ &\sum_{j=1}^{N_s} \omega_{mj}^{(r)} [\phi_j^*(x_j) - \phi_j^r(x_j)] = \hat{f}^{(r)}(x_m) + \\ &\sum_{j=1}^{N_s} \omega_{mj}^{(r)} \left\{ [h_j^*(x_j) + H(x_j)] - [h_j^r(x_j) + H(x_j)] \right\} = \\ &\hat{f}^{(r)}(x_m) + \sum_{j=1}^{N_s} \omega_{mj}^{(r)} [h_j^*(x_j) - h_j^r(x_j)] \end{aligned} \quad (1)$$

式中, $\hat{f}^{(r)}(x_m)$ 为点 $x_m$ 处第 $r$ 次迭代的估计值,上标 $r$ 为迭代次数; $\phi_j^*(x_j)$ 为在点 $x_j$ 处的观测电压; $\phi_j^r(x_j)$ 为计算电压值,由当前 $\hat{f}^{(r)}(x_m)$ 估计值计算得出; $H(x_j)$ 为根据无条件平均值 $\rho$ 计算得到的计算电压平均值, $\rho$ 为电阻率; $h_j^*(x_j)$ 、 $h_j^r(x_j)$ 分别为观测电压和计算电压的扰动量; $\omega_{mj}^{(r)}$ 为点 $x_j$ 处观测值与估计值之间的差值对第 $r$ 次迭代过程中点 $x_m$ 处 $f$ 估计值的权重。同时,该算法还必须满足最小均方差准则,即式(2)所示:

$$E \left[ \left( f(x_m) - \hat{f}^{(r)}(x_m) \right)^2 \right] = \min imum \quad (2)$$

### 1.2 卷积门控循环单元

卷积门控循环单元由卷积神经网络和门控循环单元结合而来,可以充分挖掘渗透系数分布的空间局部特征。其中,CNN是多层感知机的特殊形式,主要通过增强提高神经网络中相邻层(如:卷积层、池化层等)之间存在的局部连接模式,来深入挖掘图像所含信息,提取空间局部的相关联信息,以达到信息全局化<sup>[25]</sup>。其核心是:将局部连接获取信息、采用梯度下降的方式训练共享的相同权值、在二维时间或三维空间中进行采样这三种结构思想相结合,以达到网络位移、尺度、形变不会发生任何改变。而GRU是循环神经网络的变体,通过引入更新门和重置门,使用门控机制来记忆和遗忘信息,具有长时间记忆能力<sup>[26]</sup>。门控单元通过筛选重要信息和遗忘无关历史信息的方式,有效缓解了网络数据长序列保存和梯度消失的问题。

CNN-GRU 并行网络能够分别使用 CNN 与 GRU 进行数据局部特征与时序特征的提取。在对所获得的两种数据类型特征的融合中,获得了更加

综合的特性,使所能提取到的特征与标签之间的关系关联更强,能够有效利用两个网络算法的优势,其模型结构如图 1 所示。

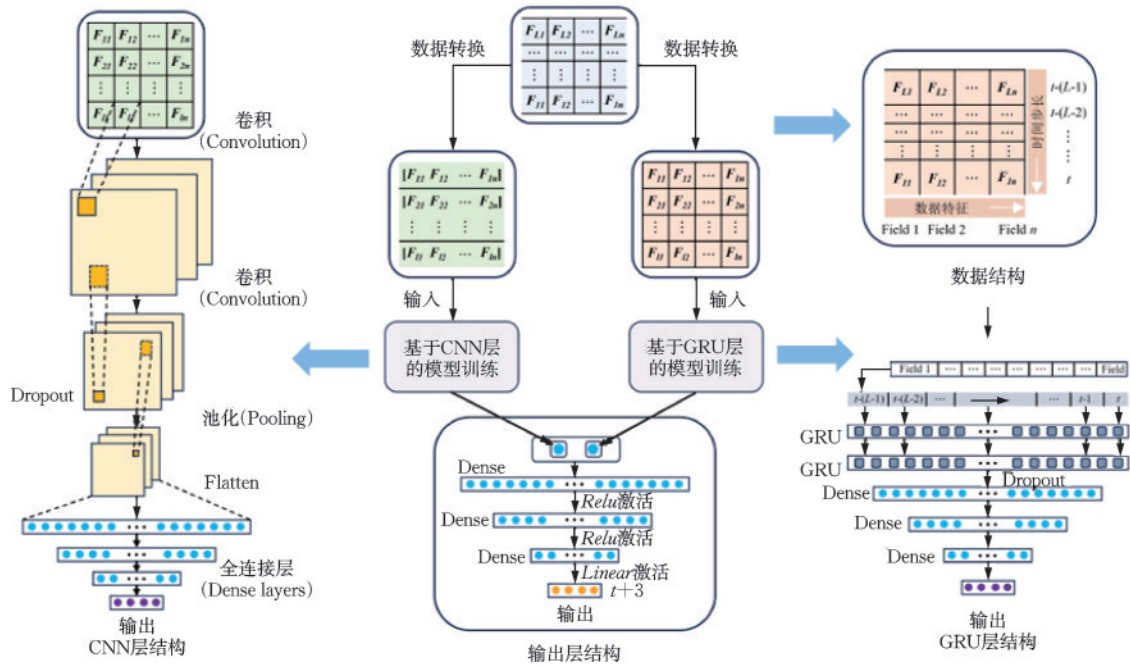


图 1 CNN-GRU 模型结构示意图

Fig.1 Schematic diagram of CNN-GRU model structure

### 1.3 联合算法

对所有神经网络而言,随着网络层数的增加,越能提取到不同级别丰富的特征信息。然而现有研究也表明,随着网络层数的增加,训练的误差往往会先减小后增大。这是因为当网络深度一味加深时,算法会越来越难以训练,即发生网络退化,同时也被称为梯度消失或梯度爆炸问题。

残差网络(ResNet)的提出便是解决上述问题的有效方式之一。该方法基于跳跃连接(shortcut connection)进行训练和预测,这种连接允许输入信息直接跳过某些层而传递到更深的层次,从而缓解深度网络中的梯度消失问题。其核心思想源于 Highway Network,避免了信息在多层网络中的过度损失。具体而言,初始输入数据在经过某些层后,将直接与输出相加,保留特征的同时传递到后续层,帮助网络更有效地学习深度特征<sup>[27]</sup>。残差块的数学表达式如式(3)所示:

$$y = \sigma(F(x, W) + x) \quad (3)$$

式中, $y$ 代表残差块的输出; $\sigma(\cdot)$ 代表激活函数; $F(\cdot)$ 代表残差函数, $x$ 代表输入, $W$ 代表残差块内的所有权重。

基于上述物理过程和深度学习的理论知识,本文将结合 CNN-GRU 并行网络和反演算法 SLE,通过引入残差网络作为集成器,将两个模型各自的预测值利用残差学习来进行优化,最后得到一个融合物理机理的深度学习算法,即 DL-ERT 模型。其网络结构图如图 2 所示。

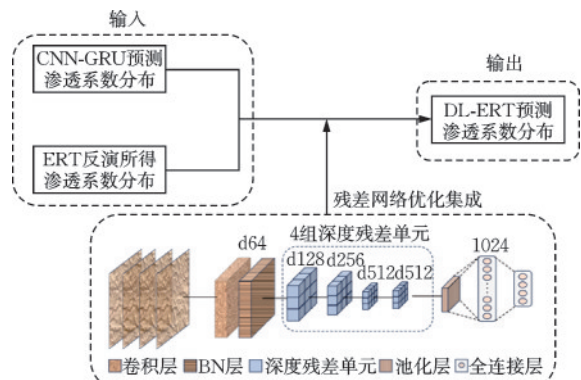


图 2 融合模型 DL-ERT 网络结构图

Fig.2 Network structure of DL-ERT fusion model

## 2 模型构建与训练

### 2.1 构建数据集

利用地下水数值模拟软件 Vsaft, 建立一个 100 网格 ( $x$  轴 10 个,  $y$  轴 10 个) 的二维剖面含水层, 如图 3 所示。将相邻四个点的电阻率取平均值, 获得 25 个电阻率分布值。采用 Newon-Raphson 插值迭代, 设置 9 个井。每个格点的初始电压为 0.1V, 左右两边界为绝缘边界, 上下边界处的初始电压为 0。依次给予 9 个井不同的电势刺激响应, 获得其余井的电势刺激-响应数据, 共 72 个数据。改变参数中的随机种子进而改变网格电阻率值等, 最后获得 2 000 组不同渗透系数分布图以及对应的电势刺激一响应数据集。

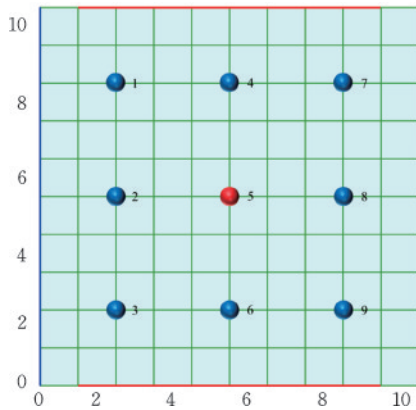


图3 Vsaft 刺激井布置图

Fig.3 Vsaft stimulation well layout

在网络训练过程中, 每一组数据集中的输入数据为响应井得到的 72 个电势刺激一响应数据, 输出数据为 25 个网格的渗透系数值。在 CNN-GRU 训练过程中, 训练选项设置为 Adam, 最大训练轮次为 300 次, 初始学习率为 0.000 1, 梯度阈值为 1, 学习率下降周期为 45, 学习率下降因子为 0.25, 求解器“Adam”中的梯度移动平均值指定指数衰减率, L2 正则化因子为 0.000 1。将生成的 2 000 组数据集中 70% 作为训练集数据, 剩余数据集作为测试集数据, 以此训练完成的 CNN-GRU 作为融合算法的基础。另重复上述 Vsaft 步骤新生成 2 000 组数据集用于 DL-ERT 模型的训练。

### 2.2 DL-ERT 模型

根据图 2 所示的融合流程, 将上述 2 000 组电势

信号数据集分别带入 ERT 和 CNN-GRU 进行渗透系数分布的预测, 然后利用残差网络优化集成两种预测值的特征, 最后输出一组更接近实际情况的渗透系数分布值。在 DL-ERT 模型学习过程中, 首先对输入数据作归一化处理, 网络权重  $H_e$  初始化, 选择 4 个不同维度的卷积核对输入的特征数据进行卷积, 然后定义一组输入的数据序列, 通过对这个序列构建一个堆叠的膨胀因果卷积神经网络, 并且在这个神经网络中增加残差模块, 采用绝对误差作为训练的损失值, 利用 Adam 优化器反向传播更新权重, 学习率设为 0.001, 权重衰减设为 0.000 1, L2 正则化因子为 0.000 1, 其训练结果如图 4 所示。




图4 DL-ERT 网络损失值变化

Fig.4 Changes in loss values of DL-ERT network

从图 4 可以发现, DL-ERT 的训练损失和验证损失都快速下降并最终趋近于零, 且二者几乎同步收敛差距极小, 表明模型在训练集和验证集上都达到了较好的拟合效果, 未出现过拟合现象。现选取测试集中某一样本为例, 分别将 CNN-GRU、ERT 和 DL-ERT 模型优化后的渗透系数分布值以及实际情况的渗透系数分布值可视化后如图 5 所示。

由图 5 可知, 图 5(a) 为实际情况的渗透系数分布, 其左右两侧均存在着一个渗透系数较大的高渗区, 而其余区域渗透系数值较低; 图 5(b) 为 ERT 反演的渗透系数分布图, 该算法虽然能识别左侧高渗区, 但刻画精度不高, 其将左下角的低渗区错误地赋予了较高渗透值, 且对右侧的高渗区仅反演出微小的局部特征; 图 5(c) 为 CNN-GRU 预测得到的渗透系数分布图, 该算法仅能识别左侧高渗区, 且预测的渗透系数值显著高于实际值, 高渗区域的范围也偏大, 其对右侧的高渗区域并未能识别; 图 5(d) 则为 DL-ERT 预测的渗透系数分布图, 发现该算法对左侧高渗区的识别与刻画表现出了较高的准确

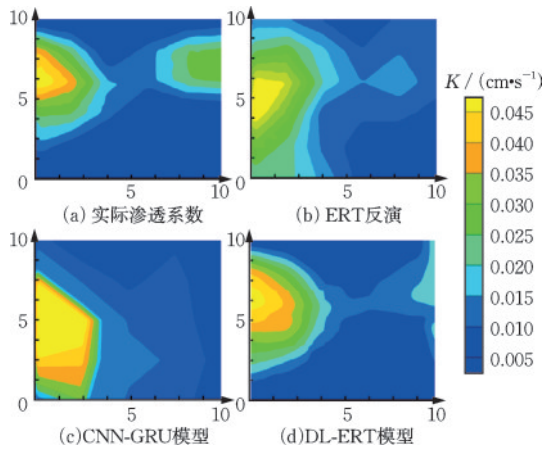


图5 不同模型对某一测试样本的渗透系数预测分布图

Fig.5 Distribution of permeability coefficient predictions of different models for a test sample

性,虽然对右侧高渗区的刻画仍存在一定偏差,但其综合反演效果已优于单一算法,表明了该融合算法在地下水渗透系数预测方面的潜力。最后再将上述各模型预测得到的渗透系数分布同实际情况的渗透系数分布进行拟合,分别得到CNN-GRU、ERT和DL-ERT的拟合精度值为0.726、0.853和0.906,各模型的拟合散点图如图6所示。

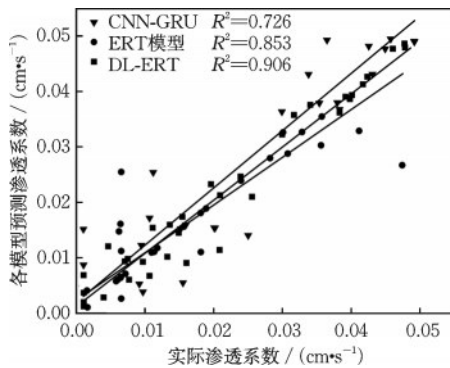


图6 不同模型对测试集的散点拟合精度图

Fig.6 Scatter plot of fitting accuracy for test set using different models

### 3 非均质含水层室内砂箱试验

为使融合算法具有更好的运用场景,现制作非均质含水层室内砂箱试验,将DL-ERT模型运用于已知渗透系数分布的二维剖面,观测其在实际试验下的刻画精度。

#### 3.1 试验装置

试验模型如图7所示,其主要由上游水箱、砂箱

主体和电阻率数据采集系统三部分组成。上游水箱用于模拟饱和地下水土壤。砂箱尺寸为10 cm×10 cm×30 cm(长×宽×高),由透明亚克力板制成,板与板连接处的内壁贴有铜片,放电时由导线接地形成零电压边界。砂箱主体布置有多个监测孔,最外侧孔距左右两边界的距离为2 cm,内部相邻监测孔四周的间距为3 cm。电阻率数据采集系统则包括三维层析扫描装置、电池箱和电缆接头等。现选取砂箱中部的9个监测孔布置电极,以避免上下边界试验器材的影响,将其连接到电阻率数据采集系统,用于收集对砂箱内部某一电极进行放电时其余监测点的电势刺激—响应数据。

另外,本次砂箱试验为更好反映地下水含水层的非均质性,拟采用两种渗透系数差异较大的砂样对砂箱主体进行填充,填充范围为10 cm×10 cm×10 cm。取其中一个剖面进行渗透系数分布反演研究,从而对9个监测孔进行电势刺激—响应规律的探索。




图7 砂箱装置示意图

Fig.7 Schematic diagram of sandbox setup

#### 3.2 试验步骤

(1)将预处理好的土样分层装入砂箱,每一层进行压实和刮毛处理,直至试样完全装载。

(2)上游水箱缓慢加入渗透水流,直至砂箱内部水面与试样顶部平行,停水静置一段时间确保土壤饱和。

(3)将监测电极与三维层析扫描装置连接并设定电极布置和供电参数。

(4)进行仪器自检并开始测量,确保设备稳定

并检查电极接触情况。

(5)开始测量,通过电源向特定电极通电并采集剩余电极的响应数据。重复九组,每组测量后停止供电 0.2 s,以避免极化反应。

### 3.3 电势响应特征分析

设置在砂箱内部的二维剖面一共布设了9个电极,每个电极在放电时有其余8个电极在接收电势刺激信号,最后共能得到九组响应数据。由于测量时可能会有电极极化、电极接触不良、线路老化等原因会造成一些数据产生误差。而当测量的电势数据存在较大误差时,直接将全部刺激—响应数据带入模型进行反演将会对反演结果造成显著的影响。因此,在反演之前需要对电极进行电势响应特征分析,以确保测量数据的合理性。现分别对9个电极的测量数据进行电势刺激—响应特征分析,将响应数据可视化后如图8所示。

从图8可以看出,当一个电极进行放电时,距离较近的电极接收到的电势信号较强,距离较远的电极接收到的信号较弱,整个电势响应分布大致以刺激源点为圆心向四周渐弱扩散,这与实际物理现象

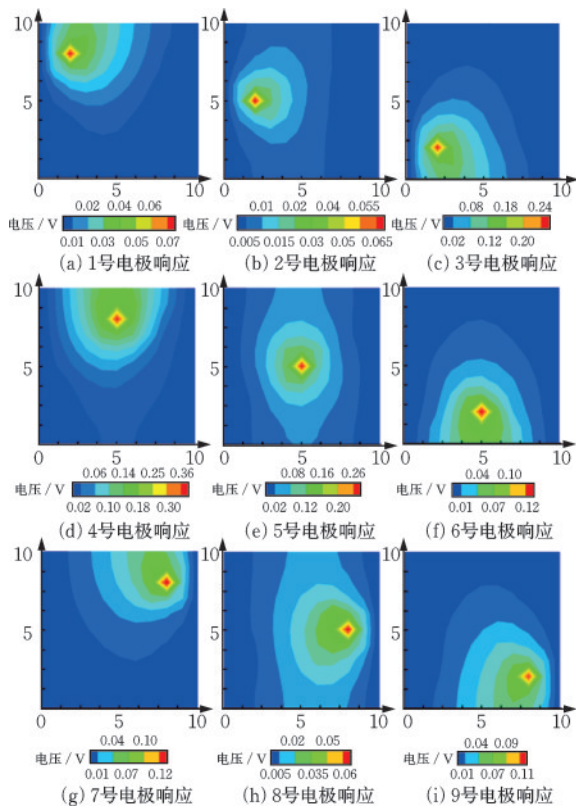


图8 剖面9个电极电势响应特征图

Fig.8 Potential response characteristics of 9 electrodes along profile

一致。因此,该试验的9组电极电势刺激—响应数据均可以用于后续的电阻率分布反演分析。

### 3.4 渗透系数反演精度对比分析

将3.3小节所得的所有电势刺激—响应数据分别带入克里金插值法、ERT、CNN-GRU以及DL-ERT中进行地下水含水层渗透系数的预测反演,再把各模型所得的渗透系数分布同已知的真实渗透系数分布进行可视化,结果如图9所示。

从图9可以发现,在图9(a)已知的真实渗透系数分布中,高渗区域主要位于右侧中部及左侧小范围区域,其余区域的渗透系数较低。图9(b)是传统算法克里金插值法刻画的含水层渗透系数分布,该算法可以刻画右侧高渗区域,但结果并不精准,其范围偏大,且对左侧的高渗区未能识别。图9(c)是ERT反演得到的渗透系数分布,该算法可以大致刻画左右两侧的高渗区域,但与真实分布对比,ERT对渗透高值的刻画存在较大误差,导致总的反演高渗范围整体偏大。图9(d)为CNN-GRU预测所得的渗透系数分布图,该算法预测的左右两侧高渗区整体向上偏移,且网络对极端值的预测并不准确,将较大部分的低渗区错误的赋予了高渗透值,导致

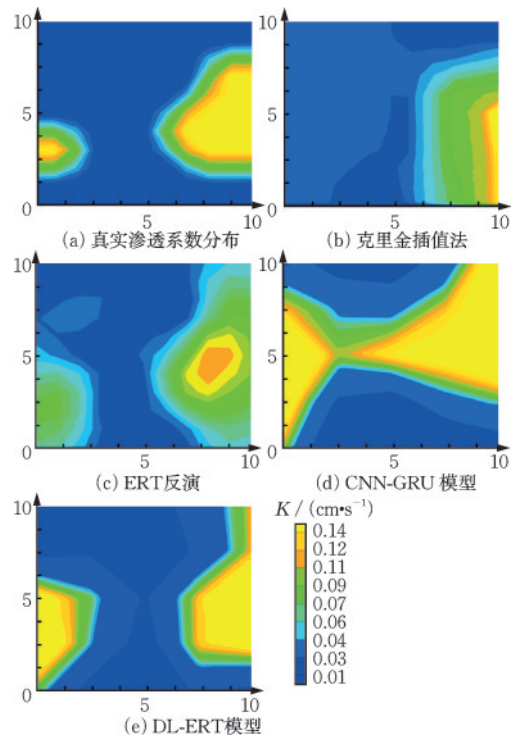


图9 不同模型反演渗透系数分布图

Fig.9 Distribution of permeability coefficient inversion using different models

总的预测范围具有较大差异。图9(e)则为联合解译模型DL-ERT预测所得的渗透系数分布图,相比于上述其他方法可以发现,DL-ERT对右侧的高渗区域刻画更为精准,尽管左侧高渗区域的刻画略有偏差,但是其结果也与真实渗透系数分布较为接近。

最后,为了更为直观的对比各方法对渗透系数刻画效果的优劣,将它们各自反演预测所得的渗透系数分布同已知的砂箱试验真实渗透系数分布作拟合精度分析,各模型的拟合精度散点图如图10所示。

从图10可知,上述4种模型的拟合精度值分别为0.707、0.836、0.760和0.895。分析结果表明:克里金插值法可能受限于电极布设的限制,其插值精度较低;ERT得益于SLE算法对物理规律的运用,该方法实现了较高的渗透系数反演精度;CNN-GRU在面对复杂地下水渗透系数分布时模型泛化性还不够充分,但也展现出较高的运用潜力;而结合物理机理与深度学习的融合算法DL-ERT则较为完整的预测出了真实渗透系数的分布情况,在精度和适用性方面都优于其他方法。

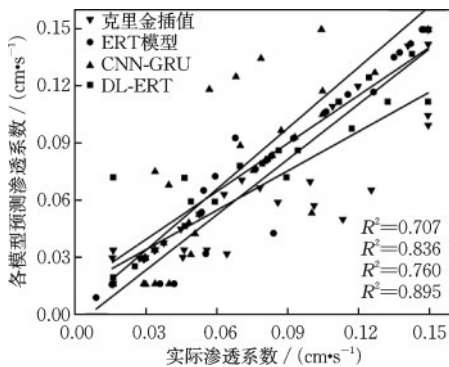


图10 不同模型反演结果与真实渗透系数散点拟合精度图  
Fig.10 Scatter plot of fitting accuracy between inversion results using different models and actual permeability coefficients

## 4 结 论

根据残差网络将CNN-GRU和ERT进行优化集成学习,基于含水层电势刺激与响应的数值模拟提出了一个联合多方法解译电势信号的DL-ERT算法模型。对其开展室内砂箱试验,将该算法模型与多个传统模型都运用于已知渗透系数分布的二

维剖面作对比论证,观测各个算法模型在地下水含水层的渗透系数刻画精度,得出结论如下:

(1)模型训练过程中,训练损失和验证损失都快速下降,两者趋势一致且最后的收敛均趋近于零,表明DL-ERT模型的学习能力强,具有较好的泛化性能。

(2)以测试集的某一样本为例,DL-ERT模型的渗透系数预测值与真实值拟合精度达到了0.906,优于单一算法CNN-GRU的精度值0.726和ERT的精度值0.853。从云图可视化结果来看,DL-ERT模型确实集成了两种算法的优势,其预测结果能更准确地反映实际渗透系数的分布情况。

(3)在实际试验下,克里金插值法的精度最低,DL-ERT模型的预测效果最好。虽然DL-ERT模型刻画的左侧高渗区域范围偏大,但是相比于其它算法模型,其预测精度也提升了7%~17%。表明了该模型在实际工程运用方面的潜力。

## 参考文献:

- [1] 王鑫永,王锡勇,章杨松,等.岩体裂隙连通路径及岩体等效渗透张量参数研究[J].防灾减灾工程学报,2020,40(5):789-795.  
Wang X Y, Wang X Y, Zhang Y S, et al. Study on connected path of rock fracture and equivalent permeability tensor parameters of rock mass[J]. Journal of Disaster Prevention and Mitigation Engineering, 2020, 40(5): 789-795. (in Chinese)
- [2] 王志杰,姜鹏飞,景所林,等.煤矿地下水底板渗流模拟试验系统研制及验证[J].煤炭学报,2021,46(5):1487-1497.  
Wen Z J, Jiang P F, Jing S L, et al. Development and verification of simulation testing system for floor seepage in coal mine underground reservoir[J]. Journal of China Coal Society, 2021, 46(5): 1487-1497. (in Chinese)
- [3] 江文豪,冯晨,黄啸,等.缓冲层-复合隔离墙-含水层系统中有机污染物二维运移规律研究[J].岩土力学,2024,45(增1):731-741.  
Jiang W H, Feng C, Huang X, et al. Two-dimensional transport mechanisms of organic contaminants in a buffer layer-composite cutoff wall-aquifer system[J]. Rock and Soil Mechanics, 2024, 45(Sup1): 731-741. (in Chinese)
- [4] 曹渊,牛冠毅,王铁良.基于钻孔充气试验的岩石渗透率原位测量研究[J].岩土工程学报,2017,39(3):

- 534-539.
- Cao Y, Niu G Y, Wang T L. In-situ measurement of rock permeability based on pneumatic tests in boreholes [J]. Chinese Journal of Geotechnical Engineering, 2017, 39(3): 534-539. (in Chinese)
- [5] 吴冰, 朱鸿鹄, 曹鼎峰, 等. 黄土水分场光纤原位监测及非饱和渗透系数估算[J]. 防灾减灾工程学报, 2019, 39(5): 691-699.
- Wu B, Zhu H H, Cao D F, et al. In-situ monitoring of moisture field and estimation of unsaturated permeability coefficient of loess foundation[J]. Journal of Disaster Prevention and Mitigation Engineering, 2019, 39(5): 691-699. (in Chinese)
- [6] 包孟碟, 朱俊高, 吴二鲁, 等. 基于级配方程的粗粒土渗透系数经验公式及其验证[J]. 岩土工程学报, 2020, 42(8): 1571-1576.
- Bao M D, Zhu J G, Wu E L, et al. Empirical formula for permeability coefficient of coarse grained soil based on gradation equation and its verification [J]. Chinese Journal of Geotechnical Engineering, 2020, 42(8): 1571-1576. (in Chinese)
- [7] 蒋小虎, 黄跃廷, 胡海军, 等. 基于原位双环、试坑浸水试验和数值模拟反演的Q3黄土饱和渗透系数对比研究[J]. 岩土力学, 2022, 43(11): 2941-2951.
- Jiang X H, Huang Y T, Hu H J, et al. Comparison of saturated permeability coefficient of Q3 loess based on in-situ double ring test, field water immersion test and numerical simulation inversion [J]. Rock and Soil Mechanics, 2022, 43(11): 2941-2951. (in Chinese)
- [8] Eggleston J, Rojstaczer S. The value of grain-size hydraulic conductivity estimates: Comparison with high resolution in-situ field hydraulic conductivity [J]. Geophysical Research Letters, 2001, 28(22): 4255-4258.
- [9] Ruan K, Fu X L. A modified Kozeny-Carman equation for predicting saturated hydraulic conductivity of compacted bentonite in confined condition [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2022, 14(3): 984-993.
- [10] Vienken T, Dietrich P. Field evaluation of methods for determining hydraulic conductivity from grain size data [J]. Journal of Hydrology, 2011, 400(1-2): 58-71.
- [11] 李治甫, 康帅, 王自法, 等. 基于时频变换和卷积神经网络的结构损伤识别[J]. 防灾减灾工程学报, 2023, 43(6): 1275-1283.
- Li Z F, Kang S, Wang Z F, et al. Structural damage identification based on time-frequency transform and convolutional neural network [J]. Journal of Disaster Prevention and Mitigation Engineering, 2023, 43(6): 1275-1283. (in Chinese)
- [12] 张成龙, 丁世飞, 郭丽丽, 等. 随机配置网络研究进展 [J]. 软件学报, 2024, 35(5): 2379-2399.
- Zhang C L, Ding S F, Guo L L, et al. Research Progress on Stochastic Configuration Network [J]. Journal of Software, 2024, 35(5): 2379-2399. (in Chinese)
- [13] Srisutthiyakorn N. Deep-learning methods for predicting permeability from 2D/3D binary-segmented images [C]//SEG technical program expanded abstracts 2016. Tulsa: Society of Exploration Geophysicists, 2016: 3042-3046.
- [14] Zhong Z, Carr T R, Wu X, et al. Application of a convolutional neural network in permeability prediction: A case study in the Jacksonburg-Stringtown oil field, West Virginia, USA [J]. Geophysics, 2019, 84(6): B363-B373.
- [15] Tian Y, Wang G, Li H, et al. A novel deep learning method based on 2-D CNNs and GRUs for permeability prediction of tight sandstone [J]. Geoenergy Science and Engineering, 2024, 238: 212851.
- [16] Alao O J, Lawal M K, Dewu M B B, et al. Detection of shallow underground targets using electrical resistivity tomography and the implications in civil/environmental engineering [J]. Discover Geoscience, 2024, 2(1): 52-52.
- [17] 盛丰, 文鼎, 熊祎玮, 等. 基于电阻率层析成像技术的农田土壤优先流原位动态监测 [J]. 农业工程学报, 2021, 37(8): 117-124.
- Sheng F, Wen D, Xiong Y W, et al. In-situ monitoring of preferential soil water flow with electrical resistivity tomography technology [J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2021, 37(8): 117-124. (in Chinese)
- [18] Perdomo S, Kruse E E, Ainchil J E. Estimation of hydraulic parameters using electrical resistivity tomography (ERT) and empirical laws in a semi-confined aquifer [J]. Near Surface Geophysics, 2018, 16(6): 627-641.
- [19] González J A M, Comte J C, Legchenko A, et al. Quantification of groundwater storage heterogeneity in weathered/fractured basement rock aquifers using electrical resistivity tomography: Sensitivity and uncertainty associated with petrophysical modelling [J]. Journal of Hydrology, 2021, 593: 125637.
- [20] 刘征宇, 庞永昊, 王传武, 等. 基于不完整边界先验信息的跨孔电阻率CT反演方法研究 [J]. 岩土工程学报, 2019, 41(6): 1124-1132.
- Liu Z Y, Pang Y H, Wang C W, et al. Cross-hole re-

- sistivity inversion method constrained by prior information of incomplete boundary[J]. Chinese Journal of Geotechnical Engineering, 2019, 41(6): 1124-1132. (in Chinese)
- [21] 刘征宇, 李术才, 刘斌, 等. 基于距离加权约束算法的围岩三维电阻率CT反演成像研究[J]. 岩土工程学报, 2017, 39(4): 652-661.
- Liu Z Y, Li S C, Liu B, et al. 3D cross-hole resistivity inversion imaging of surrounding rock based on distance weighting constraint algorithm [J]. Chinese Journal of Geotechnical Engineering, 2017, 39(4): 652-661. (in Chinese)
- [22] Liu X, Shen J, Yang M, et al. Subsurface characterization of a construction site in Nanjing, China using ERT and CPTU methods [J]. Engineering Geology, 2022, 299: 106563.
- [23] Cromwell E, Shuai P, Jiang P, et al. Estimating watershed subsurface permeability from stream discharge data using deep neural networks[J]. Frontiers in Earth Science, 2021, 9: 613011.
- [24] Hou X, Hu R, Yeh T C J, et al. A short-term pumping strategy for hydraulic tomography based on the successive linear estimator [J]. Water Resources Research, 2023, 59(4): e2022WR033831.
- [25] 慎国强, 朱磊, 王希萍, 等. 投影卷积神经网络固、液相钾盐矿层预测[J]. 地质学报, 2024, 98(10): 2946-2955.
- Shen G Q, Zhu L, Wang X P, et al. Prediction of solid and liquid phase potash reservoirs with projected convolutional neural network [J]. Acta Geologica Sinica, 2024, 98(10): 2946-2955. (in Chinese)
- [26] 丁莹莹, 尹尚先, 连会青, 等. 基于SSA-CG-Attention模型的多因素采煤工作面涌水量预测[J]. 煤田地质与勘探, 2024, 52(4): 111-119.
- Ding Y Y, Yin S X, Lian H Q, et al. Prediction of mine water inflow along mining faces using the SSA-CG-Attention multifactor model [J]. Coal Geology & Exploration, 2024, 52(4): 111-119. (in Chinese)
- [27] Zhang G, Wang Z, Mohaghegh S, et al. Pattern visualization and understanding of machine learning models for permeability prediction in tight sandstone reservoirs [J]. Journal of Petroleum Science and Engineering, 2021, 200: 108142.

(本文编辑:赵霞)