



基于LSTM神经网络的随钻方位电磁波测井数据反演

康正明 秦浩杰 张意 李新 倪卫宁 李丰波

Data Inversion of Azimuthal Electromagnetic Wave Logging While Drilling Based on LSTM Neural Network

KANG Zhengming, QIN Haojie, ZHANG Yi, LI Xin, NI Weining, LI Fengbo

在线阅读 View online: <http://doi.org/10.11911/syztjs.2023047>

您可能感兴趣的其他文章

Articles you may be interested in

基于拟牛顿法的随钻方位电磁波电阻率仪器响应实时反演与现场试验

Real Time Inversion and Field Test of LWD Azimuthal Electromagnetic Waves Based on Quasi-Newton Method

石油钻探技术. 2020, 48(3): 120-126 <http://doi.org/10.11911/syztjs.2020025>

随钻方位电磁波仪器测量精度对电阻率及界面预测影响分析

Impacts of Accuracy of Azimuthal Electromagnetic Logging-while-Drilling on Resistivity and Interface Prediction

石油钻探技术. 2017, 45(4): 115-120 <http://doi.org/10.11911/syztjs.201704020>

随钻方位电磁波电阻率测井仪分段组合线圈系设计

The Design of the Coil System in LWD Tools Based on Azimuthal Electromagnetic-Wave Resistivity Combined with Sections

石油钻探技术. 2017, 45(2): 115-120 <http://doi.org/10.11911/syztjs.201702019>

利用随钻电磁波测井探测直井水力裂缝的正演模拟

Forward Modeling in Hydraulic Fracture Detection by Means of Electromagnetic Wave Logging While Drilling in Vertical Wells

石油钻探技术. 2020, 48(2): 123-129 <http://doi.org/10.11911/syztjs.2019133>

随钻超深电磁波仪器探测深度及响应特征模拟

Simulation to Determine Depth of Detection and Response Characteristics while Drilling of an Ultra-Deep Electromagnetic Wave Instrument

石油钻探技术. 2020, 48(1): 114-119 <http://doi.org/10.11911/syztjs.2019132>

高精度随钻成像测井关键技术

The Key Technologies of High Precision Imaging Logging while Drilling

石油钻探技术. 2019, 47(3): 148-155 <http://doi.org/10.11911/syztjs.2019060>



扫码关注公众号，获取更多信息！

◀测井录井▶

doi:10.11911/syztjs.2023047

引用格式: 康正明, 秦浩杰, 张意, 等. 基于 LSTM 神经网络的随钻方位电磁波测井数据反演 [J]. 石油钻探技术, 2023, 51(2): 116-124.

KANG Zhengming, QIN Haojie, ZHANG Yi, et al. Data inversion of azimuthal electromagnetic wave logging while drilling based on LSTM neural network [J]. Petroleum Drilling Techniques, 2023, 51(2): 116-124.

基于 LSTM 神经网络的随钻方位 电磁波测井数据反演

康正明¹, 秦浩杰¹, 张 意², 李 新^{3,4}, 倪卫宁^{3,4}, 李丰波^{3,4}

(1. 西安石油大学电子工程学院, 陕西西安 710065; 2. 中煤科工西安研究院(集团)有限公司, 陕西西安 710077; 3. 页岩油气富集机理与有效开发国家重点实验室, 北京 102206; 4. 中石化石油工程技术研究院有限公司, 北京 102206)

摘 要: 随钻方位电磁波测井仪器在地质导向和储层评价等方面具有重要作用, 但其测量响应不具有直观性, 需要用反演方法获得地层信息, 高斯-牛顿法、随机反演算法等传统反演方法计算速度较慢, 难以满足实时反演的要求。为此, 提出了一种基于长短期记忆人工神经网络 (LSTM) 的新反演方法, 用于求取地层电阻率。首先, 基于广义反射系数法建立正演算法, 完成样本集的制作; 然后, 搭建 LSTM 神经网络模型, 基于样本集进行训练和测试, 通过遍历的方法优选出合适的网络参数; 最后, 在测试集上完成电阻率的反演, 将反演电阻率与正演电阻率进行对比, 对比反演所需时间和相对误差, 并在测试集中加入白噪声验证了模型的抗噪能力。研究结果表明, 模型能够准确快速地反演地层电阻率信息, 能够满足对含有噪声数据的反演需要, 具有较好的鲁棒性。此反演方法为测井资料处理提供了新的思路 and 方向。

关键词: LSTM 神经网络; 电阻率反演; 随钻方位电磁波测井; 正演计算; 地质导向

中图分类号: P631.8⁺13

文献标志码: A

文章编号: 1001-0890(2023)02-0116-09

Data Inversion of Azimuthal Electromagnetic Wave Logging While Drilling Based on LSTM Neural Network

KANG Zhengming¹, QIN Haojie¹, ZHANG Yi², LI Xin^{3,4}, NI Weining^{3,4}, LI Fengbo^{3,4}

(1. School of Electronic Engineering, Xi'an Shiyou University, Xi'an, Shaanxi, 710065, China; 2. Xi'an Research Institute Co. Ltd., China Coal Technology and Engineering Group Corp., Xi'an, Shaanxi, 710077, China; 3. State Key Laboratory of Shale Oil and Gas Enrichment Mechanisms and Effective Development, Beijing, 102206, China; 4. Sinopec Research Institute of Petroleum Engineering Co., Ltd, Beijing, 102206, China)

Abstract: Azimuthal electromagnetic wave logging while drilling (LWD) tool plays an important role in geosteering and reservoir evaluation, but its measurement response is not intuitive. So inversion method is needed to obtain formation information. Traditional inversion methods (i.e., Gauss-Newton method, random inversion method, etc.) are difficult to meet the requirements of real-time inversion due to the slow calculation speed. In this paper, a new inversion method based on a long and short-term memory (LSTM) artificial neural network was proposed to obtain formation resistivity. Firstly, the forward algorithm was established based on the method of generalized reflection coefficient to produce the sample set. Then, the LSTM neural network model was built, and it was trained and tested on the sample set. The appropriate network parameters were optimized by the traversal method. Finally, the resistivity inversion was completed on the test set. The inverted resistivity was compared with the forward resistivity, and the

收稿日期: 2022-07-25; 改回日期: 2023-03-16。

作者简介: 康正明 (1989—), 男, 陕西靖边人, 2014 年毕业于西安石油大学勘查技术与工程专业, 2019 年获中国石油大学 (北京) 地质资源与地质工程专业博士学位, 讲师, 主要从事电法测井理论方法研究。E-mail: 190720@xsyu.edu.cn。

通信作者: 张意, yizhang86@163.com。

基金项目: 国家自然科学基金企业创新发展联合基金项目“海相深层油气富集机理与关键工程技术基础研究” (编号: U19B6003)、中国博士后科学基金项目“煤岩层界面及低阻异常体随钻方位电磁波探测方法研究” (编号: 2022M711442)、陕西省重点研发计划项目“煤矿井下方位电磁波探测技术与仪器研究” (编号: 2023-YBGY-111)、陕西省教育厅重点科学研究计划项目“基于随钻电成像测井的页岩气储层裂缝参数计算模型研究” (编号: 22JY053) 和西安石油大学研究生创新与实践能力的培养计划 (编号: YCS22214245) 联合资助。

inversion time and relative error were compared as well. Meanwhile, the anti-noise property of the model is verified by adding white noise to the test set. The results show that the model can accurately and rapidly invert formation resistivity and can invert data containing noise, indicating that the model has good robustness. This inversion method can provide a new idea and direction for logging data processing.

Key words: LSTM neural network; resistivity inversion; azimuthal electromagnetic wave LWD; forward calculation; geosteering

随着石油勘探开发不断深入,非常规油气藏越来越受到重视,但该类油气藏地质条件复杂,钻井过程中井眼轨迹的控制难度大。定向钻井时利用地质导向技术对井眼轨迹进行动态调整,可以较好地解决这一问题。定向钻井时测得的各种地球物理数据中,随钻方位电磁波电阻率不仅包含地层电阻率信息,还可以反映岩性界面位置^[1-4],因此随钻方位电磁波电阻率测井解释结果是油气井地质导向决策的主要依据之一。

随钻方位电磁波测井响应与所求解的地质参数之间存在高度的非线性关系,因此往往需要借助反演手段获取地层参数。目前常用的反演方法主要包括高斯-牛顿法和随机反演算法,如 G.Wang 等人^[5]在各向异性地层中使用了基于快速正演求解器的高斯-牛顿法进行反演,收敛速度快,但每一步迭代都需要求解目标函数的雅克比矩阵,计算量大,若初值设置不当,反演结果可能不准确,甚至无法收敛^[6];随机反演算法计算过程简单,鲁棒性强,但收敛速度慢,无法满足实时反演的要求。

近年来,深度学习技术在人工智能领域取得了显著成果,表明深度神经网络对于复杂结构有着很强的表征能力^[7-10],利用深度学习进行地层反演或将成为替代传统反演的新方法^[11-13]。例如, Jin Yuchen 等人^[14]利用深度神经网络和严格的正演模型反演了 1.5D 随钻电阻率数据; Y. Hu 等人^[15]将梯度下降算法和机器学习算法相结合,增强了模型反演的鲁棒性; M. Shahriari 等人^[16]利用深度学习反演了井眼电阻率测井数据; D. Pardo 等人^[17]针对不同地质情况设计了多种深度学习反演架构,来实现随钻电阻率的 2.5D 反演。实践证明,深度学习方法可以用于测井数据反演。但传统的神经网络结构简单,存在收敛速度慢、数据表征能力有限等缺点。

针对上述问题,笔者基于 LSTM 网络建立了深度学习反演模型,并以斯伦贝谢公司的随钻方位电磁波测井仪 PeriScope 数值模拟数据为样本,对该模型进行训练和测试;训练后的深度学习模型能够准确快速地反演地层电阻率,且有一定的鲁棒性。

1 随钻方位电磁波测井原理

目前电磁波测井常用的线圈系结构如图 1 所示。其中,图 1(a)所示线圈结构采用轴向发射和轴向接收,不具有方位性,主要用来测量地层电阻率信号;图 1(b)所示线圈结构采用轴向发射与倾斜接收,这样的线圈结构使测量信号具有方位性,可以用于测量地质信号^[18-20]。




图 1 方位电磁波测井常用线圈结构

Fig.1 Commonly used coil structure in azimuthal electromagnetic wave logging

测量地层电阻率信号时,记录 2 个接收线圈上的电压,并将其转换为幅度比和相位差(见图 1(a)):

$$Att = 20 \lg \frac{\sqrt{[\operatorname{Re}(U_{R1})]^2 + [\operatorname{Im}(U_{R1})]^2}}{\sqrt{[\operatorname{Re}(U_{R2})]^2 + [\operatorname{Im}(U_{R2})]^2}} \quad (1)$$

$$PS = \arctan \frac{\operatorname{Im}(U_{R1})}{\operatorname{Re}(U_{R1})} - \arctan \frac{\operatorname{Im}(U_{R2})}{\operatorname{Re}(U_{R2})} \quad (2)$$

式中: Att 为幅度比, dB; PS 为相位差, ($^{\circ}$); U_{R1} 和 U_{R2} 分别为 2 个接收线圈上的电压值, V; Re 表示取电压实部, Im 表示取电压虚部。

测量岩性界面信号时,仪器在每个测量位置沿轴心旋转一周,测量多个扇区的值(现有商用仪器每旋转一周测量 16 个或 32 个扇区),取其在旋转角 $\beta_1 = 0^{\circ}$ 和 $\beta_2 = 180^{\circ}$ 的测量电压作为幅度比和相位差的计算参数(见图 1(b))。幅度比地质信号和相位差地质信号的计算公式分别为:

$$G_{Att} = 20 \lg \frac{\sqrt{[\operatorname{Re}(U_{\beta_1})]^2 + [\operatorname{Im}(U_{\beta_1})]^2}}{\sqrt{[\operatorname{Re}(U_{\beta_2})]^2 + [\operatorname{Im}(U_{\beta_2})]^2}} \quad (3)$$

$$G_{PS} = \arctan \frac{\operatorname{Im}(U_{\beta_1})}{\operatorname{Re}(U_{\beta_1})} - \arctan \frac{\operatorname{Im}(U_{\beta_2})}{\operatorname{Re}(U_{\beta_2})} \quad (4)$$

式中: G_{Att} 为幅度比地质信号, dB; G_{PS} 为相位差地质信号, ($^\circ$); U_{β_1} 和 U_{β_2} 分别为工具面角为 β_1 和 β_2 时的测量电压, V。

2 电阻率反演网络模型

2.1 模型工作流程

电阻率反演流程如图2所示。首先建立水平层状各向异性地层(TI)模型, 地层参数(主要为水平电阻率 R_h 和垂直电阻率 R_v)随机取值; 然后通过正演计算得到不同地层参数下对应的测井响应(主要为幅度比 Att 和相位差 PS), 建立包含大量数据对[地层参数, 测井响应]的样本集; 最后基于预处理后的样本集训练神经网络。训练时将测井响应作为神经网络的输入, 地层参数作为神经网络的输出, 神经网络自动学习从测井响应到地层参数的映射。

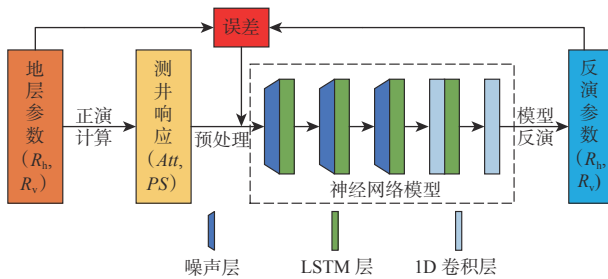


图2 电阻率反演流程

Fig.2 Inversion flow of resistivity

搭建的神经网络模型主要由噪声层、LSTM层和1D卷积层组成。噪声层可以避免神经网络在训练时出现过拟合, 使训练后的神经网络具有较强的鲁棒性; 1D卷积层可以代替普通神经网络中的全连接层, 将分布式特征空间映射到地层电阻率等数据的拟合结果; LSTM层是神经网络模型的核心, 它可以拾取数据特征、解决神经网络在处理时间序列数据时出现的梯度消失或梯度爆炸的问题, 网络架构如图3所示(δ 代表Sigmoid函数, 其表达式为 $\delta(x) = \frac{1}{1+e^{-x}}$, 返回的是一个(0, 1)内的数字; h_{t-1} 和 x_t 分别为前一个神经元的输出和当前神经元的输入; C_{t-1} 为前一个状态, f_t 由式(5)计算)^[21]。

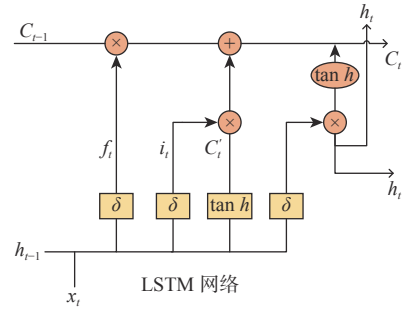


图3 LSTM网络架构

Fig.3 Architecture of LSTM network

$$f_t = \delta(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

式中: W_f 和 b_f 分别为权重矩阵和偏置。

若 f_t 为 1, 则代表完全保留 C_{t-1} 中的信息; 若 f_t 为 0, 则代表完全删除 C_{t-1} 中的信息。

C'_t 是当前神经元经过 \tanh 激活函数处理得到的有效信息, i_t 的计算与 f_t 类似, 它决定了当前神经元信息的保存:

$$i_t = \delta(W_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$C'_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (7)$$

将上一个状态值乘以 f_t , 用来表示期待清除的信息, 再将得到的值加上 $i_t C'_t$, 即可得到当前神经元的状态值 C_t , 完成信息的更新与传递。即:

$$C_t = f_t C_{t-1} + i_t C'_t \quad (8)$$

此外, 由于随钻方位电磁波测量的幅度比和相位差与电阻率为非线性对应关系, 还需要给神经网络的激励层加上非线性激活函数, 来增加神经网络的非线性映射能力。ReLU 激活函数的收敛速度快且求导简单, 进行反向传播时在速度方面具有较大的优势, 因此, 本文以此函数为激励函数。

2.2 随钻方位电磁波测量响应解析计算方法

水平层状各向异性地层模型中, 随钻方位电磁波测井的数值模拟方法主要有解析方法和数值模式匹配等。相对于数值模式匹配等方法, 解析方法中的传播系数矩阵法避免了 N 层界面对 $2N$ 个方程联立求解, 在界面较多时, 这种递推方法的计算速度更快, 本文采用此方法计算 TI 模型随钻方位电磁波测井响应。

电磁波在介质中传播满足微分形式的麦克斯韦方程组:

$$\begin{cases} \nabla \times \mathbf{H} = \mathbf{J} + \frac{\partial \mathbf{D}}{\partial t} \\ \nabla \times \mathbf{E} = -\frac{\partial \mathbf{B}}{\partial t} \\ \nabla \cdot \mathbf{B} = 0 \\ \nabla \cdot \mathbf{D} = \rho \end{cases} \quad (9)$$

式中: \mathbf{H} 为磁场强度, A/m; \mathbf{E} 为电场强度, N/C; \mathbf{B} 为磁感应强度, T; \mathbf{D} 为电位移矢量, C/m²; \mathbf{J} 为传导电流密度, A/m²; ρ 为电荷密度, C/m³。

电磁波在媒质中的传播满足本构关系:

$$\begin{cases} \mathbf{D} = \varepsilon \mathbf{E} \\ \mathbf{B} = \mu \mathbf{H} \\ \mathbf{J} = \sigma \mathbf{E} \end{cases} \quad (10)$$

式中: ε 为媒质的介电常数; μ 为媒质的磁导率, H/m; σ 为电导率张量。

电磁波测井发射线圈的尺寸相对于线圈源距可忽略不计, 发射线圈可以等同于一个磁偶极源, 在进行电磁波测井时一般使用时谐电流源 $e^{-i\omega t}$, 因此在均匀各向异性地层中, 时谐场麦克斯韦方程组可表示为:

$$\begin{cases} \nabla \times \mathbf{H} = \sigma \mathbf{E} \\ \nabla \times \mathbf{E} = i\omega(\mu_0 \mathbf{H} + \mu_0 \mathbf{M}_S) \end{cases} \quad (11)$$

式中: \mathbf{M}_S 为外加磁流源; μ_0 为真空中磁导率, H/m。

在推导中常使用 Hertz 势理论, Hertz 矢量势 $\mathbf{\Pi}$ 和标量势 Ψ 满足:

$$\begin{cases} \sigma \mathbf{E} = i\omega\mu_0\sigma_h \nabla \times \mathbf{\Pi} \\ \mathbf{H} = i\omega\mu_0\sigma_h \mathbf{\Pi} + \nabla \Psi \\ \nabla(\sigma \mathbf{\Pi}) = \sigma_v \Psi \end{cases} \quad (12)$$

式中: σ_h 为电导率水平分量, S/m; σ_v 为电导率垂直分量, S/m。

将式 (10) 代入式 (9), 可得均匀各向异性介质中的磁偶极源表达式, 然后将其代入式 (12), 可得:

$$\begin{cases} E_z = -\frac{1}{4\mathbf{H}} (M_x \sin \alpha - M_y \cos \alpha) \int_0^\infty \omega \mu \lambda k_\rho^2 \frac{J_1(k_\rho \rho)}{k_{v,z}} e^{i|z|k_{v,z}} k_\rho dk_\rho \\ H_z = \frac{1}{4\mathbf{H}} (M_x \cos \alpha + M_y \sin \alpha) \int_0^\infty k_\rho^2 \frac{\partial |z|}{\partial z} J_1(k_\rho \rho) e^{i|z|k_{v,z}} dk_\rho + \frac{M_z}{4\mathbf{H}} \int_0^\infty i k_\rho^3 \frac{J_0(k_\rho \rho)}{k_{h,z}} e^{i|z|k_{h,z}} dk_\rho \end{cases} \quad (13)$$

因此, 在 TI 模型中电磁场由以下递推公式进行计算:

$$E_{n,z} = -\frac{1}{4\mathbf{H}} (M_x \sin \alpha - M_y \cos \alpha) \omega \mu \lambda_n \frac{k_\rho^2}{k_{n,v,z}} J_1(k_\rho \rho) F_n^{TM,h} \quad (14)$$

$$\begin{aligned} H_{n,z} = & \frac{1}{4\mathbf{H}} (M_x \cos \alpha + M_y \sin \alpha) k_\rho^2 J_1(k_\rho \rho) F_n^{TM,h} + \\ & \frac{1}{4\mathbf{H}} M_z \frac{i k_\rho^3}{k_{n,h,z}} (k_\rho \rho) F_n^{TM,v} \end{aligned} \quad (15)$$

$$\begin{aligned} F_n^{TE,h} = & \delta_{mn} \frac{|z-z_0|}{z-z_0} e^{ik_{n,h,z}|z-z_0|} + U_n^{TE,h} e^{ik_{n,h,z}(z-d_n)} + \\ & D_n^{TE,h} e^{-ik_{n,h,z}(z-d_{n-1})} \end{aligned} \quad (16)$$

$$F_n^{TE,v} = \delta_{mn} e^{ik_{n,h,z}|z-z_0|} + U_n^{TE,h} e^{ik_{n,h,z}d_n} + D_n^{TE,h} e^{-ik_{n,h,z}(z-d_{n-1})} \quad (17)$$

$$\begin{aligned} F_n^{TM,h} = & \delta_{mn} e^{i\lambda k_{n,v,z}|z-z_0|} + U_n^{TE,h} e^{ik_{n,v,z}(z-d_n)} + \\ & D_n^{TM,h} e^{-i\lambda k_{n,v,z}(z-d_{n-1})} \end{aligned} \quad (18)$$

$$\delta_{mn} = \begin{cases} 1 & m = n \\ 0 & m \neq n \end{cases} \quad (19)$$

式中: F_n 为第 n 层的传播项; 上标 TM 表示 TM 波的 z 分量, TE 表示 TE 波的 z 分量, h 表示水平磁偶极子, v 表示垂直磁偶极子, z 和 z_0 表示接受点和发射源位置的纵坐标, d_n 表示界面位置; D_n , U_n 分别为第 n 层底界面处的下行波和上行波的波膜, 可由式 (20) 推出。

$$\begin{cases} U_{n+1}^{TE,v} = U_n^{TE,v} e^{ik_{n,h,z}(d_{n+1}-d_n)} \frac{1 + R_{U,n}^{TE,v}}{1 + R_{U,n+1}^{TE,v} e^{i2k_{n+1,h,z}(d_{n+2}-d_{n+1})}} \\ D_n^{TE,v} = U_n^{TE,v} R_{U,n}^{TE,v} e^{i2k_{n,h,z}(d_{n+1}-d_n)} \\ U_{n+1}^{TE,h} = U_n^{TE,h} e^{ik_{n,h,z}(d_{n+1}-d_n)} \frac{1 + R_{U,n}^{TE,h}}{1 + R_{U,n+1}^{TE,h} e^{i2k_{n+1,h,z}(d_{n+2}-d_{n+1})}} \\ D_n^{TE,h} = U_n^{TE,h} R_{U,n}^{TE,h} e^{i2k_{n,h,z}(d_{n+1}-d_n)} \\ U_{n+1}^{TM,h} = \frac{\varepsilon_n}{\varepsilon_{n+1}} U_n^{TM,h} e^{i\lambda k_{n,v,z}(d_{n+1}-d_n)} \frac{1 + R_{U,n}^{TM,h}}{1 + R_{U,n+1}^{TM,h} e^{i2k_{n+1,v,z}(d_{n+2}-d_{n+1})}} \\ D_n^{TM,h} = U_n^{TM,h} R_{U,n}^{TM,h} e^{i2\lambda k_{n,v,z}(d_{n+1}-d_n)} \end{cases} \quad (20)$$

式中: $R_{D,n}$, $R_{U,n}$ 分别为第 n 层底界面处下行波和第 n 层顶界面处上行波的广义反射系数。其递推公式如下:

$$\begin{cases} R_{U,n}^{TE} = \frac{R_{n,n+1}^{TE} + R_{U,n+1}^{TE} e^{i2k_{n+1,h,z}(d_{n+1}-d_n)}}{1 + R_{n,n+1}^{TE} R_{U,n+1}^{TE} e^{i2k_{n+1,h,z}(d_{n+1}-d_n)}} \\ R_{D,n}^{TE} = \frac{R_{n,n-1}^{TE} + R_{D,n-1}^{TE} e^{i2k_{n-1,h,z}(d_{n-1}-d_{n-2})}}{1 + R_{n,n-1}^{TE} R_{D,n-1}^{TE} e^{i2k_{n-1,h,z}(d_{n-1}-d_{n-2})}} \\ R_{U,n}^{TM,h} = \frac{R_{n,n+1}^{TM,h} + R_{U,n+1}^{TM,h} e^{i2k_{n+1,v,z}(d_{n+1}-d_n)}}{1 + R_{n,n+1}^{TM,h} R_{U,n+1}^{TM,h} e^{i2\lambda k_{n+1,v,z}(d_{n+1}-d_n)}} \\ R_{D,n}^{TM,h} = \frac{R_{n,n-1}^{TM,h} + R_{D,n-1}^{TM,h} e^{i2\lambda k_{n-1,v,z}(d_{n-1}-d_{n-2})}}{1 + R_{n,n-1}^{TM,h} R_{D,n-1}^{TM,h} e^{i2\lambda k_{n-1,v,z}(d_{n-1}-d_{n-2})}} \end{cases} \quad (21)$$

由式 (21) 递推关系可知所有界面的广义反射系数。广义反射系数由于使用简单解析表达式计算界面间的多次反射效应, 其递推公式避免了 N 层界面对应的 $2N$ 个方程的联立求解, 计算速度快。

2.3 地层模型和仪器参数

建立图 4 所示的 TI 地层模型 (模型层数为 3, 4,

5), 每一层的电阻率 R 、各向异性系数 λ ($\lambda^2 = R_v/R_h$)、地层界面位置 Z 及井斜角 θ 随机取值, 由于随钻电磁波测井适用于大斜度井和水平井, 因此将井斜角 θ 的取值范围设置为 $(65^\circ, 85^\circ)$ 。以斯伦贝谢公司生产的 PeriScope 随钻电磁波测井仪为例进行电阻率反演试验, 选用了 13 种线圈组合方式, 其中单发双收线圈 (见图 1(a)) 组合的有 5 组, 源距分别为 $[0.330 \text{ m}, 0.480 \text{ m}]$, $[0.480 \text{ m}, 0.635 \text{ m}]$, $[0.635 \text{ m}, 0.787 \text{ m}]$, $[0.787 \text{ m}, 0.889 \text{ m}]$ 和 $[0.889 \text{ m}, 1.090 \text{ m}]$, 频率设置为 400 kHz 和 2 MHz, 用于测量视电阻率信号; 单发单收的线圈组合 (见图 1(b)) 有 8 组, 对称法和反对称法各 4 组, 源距分别为 $(0.558 \text{ m}, 0.863 \text{ m}, 2.133 \text{ m}, 2.438 \text{ m})$, 频率分别设置为 100, 400 kHz 和 2 MHz, 用于测量地层边界, 被称为地质信号。基于正演算法计算每一种线圈组合在不同工作频率下的测井响应, 从而在每个地层样本下获得了 68 条不同的测井曲线 (幅度比和相位差各 34 条, 每条曲线的采样点数设置为 512)。至此得到了包含 30 000 个样本的数据集, 每个样本由 70 条曲线构成 (68 条测井响应曲线为神经网络输入, 2 条电阻率曲线为神经网络的预测值)。取其中 3 000 个样本作为验证集, 用于评估神经网络模型对电阻率的反演性能。




图 4 水平层状多层地层模型

Fig.4 Horizontal stratified formation model with multiple layers

2.4 数据集预处理

过正演计算生成的样本数据并不能直接作为神经网络的输入与输出, 还需处理异常数据, 进行数据转换和归一化处理。

由于地层电阻率等参数是随机取值, 当随机参数组合异常时, 可能导致正演结果出现无法计算的异常值, 对于这样的异常值采用归零法, 即把异常数据赋值为 0。本文同时输入同测量段不同源距和频率的测量曲线, 也即将输入数据转换为由多条测量曲线组成的二维图像; 通过归一化处理可以使样

本数据被限定在一定的范围内, 加快梯度下降求最优解的速度, 且有可能提高精度。本文采取的归一化方法为:

$$x_i = \text{sgn}(x_i) \lg[1 + |x_i|] \quad (22)$$

式中: x_i 为某条曲线中第 i 个采样点的值; $\text{sgn}(x)$ 为符号函数。

3 LSTM 网络训练与结果分析

3.1 LSTM 网络的训练与优化

在神经网络训练时, 学习率 (即在神经网络训练期间权重更新的量) 和批尺寸 (神经网络训练样本集较大, 无法一次性对所有数据进行训练, 常用的方法是每次向神经网络输入样本集的一部分) 对训练效果有很大影响, 因此优选这 2 个参数。

由于神经网络的训练速度和精度同时受学习率 (η) 和批尺寸 (n) 的影响, 本文同时使用不同的学习率和批尺寸对卷积网络进行遍历寻优。针对方位电磁波数据反演问题, 选用的学习率分别为 0.000 5, 0.001 0, 0.002 0, 0.004 0, 0.006 0 和 0.008 0, 批尺寸分别为 32, 64, 128 和 256 时, LSTM 网络训练的损失函数曲线如图 5—图 8 所示, 不同批尺寸和学习率下损失函数的最小值见表 1。

从图 5—图 8 及表 1 可以看出, 当批尺寸为 64、学习率为 0.002 时, LSTM 网络训练的损失误差最小, 精度最高。

3.2 反演结果分析

使用训练好的 LSTM 网络反演 3 层、4 层和 5 层地层模型的水平电阻率和垂直电阻率, 结果如图 9—图 11 所示。

从图 9—图 11 可以看出, 反演得到的电阻率曲线和真实电阻率曲线基本重合, 说明该网络能够准确获得各向异性地层中的电阻率信号; 且随着地层层数的增加, 反演和真实电阻率曲线的吻合程度没有明显下降, 说明该网络对于复杂地层有一定的适用性, 可以用于地质导向和地层流体评价。

为了进一步验证随钻方位电磁波电阻率的反演准确度, 将 LSTM 网络应用于 3 000 个样本的测试集, 每个样本有 512 个采样点, 记录每一个采样点处反演的电阻率, 并与真实电阻率进行比较。计算它们之间的相对误差, 结果见表 2。

从表 2 可以看出, 无论是对垂直电阻率 (R_v) 的反演还是对水平电阻率 (R_h) 的反演, 都有很高的准

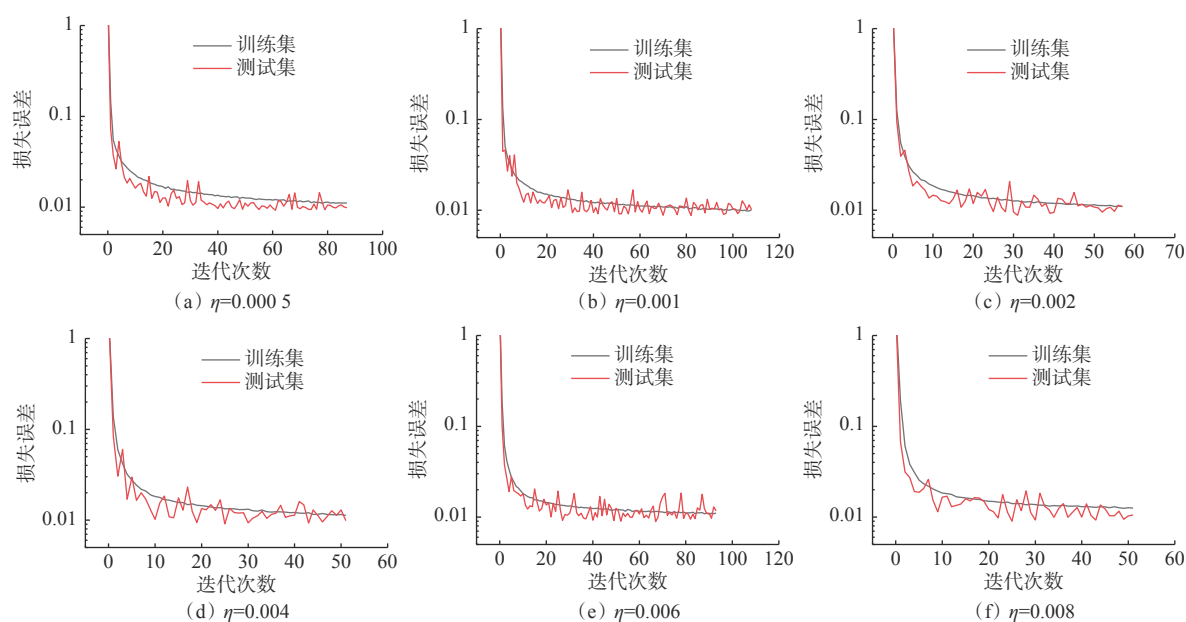


图 5 批尺寸为 32 时不同学习率下的损失函数曲线对比

Fig.5 Comparison of loss function curves under different learning rates when batch size is 32

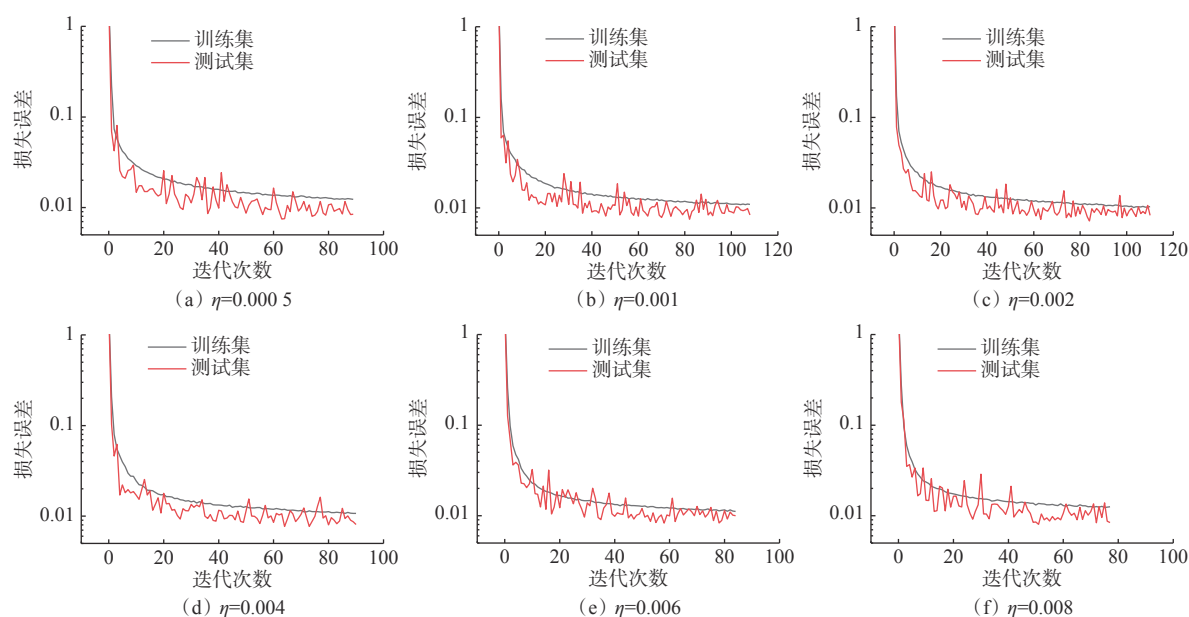


图 6 批尺寸为 64 时不同学习率下的损失函数曲线对比

Fig.6 Comparison of loss function curves under different learning rates when batch size is 64

确性, 其中 95% 以上采样点的相对误差都在 10% 以内, 相对误差大于 20% 的采样点只有 1% 左右。

为了验证该模型的鲁棒性, 在测试数据集中分别加入 5%、10% 和 20% 的相对噪声, 统计不同噪声强度下的反演误差(见图 12), 并与无噪声时的反演误差相比较。从图 12 可以看出, 噪声强度在 10% 以内时, 随着噪声强度增大, 反演准确度不断下降, 但下降的速度比较缓慢, 噪声对反演结果的影响较

小; 噪声强度增大到 20% 时, 反演准确度下降速度加快, 反演结果受噪声影响较大。这说明该网络模型在反演随钻方位电磁波测井数据时具有一定的抗干扰能力, 有望应用于含有噪声测量数据的反演。

最后记录下 LSTM 网络在验证集上反演单个样本所需的时间, 并与文献 [15] 中的监督下降法以及 Occam 反演方法进行比较, 结果见表 3。从表 3 可以看出, LSTM 网络反演速度比传统方法快了 2 个

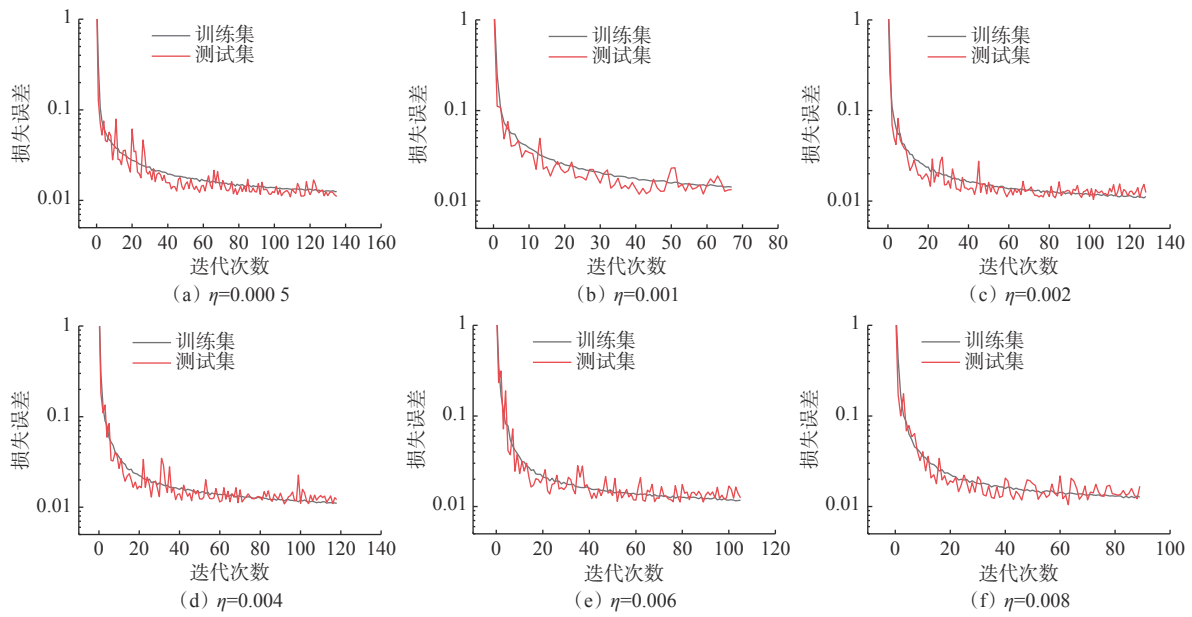


图7 批尺寸为128时不同学习率下的损失函数曲线对比

Fig.7 Comparison of loss function curves under different learning rates when batch size is 128

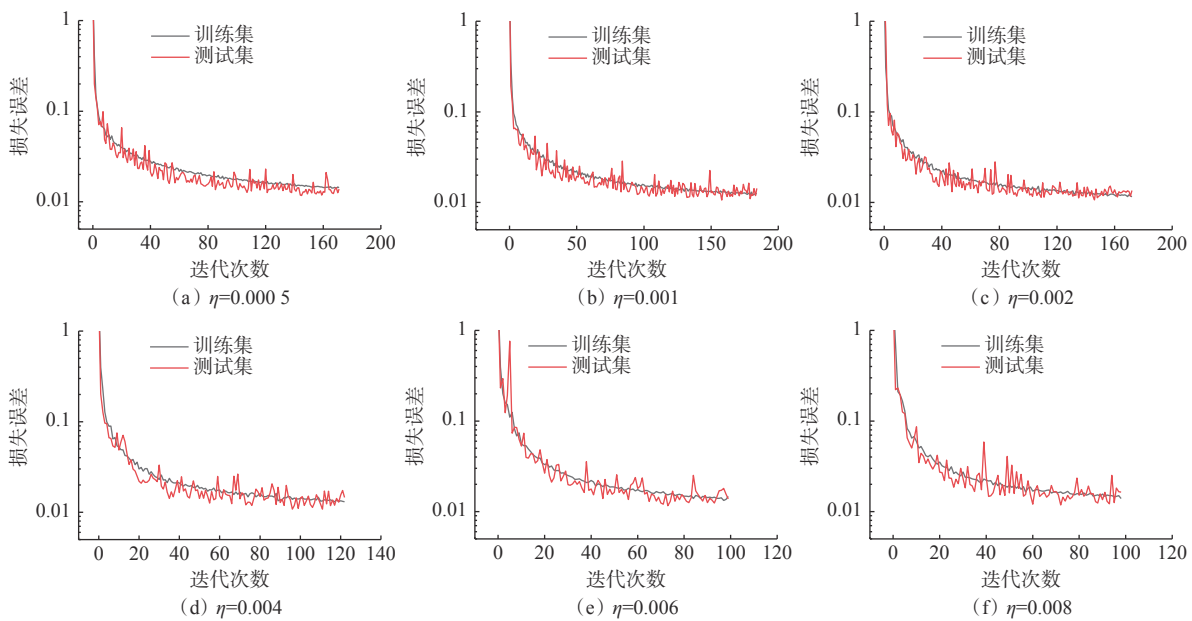


图8 批尺寸为256时不同学习率下的损失函数曲线对比

Fig.8 Comparison of loss function curves under different learning rates when batch size is 256

表1 不同批尺寸和学习率的损失误差

Table 1 Loss errors for different batch sizes and learning rates

η	训练集误差				测试集误差			
	$n=32$	$n=64$	$n=128$	$n=256$	$n=32$	$n=64$	$n=128$	$n=256$
0.000 5	0.011 0	0.012 4	0.012 5	0.014 1	0.009 3	0.007 5	0.011 1	0.011 7
0.001 0	0.009 8	0.010 9	0.014 3	0.012 1	0.008 7	0.007 5	0.011 9	0.010 6
0.002 0	0.011 0	0.010 1	0.010 8	0.011 6	0.008 8	0.007 2	0.010 4	0.010 7
0.004 0	0.011 3	0.010 7	0.011 1	0.013 1	0.009 1	0.007 7	0.010 9	0.010 8
0.006 0	0.010 8	0.011 2	0.011 6	0.013 3	0.008 9	0.008 3	0.011 2	0.011 6
0.008 0	0.012 5	0.012 3	0.012 5	0.011 9	0.009 0	0.008 1	0.010 4	0.014 0




图 9 三层地层模型反演结果

Fig.9 Inversion results of three-layer formation model

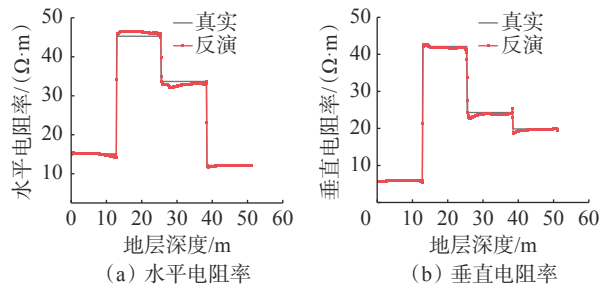


图 10 四层地层模型反演结果

Fig.10 Inversion results of four-layer formation model

数量级,且随着地层层数增加,反演时间几乎不发生变化,因此,该反演方法有望满足随钻方位电磁波测井数据井场实时反演的要求。

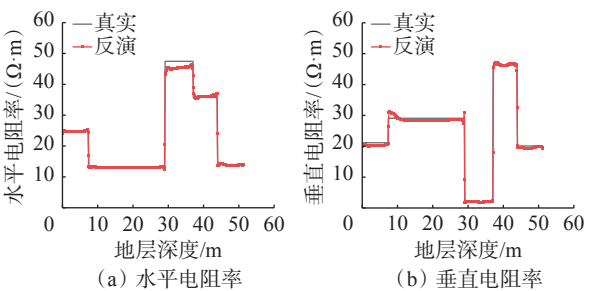


图 11 五层地层模型反演结果

Fig.11 Inversion results of five-layer formation model

表 2 电阻率反演相对误差

Table 2 Relative error of resistivity inversion

电阻率	相对误差, %	采样点数	百分比, %
R_h	<5	1 397 313	91.0
	$\geq 5 \sim <10$	112 652	7.3
	$\geq 10 \sim <20$	18 852	1.2
	≥ 20	7 183	0.5
R_v	<5	1 357 925	88.4
	$\geq 5 \sim <10$	124 935	8.1
	$\geq 10 \sim <20$	28 557	1.9
	≥ 20	24 583	1.6

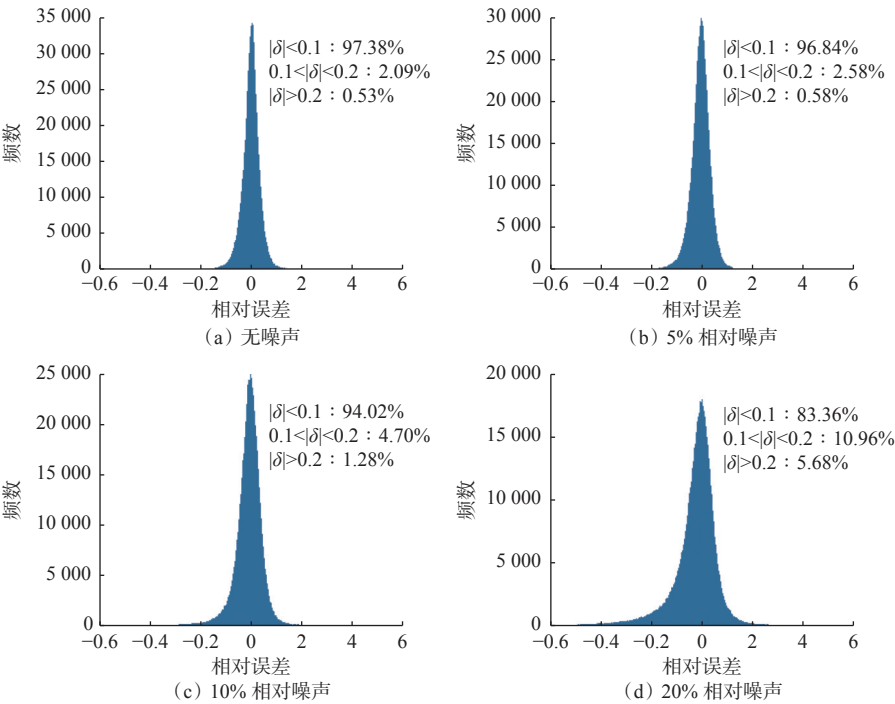


图 12 不同噪声强度下电阻率反演误差分布直方图

Fig.12 Histogram of resistivity inversion error distribution under different noise intensities

表3 不同方法反演时间比较

Table 3 Comparison of inversion time between different methods

地层模型层数	反演单个样本所需时间/s		
	LSTM网络	监督下降法	Occam法
3	0.04~0.06	0.5~4.0	>120
5	0.04~0.06	0.5~4.0	>240

4 结论与建议

1) LSTM网络能够用于反演随钻方位电磁波数据。训练后的网络反演单个样本计算速度约为0.05 s, 其计算速度较快, 能够满足数据实时反演的需要, 且无需存储大量正演模型和数据, 有利于实时应用。

2) 在神经网络架构中使用了非线性激活函数, 使神经网络具有非线性表达能力, 能够将随钻方位电磁波正演数据映射为需要反演的地层电阻率。设置不同的学习率和批尺寸等参数, 其反演准确度会有较大差别, 因此在神经网络训练时应采用遍历的方法来优选最合适的网络参数。

3) 本文提出的随钻方位电磁波测井数据反演方法使用的训练数据和验证数据均为模拟数据, 建议在今后的研究中, 增加该方法对实际测井数据反演效果的验证。

参考文献

References

- [1] NIE Xiaochun, YUAN Ning, LIU C R. Simulation of LWD tool response using a fast integral equation method[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(1): 72–81.
- [2] LEE H O, TEIXEIRA F L, SAN MARTIN L E, et al. Numerical modeling of eccentric LWD borehole sensors in dipping and fully anisotropic earth formations[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3): 727–735.
- [3] 吴柏志, 杨震, 郭同政, 等. 多尺度随钻方位电磁波测井系统响应特征研究[J]. *石油钻探技术*, 2022, 50(6): 7–13.
WU Baizhi, YANG Zhen, GUO Tongzheng, et al. Response characteristics of logging while drilling system with multi-scale azimuthal electromagnetic waves[J]. *Petroleum Drilling Techniques*, 2022, 50(6): 7–13.
- [4] 刘天淋, 岳喜洲, 李国玉, 等. 超深探测随钻电磁波测井地质信号特性研究[J]. *石油钻探技术*, 2022, 50(6): 41–48.
LIU Tianlin, YUE Xizhou, LI Guoyu, et al. Study over the geo-signal properties of ultra-deep electromagnetic wave logging while drilling[J]. *Petroleum Drilling Techniques*, 2022, 50(6): 41–48.
- [5] WANG Gongli, BARBER T, WU P, et al. Fast inversion of triaxial induction data in dipping crossbedded formations[J]. *Geophysics*, 2017, 82(2): D31–D45.
- [6] 杨震, 于其蛟, 马清明. 基于拟牛顿法的随钻方位电磁波电阻率仪器响应实时反演与现场试验[J]. *石油钻探技术*, 2020, 48(3):

120–126.

YANG Zhen, YU Qijiao, MA Qingming. Real time inversion and field test of LWD azimuthal electromagnetic waves based on quasi-newton method[J]. *Petroleum Drilling Techniques*, 2020, 48(3): 120–126.

- [7] JIN Yuchen, SHEN Qiuyang, WU Xuqing, et al. A physics-driven deep-learning network for solving nonlinear inverse problems[J]. *Petrophysics*, 2020, 61(1): 86–98.
- [8] ZHU Gaoyang, GAO Muzhi, KONG Fanmin, et al. A fast inversion of induction logging data in anisotropic formation based on deep learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(12): 2050–2054.
- [9] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436–444.
- [10] ZHU Xiaoyu, LI Jincai, ZHU Min, et al. An evaporation duct height prediction method based on deep learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(9): 1307–1311.
- [11] ARAYA-POLO M, JENNINGS J, ADLER A, et al. Deep-learning tomography[J]. *The Leading Edge*, 2018, 37(1): 58–66.
- [12] OH S, NOH K, YOON D, et al. Salt delineation from electromagnetic data using convolutional neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(4): 519–523.
- [13] COLOMBO D, TURKOGLU E, LI Weichang, et al. Physics-driven deep-learning inversion with application to transient electromagnetics[J]. *Geophysics*, 2021, 86(3): E209–E224.
- [14] JIN Yuchen, WU Xuqing, CHEN Jiefu, et al. Using a physics-driven deep neural network to solve inverse problems for LWD azimuthal resistivity measurements[R]. SPWLA-2019-III, 2019.
- [15] HU Yanyan, GUO Rui, JIN Yuchen, et al. A supervised descent learning technique for solving directional electromagnetic logging-while-drilling inverse problems[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(11): 8013–8025.
- [16] SHAHRIARI M, PARDO D, PICON A, et al. A deep learning approach to the inversion of borehole resistivity measurements[J]. *Computational Geosciences*, 2020, 24(3): 971–994.
- [17] NOH K, TORRES-VERDÍN C, PARDO D. Real-time 2.5D inversion of LWD resistivity measurements using deep learning for geosteering applications across faulted formations[R]. SPWLA-2021–0104, 2021.
- [18] 倪卫宁, 张晓彬, 万勇, 等. 随钻方位电磁波电阻率测井分段组合线圈系设计[J]. *石油钻探技术*, 2017, 45(2): 115–120.
NI Weining, ZHANG Xiaobin, WAN Yong, et al. The design of the coil system in LWD tools based on azimuthal electromagnetic-wave resistivity combined with sections[J]. *Petroleum Drilling Techniques*, 2017, 45(2): 115–120.
- [19] 杨震, 肖红兵, 李翠. 随钻方位电磁波仪器测量精度对电阻率及界面预测影响分析[J]. *石油钻探技术*, 2017, 45(4): 115–120.
YANG Zhen, XIAO Hongbing, LI Cui. Impacts of accuracy of azimuthal electromagnetic logging-while-drilling on resistivity and interface prediction[J]. *Petroleum Drilling Techniques*, 2017, 45(4): 115–120.
- [20] 杨震, 文艺, 肖红兵. 随钻方位电磁波仪器探测电阻率各向异性新方法[J]. *石油钻探技术*, 2016, 44(3): 115–120.
YANG Zhen, WEN Yi, XIAO Hongbing. A new method of detecting while drilling resistivity anisotropy with azimuthal electromagnetic wave tools[J]. *Petroleum Drilling Techniques*, 2016, 44(3): 115–120.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735–1780.