

DOI:10.19651/j.cnki.emt.2208935

参数优选残差网络下的井震联合反演方法*

郑杰¹ 文畅^{2,3} 谢凯^{1,3,4,5} 盛冠群^{4,6}

(1.长江大学电子信息学院 荆州 434023; 2.长江大学计算机科学学院 荆州 434023;
3.长江大学西部研究院 克拉玛依市 834000; 4.长江大学电工电子国家级实验教学示范中心 荆州 434023;
5.油气资源与勘探技术教育部重点实验室 荆州 434023; 6.三峡大学计算机与信息学院 宜昌 443002)

摘要: 声波测井资料在层位标定和储层反演等工作中发挥着重要作用。然而受仪器设备、地质环境等条件的限制,实际得到的声波测井曲线常有失真现象。为了向油气藏勘探提供可靠的数据支持,提高储层预测的准确性,提出一种参数优选残差网络下的井震联合反演方法,对失真的声波测井曲线予以重构。考虑到传统人工神经网络无法表达出井震间的强非线性关系,该方法以深度学习中的残差网络(ResNet)构建智能反演模型,通过网络设计、参数选择以及模型训练,找到井震间更好的映射表达。同时综合考虑测井曲线的特点与均方损失的不足,设计了一种代价敏感损失函数 Fusion,进一步提高模型整体的反演精度。在真实地震数据和测井资料上展开实验,并与全连接神经网络(FCNN)和多元回归分析(MLR)的反演结果对比分析,表明所提方法反演的声波测井曲线精度更高,相关系数达到0.912,均方根误差减小到13.399。将所提 Fusion 损失用于反演声波测井曲线,相关系数增加了2.5%,均方根误差减小了17.4%。

关键词: 井震联合反演;声波测井资料;代价敏感损失函数;残差网络;智能反演模型
中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.6099

Well-to-seismic joint inversion method based on parameter optimization residual network

Zheng Jie¹ Wen Chang^{2,3} Xie Kai^{1,3,4,5} Sheng Guanqun^{4,6}

(1. School of Electronic Information, Yangtze University, Jingzhou 434023, China;
2. School of Computer Science, Yangtze University, Jingzhou 434023, China;
3. Western Research Institute of Yangtze University, Xinjiang 834000, China; 4. National Experimental Teaching and Demonstration Center of Electrical Engineering and Electronics, Yangtze University, Jingzhou 434023, China;
5. Key Laboratory of Oil and Gas Resources and Exploration Technology, Ministry of Education, Jingzhou 434023, China;
6. School of Computer and Information, China Three Gorges University, Yichang 443002, China)

Abstract: Acoustic logging data plays an important role in horizon calibration and reservoir inversion. However, due to the limitations of equipment and geological environment, the actual acoustic logging curve is often distorted. To provide reliable data support for oil and gas exploration and improve the accuracy of reservoir prediction, a well-to-seismic joint inversion method based on parameter optimization residual network is proposed to reconstruct the distorted acoustic logging curve. Considering that the traditional artificial neural network cannot express the strong nonlinear relationship between well and seismic, this method uses the residual network (ResNet) in deep learning to build an intelligent inversion model. Through network design, parameter selection and model training, a better mapping expression between well and seismic can be found. Considering the characteristics of logging curve and the deficiency of MSE loss, a cost-sensitive loss function Fusion is designed to further improve the overall inversion accuracy of the model. Experiments are carried out on real seismic data and logging data, compared with the inversion results of Fully Connected Neural Network (FCNN) and Multiple Linear Regression (MLR), it shows that the accuracy of the acoustic logging curves inverted by the proposed method is higher, the correlation coefficient reaches 0.912, and the root mean square error is reduced to 13.399. Using the proposed Fusion loss to invert the acoustic logging curve, the correlation coefficient increases by 2.5%, and the root mean square error decreases by 17.4%.

Keywords: well-to-seismic joint inversion; acoustic logging data; cost-sensitive loss function; residual network; intelligent inversion model

0 引言

声波测井曲线反映了地层的岩性和孔隙特性,在层位

标定和储层反演等工作中发挥着重要作用。然而在实际开采过程中,受仪器设备、地质环境等条件的限制,实际获得的声波测井曲线通常伴随着失真现象,使其不能很好的反

收稿日期:2022-01-26

* 基金项目:新疆维吾尔自治区自然科学基金(2020D01A131)、湖北省自然科学基金(2021CFB119)项目资助

映地下岩性的变化规律,重新测井成本较高且对完井难以实现。因此,如何准确地对失真的数据进行人工重构已经成为了研究者们重点研究目标。

前人根据已有的测井数据重构失真的测井曲线,如物理模型反演方法^[1]与传统分析方法等,但这类传统方法计算量大,且极大地简化了地层的真实情况,因而预测效果较差。随着机器学习的不断发展,众多学者用其解决地质问题并取得了一定成效,如:多元回归分析(multiple linear regression, MLR)^[2]、支持向量机(support vector machine, SVM)^[3]以及人工神经网络(artificial neural network, ANN)^[4-5]等。由于研究者使用的人工神经网络大多都是传统的全连接神经网络(FCNN),而该网络通常层数较浅,故所得效果有限。深度学习是对机器学习的扩展和延伸,对特征提取和描述方面有了显著提高,复杂的地质非线性问题有了更好的解决方法^[6-9]。深度学习方法可以获得较好的应用效果,但是该类方法对样本数据量的要求较高,很难应用于测井少以及测井类型不同的地段。

井震联合反演是指综合考虑测井资料与地震数据在横纵向上的优势,从而得到更好的测井曲线预测精度。研究者通过岩石物理模型和经验公式^[10]等方法取得了一定的预测效果。机器学习和深度学习的不断发展,一些学者用其解决地球物理反演问题^[11-14]。卷积神经网络(convolutional neural networks, CNN)是深度学习中最常用的网络之一,以强大的特征提取能力而闻名,对地质非线性问题有更好的表达能力^[15-17]。而残差网络(residual network, ResNet)作为一种 CNN 模型,缓解了深层 CNN 的梯度消失问题^[18],张岩等^[19]和工静等^[20]分别用其解决了地震数据的噪声问题和断层检测问题并取得了较好的效果,但是目前还没有将其用于井震联合反演方面的相关文献。

因此,为了在井震联合反演上取得足够的精度,本文基于深度学习中的残差网络,提出一种新的井震联合反演方法。首先对残差网络进行模型设计,从而更好的建立地震属性与声波测井曲线间的非线性映射关系;同时综合考虑测井曲线的特点与 MSE 损失的不足,设计了一种代价敏感损失函数 Fusion,进一步提高模型整体的反演精度;最后通过实验验证所提方法的有效性。相比于 FCNN 和 MLR 方法,本文方法的反演结果更准确,且相关性更高,为重构失真曲线以更好的应用于储层预测提供技术支持。

1 原理与方法

1.1 卷积神经网络

卷积神经网络(CNN)作为深度学习方法中最常用的网络之一,以强大的特征提取能力而闻名,它独特的参数共享和局部连接等特性可以在很小的计算量下完成对格点型数据的学习^[21]。卷积、池化和全连接是构建 CNN 的基本组成部分^[22],图1为简单的 CNN 结构。




图1 CNN结构

卷积层进行特征提取,通过卷积核实现了数据的深层次分析。卷积运算十分简单,通过卷积核与相同大小的特征信息做乘法求和运算,再加上偏置项,即可得到高维信息。之后再通过激活函数增强网络的非线性表达能力。公式如下:

$$c_i = f(w * X_{i,r} + b) \tag{1}$$

其中, $X_{i,r} = [X_i, X_{i-1}, \dots, X_r]$, 表示局部特征向量; w 表示卷积核的权重矩阵; b 表示偏置; $*$ 表示卷积运算; f 表示激活函数。

卷积层之后是池化层,可以减小数据和参数量,降低网络复杂度。其运算过程与卷积大致相同,区别在于池化运算时只取运算对象的平均值或最大值等。公式如下:

$$p_j = h(c_{bj+1-b}, c_{bj+2-b}, \dots, c_{bj+a-b}) \tag{2}$$

其中, b 是步长; a 为窗口大小; h 为池化函数。

通常 CNN 的最后为全连接层,用于整合提取到的特征信息。将提取的特征信息拉平后输入全连接层,即可得到对应的输出。公式如下:

$$y_j = f(wx_j + b) \tag{3}$$

其中, x_j 是上一层第 j 个神经元的输出; w 是权重矩阵; b 是偏置; f 是激活函数。

1.2 残差网络

通常网络模型的深度能够反映出模型的非线性表达能力,但深层网络也伴随着梯度消失或梯度爆炸等问题,使得模型难以找到全局最优解。残差网络(ResNet)是 He 等^[18]提出的一种 CNN 模型,通过在原模型上增加残差模块,从而突破了制约深层 CNN 模型发展的一大限制因素--网络深度,解决了 CNN 模型随着深度增加而出现的梯度消失问题^[23-24],基本结构如图2所示。




图2 残差网络的基本结构

第 l 层单元的激活向量 $a^{(l)}$ 经过卷积和激活函数的运算可得到下一层单元的激活向量 $a^{(l+1)}$, 即

$$a^{(l+1)} = f(w^{(l+1)} * a^{(l)} + b^{(l+1)}) \quad (4)$$

第 $l+1$ 层的激活向量 $a^{(l+1)}$ 经过卷积运算后与跳跃连接的 $a^{(l)}$ 相加, 再经过激活函数运算即可得到该残差块的输出 $a^{(l-2)}$, 即

$$a^{(l+2)} = f(w^{(l+2)} * a^{(l+1)} + b^{(l+2)} + a^{(l)}) \quad (5)$$

这种残差思想也确保了输入信息不会随着卷积的增加而减弱, 有利于后续的映射进程^[25-26]。因此, 为了保证反演

模型的精度, 本文采用多层残差网络来确保学习到足够的地震数据细节特征。

1.3 多层残差网络下的井震联合反演方法

声波测井曲线与井旁地震道都能反映当前地层的波阻抗特性, 两者必然存在某种联系^[27]。因此, 本文采用已钻井层段的声波测井曲线及井旁地震道训练反演模型, 从而反演得到未钻井层的声波测井曲线。井震联合反演的算法流程如图 3 所示。

反演流程可大致分为以下 4 步:

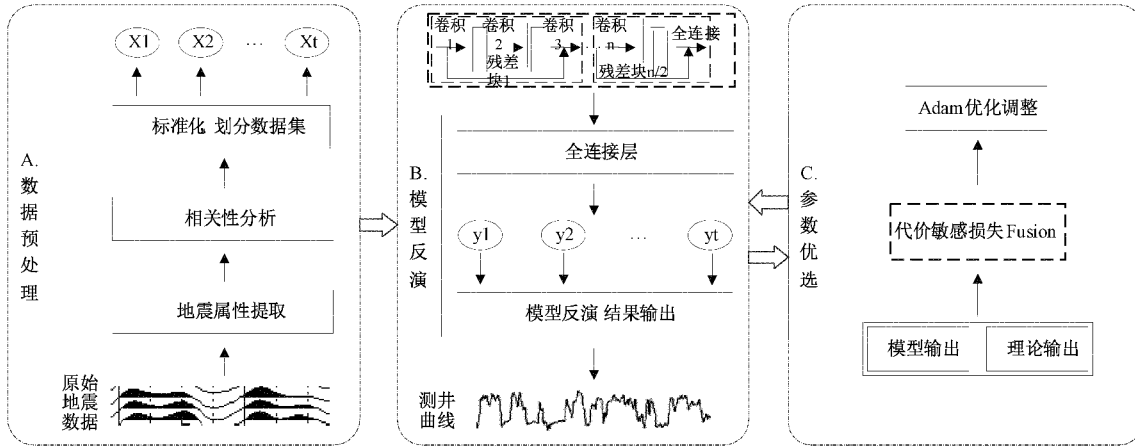


图 3 井震联合反演流程

从原始地震数据中提取出各地震属性, 并依次进行相关性分析、标准化以及划分数据集等预处理;

将划分的训练集数据输入搭建的井震联合反演模型, 并根据实验调整模型参数;

通过所提的代价敏感损失函数与优化算法对反演模型进行迭代训练, 使得模型参数不断更新, 直到反演结果符合预期要求;

利用训练好的反演模型反演得到目标测井曲线, 并通过若干指标对反演结果的好坏进行评价。

1) 地震属性提取

地震属性反映的是地震波的几何形态、运动学特征、动力学特征以及统计学特征, 对地层的岩性和物性等特征更敏感, 相比于原始地震数据, 其更适合用于建立地震数据与目标测井曲线间的映射模型。

Strata 是一种用于 2 维/3 维建模和反演的软件, 包含基本的地震处理等功能。本文采用 Strata 软件从井旁地震道中提取出共计 25 种地震属性, 其中涵盖了振幅、频率、相位和波阻抗等众多信息。

2) 相关性分析

地震属性类型众多, 但并不是每个属性都能用来反演目标测井曲线。为了减少计算量, 本文对所提取的地震属性和目标测井进行相关性分析, 从中优选出与目标测井相关性更高的地震属性组合, 用于井震关系建模。相关性的计算公式为

$$\rho(\mathbf{X}_i, \mathbf{Y}) = \frac{E[(X_i - \mu_{X_i})(Y - \mu_Y)]}{\sqrt{\sum_{j=1}^N (X_{ij} - \mu_{X_i})^2} \sqrt{\sum_{j=1}^N (Y_j - \mu_Y)^2}} \quad (6)$$

式中: \mathbf{X}_i 是第 i 个属性向量, μ_{X_i} 为该属性的均值, X_{ij} 为该属性的第 j 个值; \mathbf{Y} 是目标测井向量, μ_Y 为该测井向量的均值, Y_j 为该测井向量的第 j 个值; E 为期望。

3) 数据标准化

由于不同的地震属性具有不同的数值范围, 为了消除不同属性间数量级差别较大而引起的误差, 本文对输入的地震属性进行 z -score 标准化处理, 使不同属性间具有可比性。其表达式为

$$X'_{ij} = \frac{X_{ij} - \mu_i}{\sigma_i} \quad (7)$$

其中, X'_{ij} 是标准化后的数据; X_{ij} 为输入数据, μ_i 和 σ_i 分别为其均值和标准差。

4) 代价敏感损失函数

损失函数是影响网络性能的关键因素之一。回归问题中常用均方根误差 (mean square error, MSE) 和平均绝对误差 (mean absolute error, MAE), 两种损失的定义如下:

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2 \quad (8)$$

$$L_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - y'_i| \quad (9)$$

两者都能逐点算出每个值的损失,但 MSE 对误差进行平方造成的惩罚不平衡,会使得模型向异常点偏移。基于代价敏感思想,同时考虑到 MAE 对异常点有更好的鲁棒性,而在层位改变时声波测井曲线会有突变的情况,因此设计一种代价敏感损失函数 Fusion,在不改变模型对异常点敏感的前提下,减小其向异常点偏移的程度,以在整体上获得更好的反演效果。表达式如下

$$L_{Fusion} = \alpha L_{MSE} + (1 - \alpha)L_{MAE} \quad (10)$$

其中, α 为权重因子,用于调节两种损失所占权重。当 α 为 0.1 时模型训练取得更好的结果,且比只使用 MSE 或 MAE 时具有更快的收敛速度和更高的准确度。

5) 优化算法

优化算法能加快模型的训练速度,是网络训练中不可或缺的一个环节。目前常用的优化算法为 Adam 算法,它在解决稀疏梯度和非平稳数据等问题上都有较高优势,且实现简单、所需内存小、计算效率高。因此,采用 Adam 算法作为本文的优化算法。

2 实验与结果分析

为了验证本文方法的性能,实验流程如图 4 所示。首先简单介绍了实验设置,然后根据实验数据分别评估了模型反演方法与参数优选方法的性能。

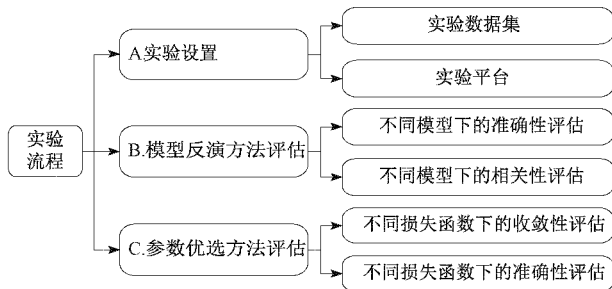


图 4 实验流程

2.1 实验设置

1) 实验平台和数据集

本文机器配置和实验平台为:Windows11 64 位操作系统, Intel Core i7-10870 CPU@2.20 GHz, 16 GB 运行内存, Nvidia GeForce RTX 2070 with Max-Q Design 显卡,深度学习框架 TensorFlow2.1、Numpy1.19.2 以及 Matplotlib3.3.2 等,编程语言为 Python3.7。实验数据来源于某油田 7 口实钻井的真实测井数据,其中都含有声波(Acoustic, AC)测井曲线,以及一个对应的三维地震数据体。

2) 模型参数设置

针对本文数据集,经过多次参数修改后最终建立的网络模型为 8 层卷积层和 2 层全连接层,共组成了 4 个残差块,具体的模型参数如表 1 所示。其中卷积核与步长分别设置为 3×1 和 1,卷积层均采用 same 填充方式。

表 1 模型参数设置

网络层	权重参数	输出规模
输入层		$7 \times 1 \times 1$
残差块 1: 卷积层 1,2	$3 \times 1 \times 16$	$7 \times 1 \times 16$
残差块 2: 卷积层 3,4	$3 \times 1 \times 32$	$7 \times 1 \times 32$
残差块 3: 卷积层 5,6	$3 \times 1 \times 64$	$7 \times 1 \times 64$
残差块 4: 卷积层 7,8	$3 \times 1 \times 128$	$7 \times 1 \times 128$
全连接层 1	128	128
输出层	1	1

2.2 数据记录与结果分析

1) 地震属性优选实验

采用 Pearson 相关系数来定量计算出各地震属性与声波测井曲线间的相关程度。目标井内的相关系数绝对值从大到小排列如图 5 所示。




图 5 地震属性与 AC 曲线的相关性

从图 5 的相关性分析结果中可以看出,前 7 种地震属性与 AC 曲线间的相关性较高,而后 18 种地震属性与 AC 曲线间的相关性低于 0.1。故本文选择图 5 中的前 7 种地震属性来反演 AC 曲线。

2) 井震联合反演实验

为了测试本文设计的 ResNet 模型在井震联合反演上的性能,假定 A1 井中的 AC 曲线部分失真,通过将相邻 6 口井(A2, A3, ..., A7)中优选出的地震属性作为输入,对应的 AC 曲线作为输出,让该 ResNet 模型自动建立起两者间的映射关系。将 A1 井中优选出的地震属性输入训练好的模型中,即可反演得到失真的 AC 曲线。不同模型下的反演结果如图 6 所示。分别计算了 3 种模型下的均方根误差和相关系数如表 2 所示。

如图 6 所示,从左到右依次为基于 ResNet、FCNN 以及 MLR 模型反演的声波测井曲线(点划线)与真实声波测井曲线(实线)。图中可以看出,三种方法在反演声波曲线上都取得了较好的效果,虽然在数值上有一定的误差,但是整体上都与真实曲线有相似的变化趋势,且在无分层情况时的反演效果更好。对图中虚框内 3 361~3 375 m、3 400~3 422 m、3 456~3 478 m、3 520~3 524 m 和 3 584~3 596 m 等层段对比分析,不难看出本文方法在分层时的反演效果更好。




图 6 不同模型下的 AC 曲线反演结果

表 2 不同模型的评价比较

反演模型	均方根误差	相关系数
MLR	32.282	0.573
FCNN	19.051	0.826
本文模型	13.399	0.912

由表 2 的评价结果可以看出,本文方法反演的声波测井曲线与真实声波测井曲线之间的相关系数要高于其它两种方法,说明本文方法反演的声波测井曲线与真实曲线

高度相关;而本文方法的均方根误差也更小,说明本文方法具有较高的反演精度。

3) 代价敏感损失函数下的反演实验

为了测试本文所提代价敏感损失函数的性能,分别将常用的平均绝对误差 MAE 和均方误差 MSE 及所提 Fusion 损失作为损失函数,并在前面表现更优的 ResNet 模型上进行了反演实验。各损失函数在训练过程中的变化趋势如图 7 所示,不同损失下的反演结果如图 8 所示。各损失函数下的均方根误差和相关系数如表 3 所示。




图 7 损失函数的变化趋势

图 7 为各损失函数在模型训练过程中的变化趋势(其中,上侧曲线为验证损失,下侧曲线为训练损失)。从图中可以看出,当所提损失训练到第 260 个 epoch 时,其变化基本趋于平缓,说明模型此时已收敛。

如图 8 所示,从左到右依次为 ResNet 模型在 Fusion、MSE 和 MAE 分别作为损失函数时反演的声波测井曲线(点划线)与真实声波测井曲线(实线)。图中不难看出,3 种损失函数下反演的声波测井曲线都取得了较好的效果,




图8 不同损失下的AC曲线反演结果

表3 不同损失函数下的评价比较

损失函数	迭代次数	均方根误差	相关系数
MAE	480	16.259	0.871
MSE	300	13.399	0.912
本文方法	260	11.067	0.935

整体上都与原曲线保持相似的趋势。对图中虚框内3361~3375 m、3400~3404 m、3411~3422 m、3438~3442 m、3520~3524 m和3592~3593 m等层段对比分析,不难看出在所提Fusion损失下对分层部分的反演效果要优于其它两种损失。同时,对比3种损失函数下的反演曲线与真实曲线在平常点上的表现,如3340~3355 m、3450~3500 m等部分,可以看出在所提Fusion损失下的拟合效果更好,整体上获得了更为精确的反演结果。

由表3的对比结果可以看出,相较于常用的两种回归损失,本文所提Fusion损失能够更快的到达收敛点,且在均方根误差和相关系数上的表现更好,说明所提Fusion损失在反演声波测井曲线上的效果更好。

3 结论

本文将深度学习中的残差网络引入到井震联合反演中,提出了一种新的井震联合反演方法,并验证了该方法

的可行性。所做工作如下:

结合本文数据集对残差网络进行设计,更好的建立起井震间的强非线性关系,并用其反演目标段的声波测井曲线。相较于传统方法,本文方法的反演精度更高,且在分层部分有更好的反演效果。

综合考虑测井曲线的特点和MSE损失的不足,设计了一种代价敏感损失函数Fusion。相较于常用的两种回归损失,在所提Fusion损失下的反演性能更好,且在整体上获得了更为精确的反演效果。

CNN作为深度学习中的一种代表网络,比传统的人工神经网络更适用于井震联合反演。本文提出的参数优选残差网络下的井震联合反演方法不仅成本低且精度高,还可用于反演其他测井曲线,且对于整个工区都有一定的应用效果,有助于更好地建立地层模型,尤其是对于未测井的地段也达到了降本增效的作用。然而,尽管本文方法在井震联合反演上取得了一定效果,但反演曲线同真实曲线之间还存在一定偏差。这是因为本文仅从井震间的非线性关系上着手,而未考虑数据自身的时序性,且仅采用了CNN模型。因此,在后续研究中考虑将数据的时序性特征融入模型中,并构建混合模型以进一步提高反演效果。

参考文献

[1] NASR M, RAYMOND J, MALO M, et al.

- Geothermal potential of the St. Lawrence Lowlands sedimentary basin from well log analysis [J]. *Geothermics*, 2018, 75: 68-80.
- [2] 李雄炎,秦瑞宝,刘小梅,等.多方法对比分析及随钻声波测井曲线的预测[J].*地球物理学进展*,2016,31(3):1131-1138.
- [3] 苏赋,马磊,罗仁泽,等.基于改进多分类孪生支持向量机的测井岩性识别方法研究与应用[J].*地球物理学进展*,2020,35(1):174-180.
- [4] 赵白民.一种自然电位测井曲线生成方法及其在存储式测井中的应用[J].*电子测量技术*,2020,43(7):103-107.
- [5] CHEN L, LIN W B, CHEN P, et al. Porosity prediction from well logs using back propagation neural network optimized by genetic algorithm in one heterogeneous oil reservoirs of ordos basin, China[J]. *Journal of Earth Science*, 2021, 32(4): 828-838.
- [6] 张宝录,罗丹婷,胡鹏,等.一种基于深度神经网络模型的测井曲线生成方法[J].*电子测量技术*,2020,43(11):107-111.
- [7] 张东晓,陈云天,孟晋.基于循环神经网络的测井曲线生成方法[J].*石油勘探与开发*,2018,45(4):598-607.
- [8] 王俊,曹俊兴,尤加春.基于 GRU 神经网络的测井曲线重构[J].*石油地球物理勘探*,2020,55(3):510-520,468.
- [9] ZENG L L, REN W J, SHAN L Q. Attention-based bidirectional gated recurrent unit neural networks for well logs prediction and lithology identification [J]. *Neurocomputing*, 2020, 414: 153-171.
- [10] 张元中,周开金,赵建斌,等.砂泥岩地层横波测井曲线预测方法研究[J].*石油物探*,2012,51(5):508-514,423,424.
- [11] 余为维,冯磊,杜艳艳,等.测井约束与神经网络联合反演储层预测技术[J].*地球物理学进展*,2016,31(5):2232-2238.
- [12] LI S C, LIU B, REN Y X, et al. Deep-Learning Inversion of Seismic Data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(3): 2135-2149.
- [13] 王一鸣,宋先海,张学强.应用人工神经网络算法的地震面波非线性反演[J].*石油地球物理勘探*,2021,56(5):979-991.
- [14] WANG Y Q, WANG Q, LU W K, et al. Seismic impedance inversion based on cycle-consistent generative adversarial network[J]. *Petroleum Science*, 2022, 19(1): 147-161.
- [15] 张逸伦,喻志超,胡天跃,等.基于 U-Net 的井中多道联合微地震震相识别和初至拾取方法[J].*地球物理学报*,2021,64(6):2073-2085.
- [16] WANG Y Q, GE Q, LU W K, et al. Well-logging constrained seismic inversion based on closed-loop convolutional neural network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(8): 5564-5574.
- [17] 安振芳,张进,张建中,等.小样本卷积神经网络井震映射反演[J].*西安石油大学学报(自然科学版)*,2020,35(4):30-38.
- [18] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770-778.
- [19] 张岩,李新月,王斌,等.基于联合深度学习的地震数据随机噪声压制[J].*石油地球物理勘探*,2021,56(1):9-25,4,56.
- [20] 王静,张军华,芦凤明,等.构建三维深度监督网络的断层检测方法[J].*石油地球物理勘探*,2021,56(5):947-957,923.
- [21] MI J X, FENG J, HUANG K Y. Designing efficient convolutional neural network structure: A survey[J]. *Neurocomputing*, 2022, 489: 139-156.
- [22] 李艺强,叶俊勇,罗晋.基于级联卷积网络的紧固件异常检测[J].*电子测量与仪器学报*,2019,33(5):171-179.
- [23] 付荣,张新宇,王子辰,等.基于 V-ResNet 的电阻抗层析成像方法[J].*仪器仪表学报*,2021,42(9):279-287.
- [24] 张利军,段礼祥,万夫,等.往复压缩机故障的残差网络诊断方法[J].*电子测量与仪器学报*,2021,35(5):38-46.
- [25] 隗永刚,杨千里,王婷婷,等.基于深度学习残差网络模型的地震和爆破识别[J].*地震学报*,2019,41(5):646-657,680.
- [26] 韩冉,曾广森,王荣杰.基于残差块网络的图像去雨算法[J].*仪器仪表学报*,2021,41(8):175-182.
- [27] 王明路.声波测井速度与地震速度的关系研究[D].北京:中国石油大学(北京),2017.

作者简介

郑杰,硕士研究生,主要研究方向为深度学习、测井曲线重构、井震联合反演。

E-mail: 1141524770@qq.com

文畅(通信作者),硕士,讲师,主要研究方向为人工智能、地震信号处理等。

E-mail: wenchang2016paper@163.com

谢凯,博士,教授,主要研究方向为人工智能、图像处理、信号处理、数据挖掘与三维建模等。

E-mail: pami2009@163.com

盛冠群,博士,讲师,主要研究方向为人工智能、信号处理等。

E-mail: 88407581@qq.com