

基于层序统计结构和空间地质结构的深度学习高分辨率处理方法

高洋¹, 孙郅松², 王文闯², 李国发^{1*}

1 中国石油大学(北京)油气资源与探测国家重点实验室, 北京 102249

2 东方地球物理勘探有限责任公司物探技术研究中心, 涿州 072751

* 通信作者, lgfseismic@126.com

收稿日期: 2023-03-30

中国石油天然气集团有限公司科学研究与技术开发项目(2021ZG03、2021DJ1206) 联合资助

摘要 高分辨率地震数据在地震数据处理中扮演着关键角色, 特别是当地震勘探目标变得越来越复杂时, 它可以提供更准确的储层识别和描绘。近年来, 随着深度学习技术的快速发展, 它越来越多地被引入到高分辨率地震数据处理中。基于大量标记数据, 建立了低分辨率地震数据和高分辨率地震数据之间的复杂非线性关系。然而, 深度学习在高分辨率数据处理中的精度与稳定性高度依赖于训练集的准确性与多样性。深度学习技术在实际应用中的主要挑战之一是稀疏的井数据, 这经常导致训练集受限。为了解决这个问题, 本文提出了一种基于深度学习的高分辨率处理方法, 通过使用大量逼真的训练集, 将井数据所表示的分层结构与地震数据所表示的空间地质结构相结合。建立训练集包括三个步骤: (1)使用井数据计算波阻抗序列, 并利用高斯匹配函数拟合波阻抗高频部分的振幅分布, 得到一个概率密度函数, 最后生成一系列符合井数据统计分布的波阻抗序列。(2)在波阻抗序列的基础上, 建立二维水平分布的波阻抗模型, 并逐步添加折叠变形、倾角变形和断层变形, 生成包含各种地质模式的二维阻抗模型。(3)使用阻抗模型计算反射系数, 然后用反射系数模型分别卷积低频和高频子波, 得到训练集。通过自动生成具有地下地质信息的大量训练集, 训练的网络可以估计稳定而准确的高分辨率结果。深度学习的框架由两个部分组成: 提取输入数据特征的编码部分和通过提取的特征重建输出的解码部分。此外, 残差模块被整合到框架中, 使网络更有效地从训练集中提取特征进而提高网络性能, 从而实现计算精度和效率之间更好的平衡。通过模型数据和实际数据的测试, 本文提出的方法相比于传统深度学习方法对噪声具有更好的鲁棒性, 可以产生更精确且横向连续性更好的高分辨率结果。

关键词 深度学习; 高分辨率处理; 残差模块; 薄层恢复; 人工智能

A deep learning method for high-resolution seismic processing based on a layered statistical structure and a spatial geological structure

GAO Yang¹, SUN Yunsong², WANG Wenchuang², LI Guofa¹

1 State Key Laboratory of Petroleum Resources and Prospecting, China University of Petroleum-Beijing, Beijing 102249, China

2 Research & Development Center of BGP, CNPC, Zhuozhou 072751, China

引用格式: 高洋, 孙郅松, 王文闯, 李国发. 基于层序统计结构和空间地质结构的深度学习高分辨率处理方法. 石油科学通报, 2023, 03: 290-302
GAO Yang, SUN Yunsong, WANG Wenchuang, LI Guofa. A deep learning method for high-resolution seismic processing based on a layered statistical structure and a spatial geological structure. Petroleum Science Bulletin, 2023, 03: 290-302. doi: 10.3969/j.issn.2096-1693.2023.03.021

Abstract High-resolution seismic data processing plays a crucial role in the depiction and characterization of reservoir structures, especially when exploration targets become increasingly complex. In recent years, with the rapid development of deep learning technology, it has been increasingly introduced into high-resolution seismic data processing. Based on a large amount of labeled data, complex nonlinear relationships between low-resolution seismic data and high-resolution seismic data are established. However, the accuracy and stability of the results generated by deep learning in high-resolution data processing highly depend on the accuracy and diversity of training sets. One of the main challenges of practical application of deep learning-based high-resolution reconstruction in production is the sparse well data, which often leads to limited training sets. To address this issue, this paper proposes a deep learning-based high-resolution processing method that integrates the layered structure represented by well data and the spatial geological structure represented by seismic data in the working area by using numerous and realistic training sets. The establishment of the training sets includes three steps. (1) Calculate the impedance sequence using well data, fit the amplitude distribution of the high-frequency part of the impedance using a Gaussian matching function to obtain a probability density function (PDF), and generate a series of impedance sequences that conform to the statistical distribution of the well data. (2) On the basis of the impedance sequences, establish a two-dimensional horizontal impedance model, and gradually add folding deformation, dip deformation, and fault deformation to generate a two-dimensional impedance model containing various geological patterns. (3) Calculate the reflection coefficient using the impedance model, and then convolute the low-frequency and high-frequency wavelets with the reflection coefficient model to obtain the training sets. By automatically generating a large number of training sets with underground geological knowledge, the trained network can estimate stable and accurate high-resolution results. The framework of deep learning is composed of two parts: an encoding part that extracts features from the input data and a decoding part that reconstructs the output from the extracted features. In addition, residual modules are incorporated into the framework to enhance performance by enabling the network to learn more effectively from the training sets, resulting in a better balance between computational accuracy and efficiency. Synthetic data and field data tests show that the proposed method has better robustness to noise and can yield more accurate and laterally more consistent high-resolution results compared to traditional deep learning methods.

Keywords deep learning; high-resolution processing; residual module; thin layer reconstruction; artificial intelligence

doi: 10.3969/j.issn.2096-1693.2023.03.021

0 引言

在石油勘探领域,地震数据的分辨率常受大地滤波作用和地下介质非完全弹性的影响,从而限制了对储层的准确圈定和表征。为了克服这一挑战,研究人员提出了多种方法来提高地震数据的分辨率^[1]。Q理论被广泛应用于描述地下介质的固有衰减,衍生了多种地震衰减补偿方法,可用于提高地震记录的分辨率^[2-4]。Braga等^[5]采用二范数约束的小波域反Q滤波方法,以恢复稳定带宽的地震记录。Wang等^[6]提出了一种模态相关的自适应稳定算子,该算子能够处理黏弹性补偿引起的数值不稳定性。反褶积方法在地震资料高分辨率处理中得到了广泛的应用,旨在消除地震数据中地震子波的低通滤波效应,从而拓宽频带,提高垂直分辨率。经典的最小二乘反褶积方法对噪声比较敏感,其高分辨率结果的频带被限制在原始数据的有效频带范围之内,进而避免产生高频噪声^[7-10]。为了有效拉宽地震频带,稀疏脉冲反褶积技术得到了很好的发展。该方法的基本思想是对重构的反射系数序列施加稀疏正则化约束,进而稀疏脉冲反褶积可以在不放大噪声的情况下恢复高频分量。Sacchi^[11]利用

Cauchy约束和Huber约束项来恢复全频带反射系数序列。Alemie等^[12]采用三元柯西正则化项同时反演稀疏P波反射系数、S波反射系数和密度反射系数。Zhang等^[13]发展了将稀疏反射系数视为偶数和奇数反射系数对的叠加的稀疏脉冲反褶积方法。Du等^[14]利用地震数据结构约束项进行多道反射系数反演,该方法可以使高分辨结果具有稀疏特征,并增强其空间连续性。当地震记录被强反射支配时,反射系数被限制为稀疏是一个理想的假设。然而,地下的薄层反射往往具有微弱的振幅。当强反射周围存在薄层弱反射时,稀疏反褶积只能重建强反射系数,导致薄层识别困难。

近年来,深度学习在地震数据解释和处理中的应用引起了广泛的关注,如地震数据断层解释^[15-16],速度模型建立^[17-18],噪声衰减^[19-21]等。深度学习通过构建由多个神经网络组成的计算模型,提取多尺度特征,形成复杂的非线性关系,而不需要像传统方法一样进行假设。然而,限制深度学习应用的一个关键因素是是否有足够的高质量数据集来训练神经网络。深度学习应用于地震数据高分辨率恢复时,训练标签通常来自于测井数据。由于钻井的成本高,用于训练网络的标记数据通常是有限的。为了在训练集有限的情况下

提高神经网络的性能, 研究人员开发了许多策略^[22-23]。Yang等^[24]利用双向长短期记忆神经网络提取测井数据中复杂的时间序列模式, 最大程度压缩地震子波, 提高地震数据的分辨率。Gao等^[25]利用循环生成对抗网络同时优化低频到高频映射以及其逆过程, 并将未标记的数据(即地震数据)添加到训练集中, 以提高网络在地震数据上的预测精度。Wang等^[26]在训练集有限的情况下, 通过将卷积模型与双边滤波结合在神经网络中, 进一步优化深度学习的网络参数, 提高了预测结果的准确性。Das等^[27]使用合成训练数据集先对卷积神经网络进行预训练, 然后将实际工区中的测井数据加入到标签中, 通过迁移学习策略对预训练的网络进行微调, 以缓解训练数据不足的问题。

本文使用深度学习框架开发了一种高分辨率地震资料处理方法。其核心思想是利用神经网络构建从低分辨率地震数据到高分辨率地震数据的非线性映射。为了确保在实际应用中神经网络具有高精度和稳定性, 我们使用一个工作流程自动生成大量具有实际工区数据特征的训练集: (1)使用测井数据计算波阻抗序列, 并利用高斯匹配函数拟合其高频部分的振幅分布得到概率密度函数(PDF), 利用PDF生成一系列符合该地区统计分布的随机波阻抗序列; (2)在随机波阻抗序列的基础上添加真实的地质结构, 建立二维水平波阻抗模型, 并逐步添加褶皱变形、倾斜变形和断层变形, 生成包含各种地层模式的二维波阻抗模型; (3)利用波阻抗模型计算反射系数, 将低频子波和高频子波分别与反射系数模型卷积得到训练集。此外, 该方法采用的深度学习框架基于U-net模型, 在原编码器-解码器

器结构的基础上添加残差学习结构, 以保证计算成本可承受, 并准确预测结果。合成数据与实际数据结果表明, 与传统深度学习方法相比, 本文提出的方法具有更好的鲁棒性, 能更有效拓宽地震频带, 并且恢复了横向一致性更好的薄层结构。

1 方法与数据

1.1 网络框架

本文所使用的网络结构如图1所示, 它由两部分组成: U-net网络和残差学习结构。在许多以深度学习为代表的人工智能处理技术中^[28-30], U-net网络由于其出色的性能和GPU内存的高效使用, 被广泛采用。U-net是一种编码器-解码器网络, 包括四个下采样模块和相应的上采样模块。地震数据在输入网络后, 提取的特征首先在编码器中向下采样, 然后通过跳跃连接层与解码器中向上采样的特征重新组合。通常在U-net网络的编码阶段提取输入数据的局部特征, 而在解码阶段中, 当接受域越来越大时, 获得相对高级和全局的数据特征。因此, 编码器和解码器聚合了多尺度结构特征。此外, 由于结构信息可能在网络加深过程中逐渐丢失, 相较于高层次特征, 编码阶段计算的低层次特征与输入数据有更好的结构一致性。跳过连接层的使用有助于增强整个网络的底层特征, 并产生与输入结构一致的模型。

每个下采样块包括两个核为 3×3 的卷积层, 其中每一个卷积层后面是一个批量归一化层和一个激活函数(ReLU), 和一个核为 2×2 , 步长为2的最大池化层。

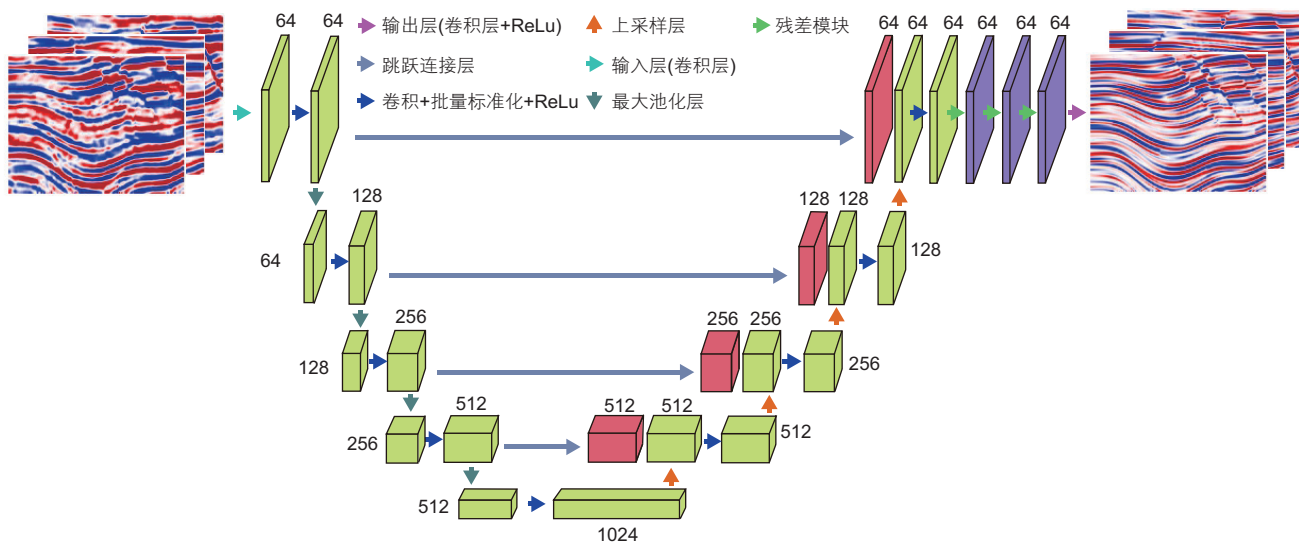


图1 网络结构示意图

Fig. 1 Network structure diagram

通过4个下采样块后,特征谱的数量分别为64、128、256和512。相应的,解码器由4个上采样模块组成。上采样模块与下采样模块结构类似,除了将最大池化层替换为上采样层。我们将上采样层的输出与来自同一级别下采样块的特征映射连接起来。在此之后,输出的特征谱作为输入被馈送到下一级的上采样模块中。

大多数人认为神经网络越深,表达能力越强。然而简单地堆叠神经网络形成更深的网络架构很难获得更好的改进。例如,过度使用最大池化层会使特征图尺寸极小,数据的结构信息无法保存,从而阻碍网络的最终的预测结果。此外,更深层次的神经网络通常收敛更困难。基于此,人们提出残差学习模块。残差学习通过学习输入和目标的差,可以有效地在整个网络中反向传播梯度信息,提高网络的收敛速度。我们在网络架构的输出端增加3个残差模块,其中每个残差模块包含两个卷积层,每个卷积层后面是一个批处理归一层和一个ReLU激活。

本文需要解决的是对高分辨率数据的预测,属于回归问题,采用的损失函数为 ℓ_1 范数残差损失:

$$L_{\ell_1} = \frac{1}{N} \sum_{i=1}^N |x_i - y_i| \quad (1)$$

其中, N 为训练样本或标签的数量, x_i 和 y_i 分别为第 i 个低分辨率地震数据、第 i 个高分辨率数据。

1.2 准备数据集

深度学习算法通过对训练集的学习和建模,建立复杂的映射关系。在基于深度学习的高分辨率处理中,如何获得大量包含目标区域地下特征的训练集是获得精确解的关键。在本研究中,训练集设计考虑到测井数据表示的层序统计结构与地震数据表示的空间地质结构。

对于测井数据表示的层序统计结构,我们的基本思路是提取测井数据的统计分布并随机生成大量波阻抗序列。模拟符合真实地下分布波阻抗序列的方法可以概述为以下三步:

1) 获取工区内可用的井数据,利用其计算波阻抗 AI ,并利用滤波得到波阻抗的低频部分 AI_L 与高频部分 AI_H 。

2) 对测井数据的高频部分 AI_H 进行统计分析,并用高斯匹配函数提取 AI_H 的概率密度函数,其中高斯匹配函数定义为:

$$f(a_k, b_k, c_k) = \sum_{k=1}^K a_k e^{-(x-b_k/c_k)^2} \quad (2)$$

其中, K 为高斯匹配函数的个数, a_k 、 b_k 和 c_k 分别为第 k

个高斯函数的峰值、峰值位置和半宽距离。通过更改这些参数,高斯匹配函数可以拟合任一分布。

3) 利用概率密度函数生成一系列高频部分,并将其与低频部分 AI_L 相加,从而得到真实的伪测井曲线。

以实际数据为例子,如图2所示,我们首先将井数据得到的阻抗分解为低频部分与高频部分,然后将高频部分的振幅值从小到大划分为许多段,通过计算每段内的数据点数,统计其概率分布。如图3a所示,我们利用直方图分析测井数据中高频部分的概率分布,并使用高斯匹配函数进行统计拟合,其中拟合参数设置为 $K=2$, $[a_1, b_1, c_1, a_2, b_2, c_2] = [12.3, 0.00156, 0.02167, 5.452, 0.0001, 0.05]$ 。最后,我们利用拟合得到的概率密度函数生成随机序列,并将其与原始井中的低频部分相加进而得到波阻抗序列,其长度与原始测井数据相同。如图3b中所示,基于测井分布的随机波阻抗序列(第二列至第五列)与由测井数据计算得到的波阻抗序列(第一列)的特征较为相似。

对于地震数据表示的空间地质结构,我们的基本思想是将各种空间中特定的结构和地层模式加入到训




图2 用于提取统计分布的测井数据

Fig. 2 Log data used to extract distributed statistics

练集中，具体做法可分为以下两步：

1) 从生成的一维序列中随机选取波阻抗，通过插值得到初始水平分布的二维波阻抗模型，如图 4a 所示。

2) 依次在水平模型的基础上添加褶皱、倾斜和断层构造，进一步使二维模型复杂化。

如图 4b 所示，生成二维波阻抗模型不仅在纵向上

包含了测井数据的薄层结构特征，而且包含了地震数据中的空间地质结构模式。接下来，我们利用卷积模型求得二维模型的地震记录 d ，其形式如下：

$$d = Wr + n, \tag{3}$$

其中， W 为地震子波， n 为随机噪声， $r = (AI_{q+1} - AI_q) / (AI_{q+1} + AI_q)$ 为反射系数，其中 q 为采样点。

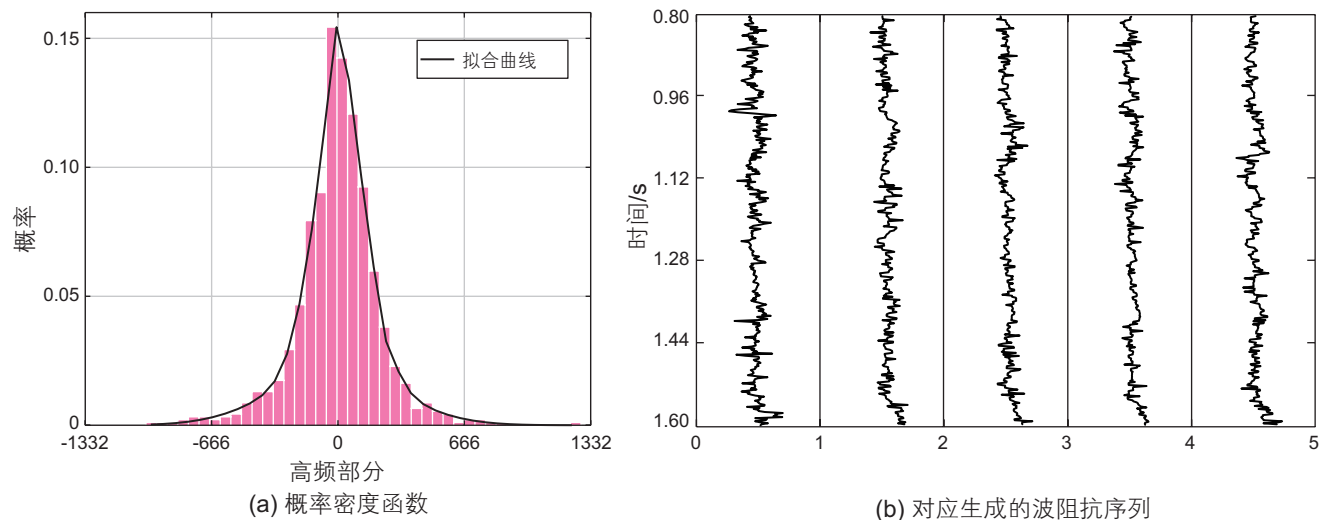


图 3 提取的概率密度函数以及其对应生成的波阻抗序列

Fig. 3 The extracted probability density function and its corresponding generated wave impedance sequence

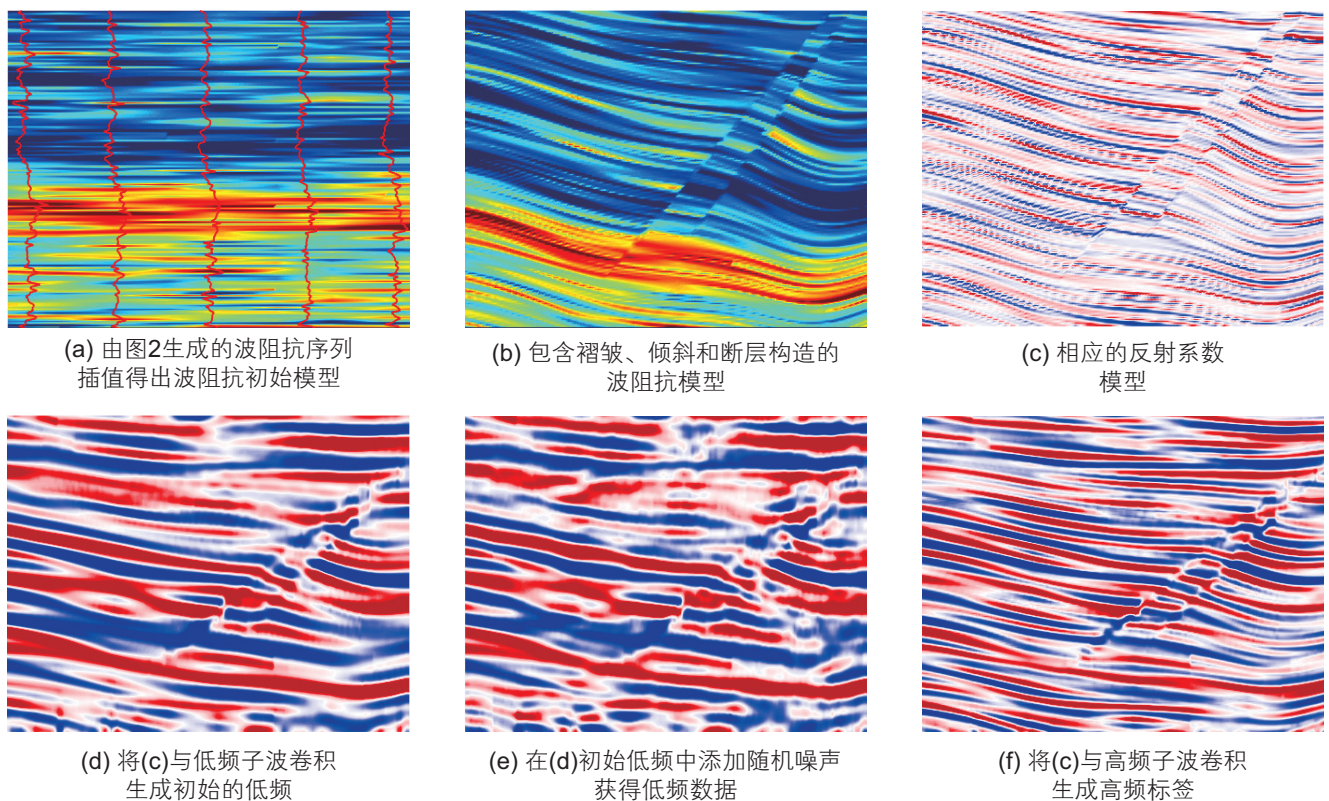


图 4 从波阻抗序列生成相关的低频数据与高频标签

Fig. 4 Generate associated low frequency data and high frequency labels from wave impedance sequences

如图 4d-f所示, 我们通过给定特定频带的低频子波以及高频子波对, 生成低分辨率与高分辨率地震数据, 其中在低分辨率地震数据中加入随机噪声, 以获得更真实的训练集。

最后, 通过该工作流程, 我们总共生成了 300 组低频数据, 及其对应的高频标签, 每个模型的大小为 128×138 。图 5 展示了生成的部分训练集, 其中第一行和第二行分别对应低频地震数据和高频标签。

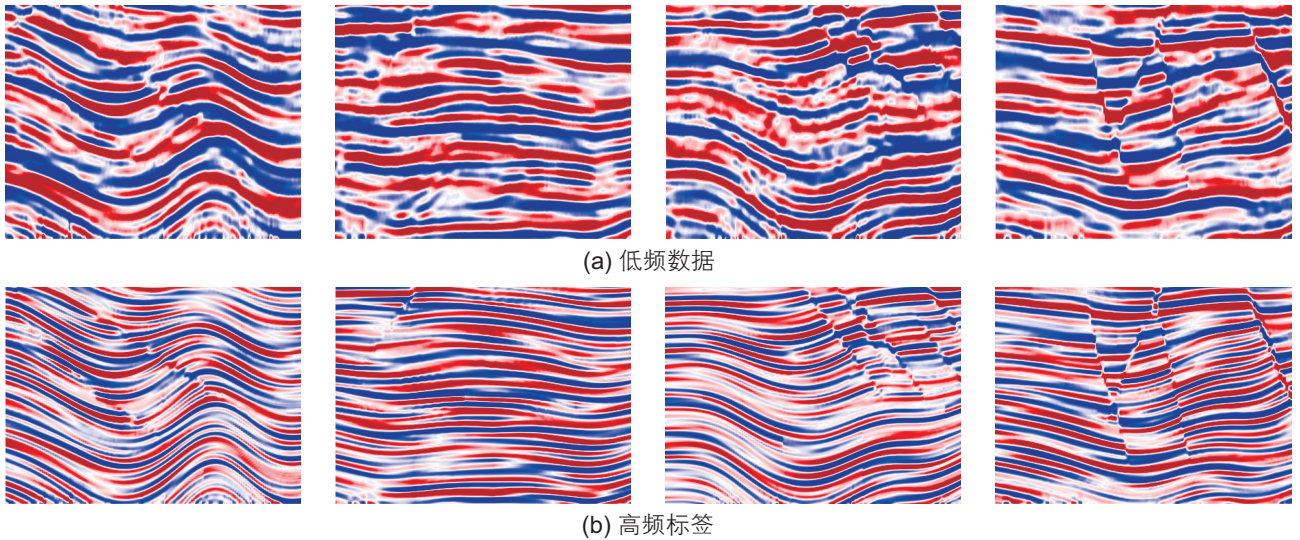


图 5 最终生成的部分训练集
Fig. 5 The resulting partial training set

2 数值模型测试

为了更好地验证所提出的高分辨率方法的可行性, 我们建立了一个复杂的模型, 如图 6 所示。从整体上看, 其振幅从左到右表现出强烈的变化。其次, 存在一些弱振幅波形, 特别是在 0.5 ms 左右的深部。最后, 强断裂引起了地震构造明显的错动与不连续。在训练




图 6 合成地震记录
Fig. 6 Synthetic seismogram

网络时, 为了减少梯度下降优化过程中的波动, 将批尺寸(batch size)设置为 16, 并采用学习率为 0.001 的自适应矩估计优化器 Adam 进行梯度下降。我们随机选择 3 条地震记录作为井旁地震道, 其真实波阻抗数据已知, 用于生成训练集。我们采用了 3 种标签生成策略, 分别为: (1)传统深度学习, (2)深度学习(薄层结构), 以及(3)深度学习(基于层序统计结构和空间结构)。第一种策略中, 我们利用 3 口井的数据计算反射系数, 并采用峰值频率为 20 Hz 和 40 Hz 的雷克子波与反射系数卷积生成对应的低频数据和高频标签; 在第二种策略中, 我们计算了 3 口井中波阻抗的统计分布, 利用该分布生成一系列伪测井曲线, 并利用雷克子波与反射系数卷积生成相应的列低频数据和高频标签; 在第三种策略中, 在第二种策略的基础上, 我们随机选取伪波阻抗曲线, 通过插值获得水平分布的波阻抗模型, 并添加褶皱、倾斜和断层构造, 最终在二维波阻抗模型上计算反射系数, 并利用雷克子波生成相应的训练集。在这 3 种策略中, 策略 1 利用现有井数据生成标签; 策略 2 利用井中统计分布生成了大量伪井数据, 增加了标签数据的多样性; 策略 3 在策略 2 的基础上, 进一步考虑了地震数据中的空间结构特征。由于策略 1 和 2 采用一维训练集, 所以相应的网络变为一维神经网络, 网络框架与策略 3 采用的二维

神经网络相同。

图 7a 和 b 分别展示了传统深度学习和深度学习(薄层结构)的结果。两种方法都能够在一定程度上恢复地下高分辨率结构。但是,在只有少量井数据的情况下,使用一维神经网络得到的高分辨率结果(图 7a)存在许多噪声特征,断层结构也较为模糊。这表明,仅依靠 3 口井数据的训练集不足以使神经网络学习到低分辨率数据与高分辨率数据之间的复杂非线性关系。相比之下,通过考虑测井数据中的统计分布并生成大量伪井,增加训练集多样性之后,神经网络(图 7b)可以产生更准确的高分辨率结果。然而,我们仍然可以在结果中观察到一些噪声特征和不连续性。图 7c 中的深度学习(薄层结构和空间结构)方法能够更好地恢复空间中的薄层结构,这些薄层不仅在纵向上较薄,而且在横向上延续得更好,表现出与真实高分辨率结果

(图 7d)更好的一致性。

频谱分析如图 8 所示,所有方法都有效地展宽了合成数据的频带,提高了分辨率,但本文方法得到的结果与真实结果频谱的匹配度更好。

为了更详细的对比不同方法产生高频成分的有效性,我们采用 30-50-90-100 Hz 带通滤波器分别对结果(图 7)进行滤波,得到图 9 所示的高频部分。通过对比可以看到,深度学习(薄层结构和空间结构)方法恢复的高频成分(图 9c)具有更清晰的薄层结构,并且断层等空间结构保存较好。

最后,为了检验不同方法对噪声的鲁棒性,我们在不同噪声水平下进行了一系列高分辨率数据恢复实验。评价指标采用均方误差,其定义为:

$$MSE = \frac{1}{m \cdot n} (X - X')^2 \quad (4)$$




图 7 合成数据的高分辨率恢复结果

Fig. 7 High-resolution recovery results of composite data




图 8 不同方法结果的振幅谱

Fig. 8 Amplitude spectra of results from different methods




图 9 合成数据高分辨率结果的高频成分

Fig. 9 Synthesize high frequency components of high resolution results from data

其中, X 和 X' 分别为真实的高分辨率数据和预测高分辨率结果, m 和 n 分别为高分辨率结果的时间采样点数和道数。实验结果如表1所示, 随着输入信噪比的升高, 三种方法输出的均方误差均有所降低。相比较传统深度学习方法, 考虑纵向薄层结构的深度学习方法获得了更小的均方误差, 这表明增加训练集的多样性后, 提高了单道深度学习性能。然而, 这不能从本质消除单道深度学习的逐道进行高分辨率的局限性, 其中地震数据中的横向结构特征被完全忽略。多道深度学习方法预测高分辨率数据时, 考虑了薄层结构以及空间结构, 在所有噪声水平下都能获得更准确的高分辨率结果, 即更小的均方误差。综上所述, 深度学习(薄层结构和空间结构)方法可以从高噪声污染的地震数据中获得准确的高分辨率结果, 显示了其对噪声良好的鲁棒性。

3 实际数据应用


本文选用来自中国西部某地区的叠后地震数据进行实验验证。图12a展示了叠后地震数据, 该数据包位于CDP 157的一口井。因为井数据有限, 我们只能采用基于策略2和策略3的深度学习方法进行高分辨数据重建。我们首先采用井数据计算波阻抗, 提取其概率密度函数用于生成波阻抗序列。随后, 在波阻抗序列的基础上, 我们添加各种构造, 生成二维波阻抗模型并计算反射系数模型。最后, 使用Hampson-Russell软件中的统计方法从原始数据中提取子波作为低频子波, 同时, 选用带宽为5-10-60-80 Hz的带通小波作为高频子波, 并与反射系数卷积生成训练集, 其中采用的子波如图10所示。最终生成如图11所示的训练集, 用于策略3。

图12b和c展示了考虑了薄层结构的深度学习方


表1 不同方法抗噪性结果比较

Table 1 Comparison of noise resistance results of different methods

信噪比/dB	均方误差		
	单道深度学习		多道深度学习
	传统(策略1)	薄层结构(策略2)	薄层结构+空间结构(策略3)
5	0.0361	0.0115	0.0043
10	0.0338	0.0093	0.0037
15	0.0317	0.0073	0.0031
20	0.0299	0.0057	0.0023



(a) 低频子波与高频子波



(b) 对应的振幅谱

图10 用于生成训练集的子波对

Fig. 10 A pair of wavelets used to generate a training set

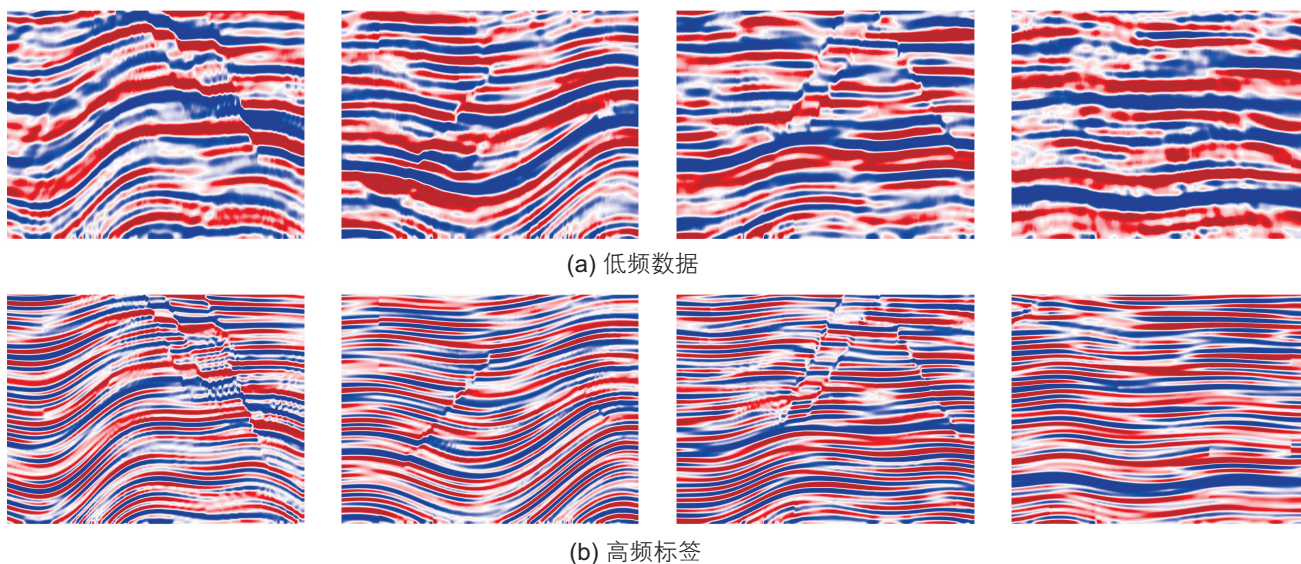


图 11 最终生成的部分训练集

Fig. 11 The resulting partial training set

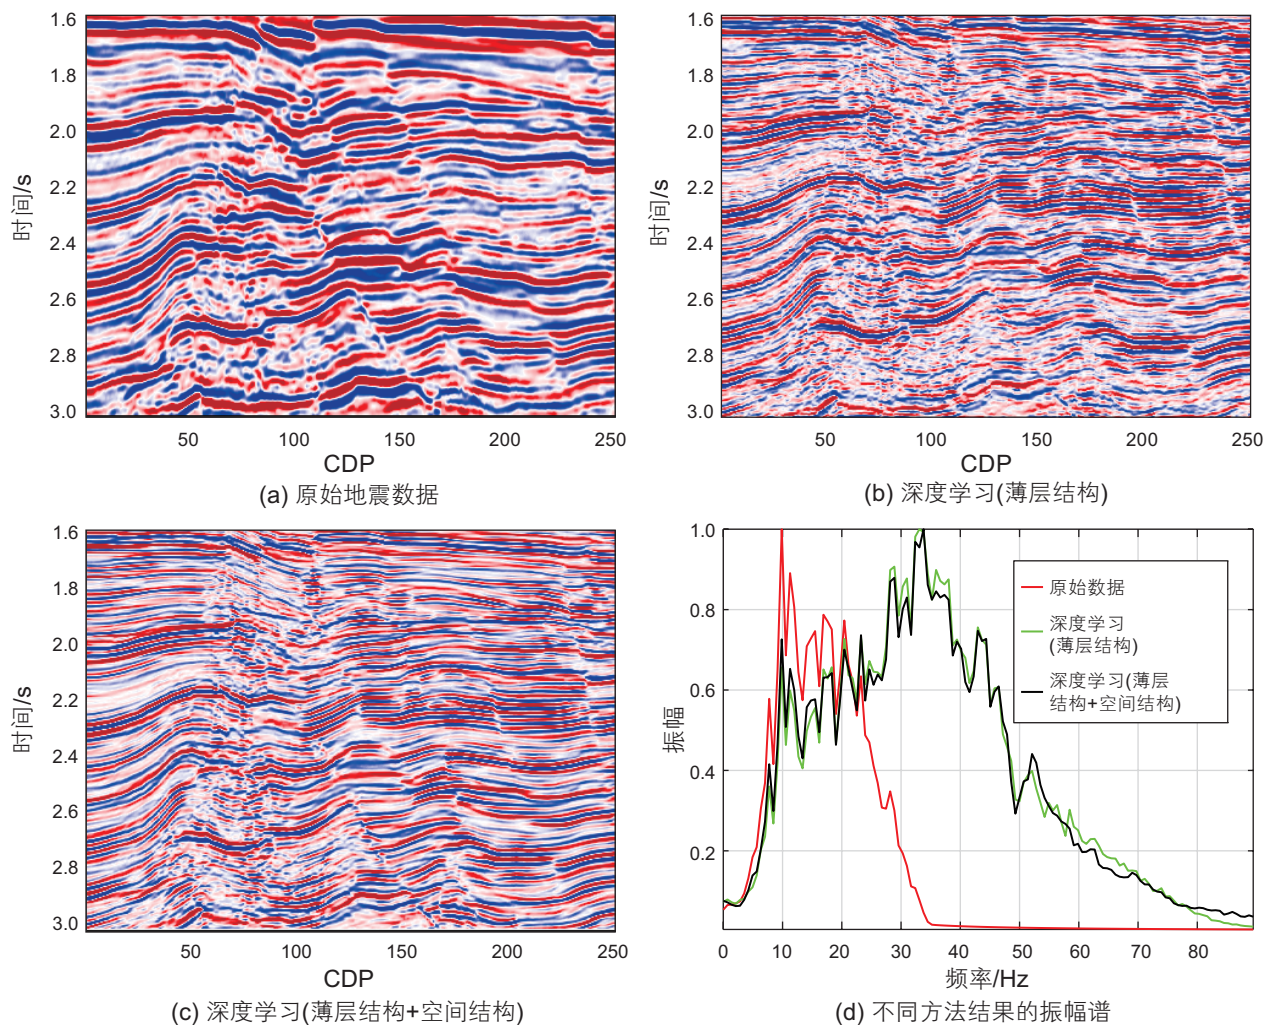


图 12 实际数据的高分辨率结果

Fig. 12 High resolution results of actual data

法(策略2)和考虑了薄层结构与空间结构的深度学习方法(策略3)的结果。相对于仅包含薄层结构的一维神经网络的结果(图12b),二维神经网络的结果(图12c)在横向特征和薄层分辨率方面表现更加一致和清晰。这表明使用加入空间结构的二维训练数据集能够有效地捕捉到二维地震数据中空间变化的结构。频谱图12d显示出,两种方法的频谱没有明显差异。

为了进一步对比不同方法产生高频成分的有效性,本文选用30-40-50-100 Hz带通滤波器分别对结果进

行滤波,其结果如图13所示。从图中可以看出,仅考虑薄层分布的深度学习恢复的高频成分连续性较差,存在明显的噪声特征。为了更清晰地比较不同方法产生的高频分量,我们对其进行了局部放大处理,如图14所示。从图中可以看出,加入空间结构的深度学习学习方法在训练过程中可以捕获地震数据中的空间变化模式,并能够产生稳定的高分辨率成分,其恢复的高频成分相对于仅考虑薄层分布的方法更加连续且不含噪声特征。

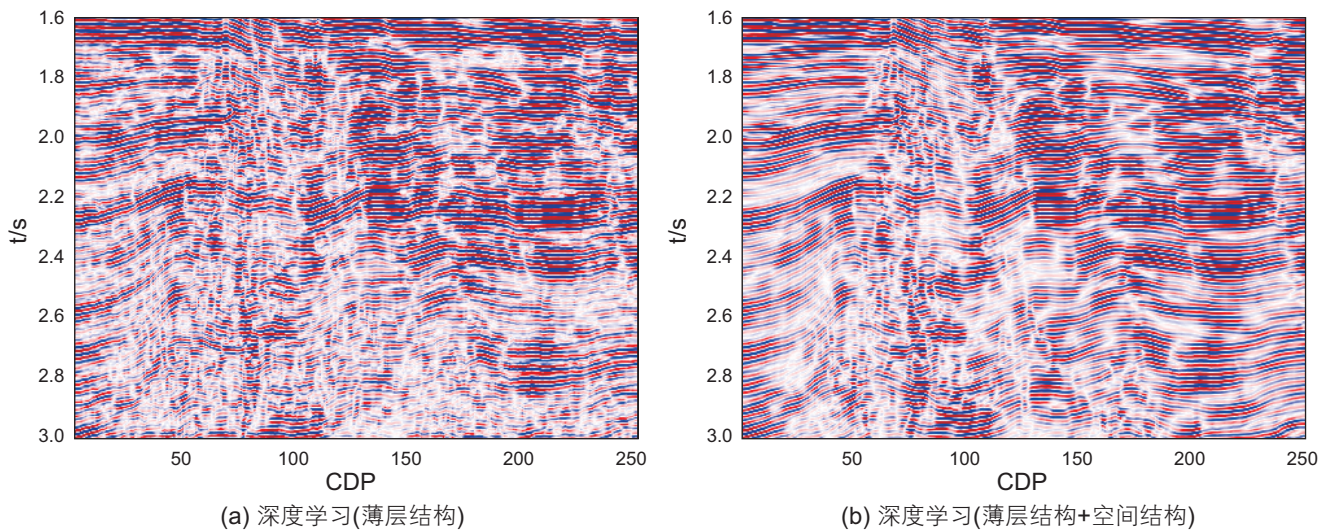


图13 实际地震数据高分辨率结果的高频成分

Fig. 13 High frequency components of high resolution results from real seismic data




图14 局部放大的高频成分

Fig. 14 Locally amplified high frequency components

4 结论与认识

本文提出了一种基于有监督学习的多道地震数据

高分辨率处理方法,将低分辨率的地震数据输入训练完成的神经网络,可直接输出高分辨率处理后的地震数据。所开发的神经网络采用标准的编码器-解码器结构,辅以残差学习机制,从训练集中学习更多高频

信息特征和细节。利用神经网络对地震数据进行高分辨率恢复的准确性很大程度上取决于训练集所包含特征的准确性和多样性。在此观点上,首先对测井数据所表示的以波阻抗分布模式为特征的薄层结构关系进行了分析和评价,并基于此分布生成大量一维波阻抗序列。此外,还考虑了地震数据中所包含的空间结构特征,例如褶皱、断层等。在波阻抗序列的基础上生

成了包含各种空间结构的二维波阻抗模型。最后通过不同频带子波与二维波阻抗模型进行正演,建立低频数据与高频标签。合成数据的结果表明,该方法可以提高垂直分辨率,并具有较好的抗噪性。实际数据进一步表明,与单道深度学习方法相比,该方法在只有少量测井数据的情况下,可以更准确地恢复薄层结构,并在横向上估计出更一致的高分辨率结果。

参考文献

- [1] 渥·伊尔马滋著;刘怀山,王克斌,童思友,等译.地震资料分析:地震资料处理、反演和解释(下册)[M].北京:石油工业出版社,2006.[ÖZ Y. Seismic data analysis: Processing, inversion, and interpretation of seismic data[M]. Beijing: Petroleum Industry Press, 2006.]
- [2] CLARKE G K C. Time-varying deconvolution filters[J]. *Geophysics*, 1968, 33(6): 936–944.
- [3] MARGRAVE G F, LAMOUREUX M P, HENLEY D C. Gabor deconvolution: Estimating reflectivity by nonstationary deconvolution of seismic data[J]. *Geophysics*, 2011, 76(3): W15–W30.
- [4] HARGREAVES N D, CALVERT A J. Inverse Q filtering by Fourier transform[J]. *Geophysics*, 1991, 56(4): 519–527.
- [5] BRAGA I L S, MORAES F S. High-resolution gathers by inverse Q filtering in the wavelet domain[J]. *Geophysics*, 2013, 78(2): V53–V61.
- [6] WANG Y, ZHOU H, CHEN H, et al. Adaptive stabilization for Q-compensated reverse time migration[J]. *Geophysics*, 2018, 83(1): S15–S32.
- [7] YUAN S, WANG S, MA M, et al. Sparse Bayesian learning-based time-variant deconvolution[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(11): 6182–6194.
- [8] BERKHOUT A J. Least-squares inverse filtering and wavelet deconvolution[J]. *Geophysics*, 1977, 42(7): 1369–1383.
- [9] COOKE D A, SCHNEIDER W A. Generalized linear inversion of reflection seismic data[J]. *Geophysics*, 1983, 48(6): 665–676.
- [10] OLDENBURG D W, SCHEUER T, LEVY S. Recovery of the acoustic impedance from reflection seismograms[J]. *Geophysics*, 1983, 48(10): 1318–1337.
- [11] SACCHI M D. Reweighting strategies in seismic deconvolution[J]. *Geophysical Journal International*, 1997, 129(3): 651–656.
- [12] ALEMIE W, SACCHI M D. High-resolution three-term AVO inversion by means of a Trivariate Cauchy probability distribution[J]. *Geophysics*, 2011, 76(3): R43–R55.
- [13] ZHANG R, CASTAGNA J. Seismic sparse-layer reflectivity inversion using basis pursuit decomposition[J]. *Geophysics*, 2011, 76(6): R147–R158.
- [14] DU X, LI G, ZHANG M, et al. Multichannel band-controlled deconvolution based on a data-driven structural regularization[J]. *Geophysics*, 2018, 83(5): R401–R411.
- [15] WU X, LIANG L, SHI Y, et al. Fault Seg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation[J]. *Geophysics*, 2019, 84(3): IM35–IM45.
- [16] 杜炳毅,张广智,王磊,等.基于机器学习的复杂储层微小断裂系统识别方法研究与应用[J].*石油物探*, 2021, 60(04): 621–631. [DU B, ZHANG G Z, WANG L, et al. Research and application of micro-fault system detection based on machine learning[J]. *Geophysical Prospecting for Petroleum*, 2021, 60(4): 621–631.]
- [17] YANG F, MA J. Deep-learning inversion: A next-generation seismic velocity model building method for velocity model building[J]. *Geophysics*, 2019, 84(4): R583–R599.
- [18] 张兵.基于卷积神经网络和叠加速度谱的地震层速度自动建模方法[J].*石油物探*, 2021, 60(3): 366–375. [ZHANG B. Automatic seismic interval velocity building based on convolutional neural network and velocity spectrum[J]. *Geophysical Prospecting for Petroleum*, 2021, 60(3): 366–375.]
- [19] 唐杰,韩盛元,刘英昌,等.基于去噪卷积神经网络的面波噪声压制方法[J].*石油物探*, 2022, 61(2): 245–252. [TANG J, HAN S Y, LIU Y, et al. Seismic surface wave attenuation based on denoising convolutional neural networks. *Geophysical Prospecting for Petroleum*, 2022, 61(2): 245–252.]
- [20] GAO Y, ZHAO P, LI G, et al. Seismic noise attenuation by signal reconstruction: an unsupervised machine learning approach[J]. *Geophysical Prospecting*, 2021, 69(5): 984–1002.
- [21] 罗刚,肖立志,史燕青,等.基于机器学习的致密储层流体识别方法研究[J].*石油科学通报*, 2022, 01: 24–33. [LUO G, XIAO L Z,

- SHI Y Q, et al. Machine learning for reservoir fluid identification with logs[J]. *Petroleum Science Bulletin*, 2022, 01: 24–33.]
- [22] GE Q, CAO H, YANG Z, et al. High-resolution seismic impedance inversion integrating the closed-loop convolutional neural network and geostatistics: An application to the thin interbedded reservoir[J]. *Journal of Geophysics and Engineering*, 2022, 19(3): 550–561.
- [23] SONG C, LU M, WANG Y, et al. A dynamic time warping loss-based closed-loop CNN for seismic impedance inversion[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1–13.
- [24] YANG N, XIONG J, GUO C, et al. Reflection coefficients inversion based on the bidirectional long short-term memory network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1–5.
- [25] GAO Y, ZHANG J, LI H, et al. Incorporating structural constraint into the machine learning high-resolution seismic reconstruction[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1–12.
- [26] WANG Y, WANG Q, LU W, et al. Physics-constrained seismic impedance inversion based on deep learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 1–5.
- [27] DAS V, POLLACK A, WOLLNER U, et al. Convolutional neural network for seismic impedance inversion CNN for seismic impedance inversion[J]. *Geophysics*, 2019, 84(6): R869–R880.
- [28] 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. [ZHANG Y L, YU Z C, HU T Y, et al. Multi-trace joint downhole microseismic phase detection and arrival picking method based on U-Net[J]. *Chinese Journal of Geophysics (in Chinese)*, 2021, 64(6): 2073–2085.]
- [29] 田亚军, 高静怀, 王大兴, 等. 基于深度神经网络的地震强反射剥离方法[J]. *地球物理学报*, 2021, 64(8): 2780–2794. [TIAN Y J, GAO J H, WANG D X, et al. Removing strong seismic reflection based on the deep neural network[J]. *Chinese Journal of Geophysics (in Chinese)*, 2021, 64(8): 2780–2794.]
- [30] 杨午阳, 杨佳润, 陈双全, 等. 基于U-Net深度学习网络的地震数据断层检测[J]. *石油地球物理勘探*, 2021, 56(4): 688–697. [YANG W Y, YANG J R, CHEN S Q, et al. Seismic data fault detection based on U-Net deep learning network[J]. *Oil Geophysical Prospecting*, 2021, 56(4): 688–697.]

(编辑 付娟娟)