



移动阅读

陈文超, 刘达伟, 魏新建, 等. 基于地震资料有效信息约束的深度网络无监督噪声压制方法[J]. 煤田地质与勘探, 2021, 49(1): 249–256. doi: 10.3969/j.issn.1001-1986.2021.01.027

CHEN Wenchao, LIU Dawei, WEI Xinjian, et al. Unsupervised noise suppression method for depth network seismic data based on prior information constraint[J]. Coal Geology & Exploration, 2021, 49(1): 249–256. doi: 10.3969/j.issn.1001-1986.2021.01.027

基于地震资料有效信息约束的深度网络 无监督噪声压制方法

陈文超¹, 刘达伟¹, 魏新建², 王晓凯¹, 陈德武², 李书平², 李 冬²

(1. 西安交通大学 信息与通信工程学院, 陕西 西安 710049;

2. 中国石油勘探开发研究院西北分院, 甘肃 兰州 730020)

摘要: 地震资料处理是地震勘探中的关键环节, 由于地下构造和地表条件的复杂性, 地震资料的处理需要经过一系列复杂流程, 从而形成多种不同类型的地震数据。不同种类的地震数据具有不同的数据特征, 充分利用和发掘其中的数据特征, 不仅可以充分发挥处理方法的技术潜力, 消除各类非地质因素对地震资料处理质量的影响, 同时可以增强地震资料处理的可靠性, 改善地震资料的资料信噪比及分辨率, 在复杂油气藏勘探开发中具有非常重要的基础作用。叠前地震成像道集(CRP)中的有效信号同相轴近似水平, 叠后地震成像数据因为地层沉积的规律性, 有效信号相比于随机噪声、成像弧状噪声等干扰具有规律、简单等特点。具体表现为 CRP 道集及叠后地震资料有效信号具有多尺度自相似性的特征, 其高维 Fourier(FK 或 FKK)域主要能量集中在低频、低波数区域。针对上述地震数据的特点, 提出一种基于先验信息约束的深度网络地震资料无监督噪声压制方法。受到深度图像先验(DIP)的启发, 神经网络的结构可以视为一种特殊的隐式先验信息, 合理设计网络结构可以使得网络具有多尺度自相似性特征的提取能力。由于叠前地震成像道集数据和叠后地震成像数据有效信号的多尺度自相似性, 而噪声不具备这一特性, 因此, 特定结构的网络可以从原始数据提取出有效信号, 从而达到噪声压制的目的。叠前成像道集和叠后成像的实际数据随机噪声压制试验结果表明, 本文方法具有良好的保真性与鲁棒性。此外, 由于本文方法具有强大的特征提取能力, 因此, 对常规方法不易压制的弧状成像噪声也有良好的效果。

关键词: 无监督学习; 神经网络; 弧状成像噪声压制; 成像道集; 多尺度自相似性
中图分类号: P631 **文献标志码:** A **文章编号:** 1001-1986(2021)01-0249-08 **语音讲解**



Unsupervised noise suppression method for depth network seismic data based on prior information constraint

CHEN Wenchao¹, LIU Dawei¹, WEI Xinjian², WANG Xiaokai¹, CHEN Dewu², LI Shuping², LI Dong²

(1. School of Information and Communication Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. Research Institute of Petroleum Exploration & Development-Northwest(NWGI) PetroChina, Lanzhou 730020, China)

Abstract: Seismic data processing is a critical step in seismic exploration. Due to the complexity of underground structure and surface conditions, seismic data processing needs to go through a series of complex processes, thus forming various types of seismic data. Different types of seismic data have different data characteristics. Exploring and making full use of the data characteristics can not only give full play to the technical potential of processing methods, eliminate the influence of various non-geological factors on the quality of seismic data processing, but also enhance the reliability of seismic data processing. Improving the signal-to-noise ratio and resolution of seismic data plays a significant role in the exploration and development of complex reservoirs. The useful signal in pre-stack seis-

mic imaging gathers(common-reflection-point gathers) is approximately horizontal, and the useful signal in post-stack seismic imaging data is regular and straightforward compared with random noise and arc-like imaging noise because of the regularity of stratum deposition. Therefore, the corresponding FK domain is focused on low-frequency energy due to the specific characteristics of multiscale self-similarity. According to the characteristics of the above seismic data, this paper proposes an unsupervised noise suppression method for deep network seismic data based on prior information constraints. Inspired by the deep image prior (DIP), the structure of the neural network can be regarded as a kind of particular implicit prior information. The reasonable design of network structure can improve the ability of multiscale self-similarity feature extraction. Because of the multiscale self-similarity of the useful signals of pre-stack seismic imaging gather data and post-stack seismic imaging data but noise without this characteristic, the network with specific structure can extract the useful signals from the original data, so as to achieve the goal of noise suppression. The application results of pre-stack imaging gathers and post-stack imaging data show that the proposed method has good fidelity and robustness. In addition, due to its strong feature extraction ability, the proposed method also has a good effect on arc-like imaging noise not easy to suppress by conventional methods.

Keywords: unsupervised learning; neural network; arc-like imaging noise; imaging gathers; multiscale similarity

地震资料处理是地震勘探中的关键环节,对于连接采集和解释工作发挥着重要功能,其处理质量对地震资料解释和储层预测精度起到了决定作用。在地震数据采集过程中,不可避免地会引入随机噪声,压制随机噪声可以提升信噪比,有助于提高解释精度,对后期的地震数据的解释至关重要。因此,地震数据的随机噪声压制问题在地震资料处理中占据着重要地位。传统基于模型的优化方法和近年来兴起的判别学习方法是随机噪声压制的两大类方法。

基于模型的优化方法使用明确的先验信息建立相关模型,然后通过求解优化问题得到干净的去噪数据。这类方法具有明确的物理含义,并且具有较强的泛化性能,对于不同种类的地震数据都有一定的噪声压制效果。按照使用的不同的先验知识,基于模型的方法可以大致分为三大类。第一类是基于滤波的方法^[1-2]。假设地震有效信号的反射同相轴具有横向连续性,以此来区分有效信号和噪声。第二类是基于低秩的方法,包括低秩分解^[3-5]和核范数最小化^[6]。第三类是基于稀疏表示的噪声压制方法,这类方法构建合适的字典对有效信号进行稀疏表示,而该字典无法稀疏表示随机噪声,从而达到压制随机噪声的目的^[7-9]。上述方法在实际数据的处理过程中均取得了良好的效果,但是也会面临一些挑战。一方面,这类方法要求人为指定的先验知识尽可能准确,然而由于地震数据的复杂性,使用这些先验知识在某些复杂结构区域仍然无法区分有效信号和随机噪声。另一方面,模型优化的时间通常比较耗时,并且需要专业的计算机知识才可以实现快速并行计算。

与之相反,判别学习方法,如最近几年流行的深度学习方法,通过端对端地学习训练样本对获得先验知识,这把研究人员从复杂的先验知识设计中解放出来,尤其对于那些无法用明确公式表达的先

验知识很有效果。此外,深度学习在随机噪声压制问题中得到大规模使用的另一个原因是它很容易并行计算,虽然训练耗时较长,但是测试时间相比模型优化法很有优势。按照网络维度的不同,此类可以分为二维网络方法^[10]和三维网络方法^[11-12]。尽管它们在实际使用中可以取得令人满意的结果,但是也遇到了一些挑战。首先,判别学习类方法需要大量的不含噪地震数据作为标签数据,而这在实际中是几乎不可能获得的。其次,网络的泛化能力通常较弱,当处理较大规模的地震数据时,它的去噪能力会退化。

无监督的深度学习方法可以兼具上述两类方法的优点。无监督深度学习方法既不需要标签数据,并且有较强的泛化能力,此外还可以使用深度学习框架较为容易地实现并行计算。无监督深度学习方法已经成功地应用于地震数据集的噪声压制^[13]。本文提出了一种基于先验信息约束的深度网络地震资料无监督噪声压制方法。由于叠前地震成像道集数据和叠后地震成像数据有效信号的多尺度自相似性,而噪声不具备这一特性,因此,可以设计一种可以提取多尺度自相似性的网络,从中提取有效信号,从而达到噪声压制的目标。受到深度图像先验(Deep Image Prior, DIP)^[14]的启发,本文使用一种多尺度的生成卷积神经网络,以含噪地震数据作为训练目标,使之从含噪地震数据中提取有效信号。训练过程中使用早停法选择合适的迭代次数,使网络输出去噪后的地震数据。

1 方法原理

1.1 建立模型

假设含噪地震数据 $\mathbf{x}_0$ 为有效信号 $\mathbf{x}$ 和随机噪声 $\mathbf{n}$ 的线性叠加:

$$\mathbf{x}_0 = \mathbf{x} + \mathbf{n} \quad (1)$$

本文使用深度生成网络参数化表示有效信号 $\mathbf{x}$ 如下:

$$\mathbf{x} = f_{\theta}(\mathbf{z}) \quad (2)$$

式中: θ 表示网络参数, 包括权重和偏置; $\mathbf{z}$ 为随机向量; f 表示深度生成网络, 实现由 $\mathbf{z}$ 到 $\mathbf{x}$ 的非线性映射。网络参数化的过程可以视为对 $\mathbf{x}$ 的重构过程。将式(2)代入式(1)中可得:

$$\mathbf{x}_0 = f_{\theta}(\mathbf{z}) + \mathbf{n} \quad (3)$$

式中: 只有 θ 是未知变量。随机噪声压制问题等同于通过优化如下的能量函数, 找到最优的网络参数 θ^* :

$$\theta^* = \arg \min_{\theta} E(f_{\theta}(\mathbf{z}); \mathbf{x}_0) \quad (4)$$

本文所使用的能量函数 $E(f_{\theta}(\mathbf{z}); \mathbf{x}_0)$ 如下所示:

$$E(f_{\theta}(\mathbf{z}); \mathbf{x}_0) = \|f_{\theta}(\mathbf{z}) - \mathbf{x}_0\|^2 \quad (5)$$

从式(4)中可以发现, 在网络的训练过程中只需要用到含噪地震数据 $\mathbf{x}_0$, 而不需要干净的地震数据作为标签。一旦找到最优的网络参数 θ^* , 就可以很容易地得到网络输出的去噪后地震数据 $\mathbf{x}^* = f_{\theta^*}(\mathbf{z})$ 。

1.2 网络结构

本文所使用的深度生成网络结构是一种经典的 U-Net 网络结构, 包括 3 大部分: 5 个下采样(Downsample)模块(Block), 2 个跳跃连接层(Skip)模块及 5 个上采样(Upsample)模块。每个模块包含几个基本单元, 基本单元包括卷积(Conv)层、批归

一化(Batch normalization, BN)层、下采样(Downsample)层、上采样(Upsample)层和激活函数(LeakyReLU)层, 如图 1 所示。为了节省计算开销, 随着网络深度的加深, 下采样的卷积滤波器数目从初始的 8 个增加到 128 个, 上采样层的滤波器数目与之对称。不同网络深度的下采样模块和上采样模块通过压缩共有特征和剔除无用信息来降低目标地震数据的维数。这种网络结构使深度生成网络具有多尺度自相似特征的提取能力。地震资料的有效信号在本质上具有多尺度特征, 许多地震处理方法从中受益^[15-16]。因此, 本文可以应用上述网络的特征提取能力来提取有效信号, 从而达到压制地震资料随机噪声的目的。

同时, 本文在原有 U-Net 网络结构的基础上做了一些修改。首先, 为了减少由上采样模块引起的棋盘效应, 采用转置卷积代替双线性插值。其次, 设置跳跃连接的策略来避免梯度消失问题。第三, 用漏泄线性整流函数替换原有激活函数, 防止神经元湮灭。

1.3 模型训练

如式(2)所示, 本文使用深度生成网络对地震数据进行参数化, 这相当于增加了先验信息约束, 即重构的地震数据是深度生成网络输出解空间内的一个解。在这个约束下, 式(4)可以由 l_2 范数优化问题求解得到, 此优化问题是一个具有唯一位置变量 θ 的非凸问题。本文可以把这个问题看作一个无监督的网络训练问题, 并应用自适应矩估计(Adaptive




图 1 本文所使用的网络模型结构

Fig.1 The network architecture of the proposed method

Moment Estimation, ADAM)优化器迭代地估计一个局部最优的 θ^* 。网络从随机初始化 θ_0 开始, $\mathbf{z}$ 使用均匀分布的随机变量进行初始化。当训练开始时,每个迭代的参数 θ_n 被映射到网络输出 $\mathbf{x}'_n = f_{\theta_n}(\mathbf{z})$ 。随着训练迭代次数的增加,式(5)中的能量函数逐渐收敛。如前文所述,深度生成网络由于其特殊的网络结构,倾向于在多个尺度上提取自相似特征。地震数据有效信号在空间上是相关的,而随机噪声是随机分布的,这使得有效信号比随机噪声更具有自相似性。由于深度生成网络解空间的限制,与随机噪声相比,网络更容易提取具有自相似性的有效信号。为了验证这一点,本文分别用深度生成网络重构了含噪地震数据、随机噪声和有效信号,其中含噪地震资料是将另外两个数据相加得到的。如图2所示,如果重建有效信号,1500次迭代就可以使得能量函数很小,这是因为深度生成网络很容易学习有效信号的这些自相似特征。然而,如果要重建随机噪声,需要8000次以上的迭代,因为几乎没有自相似的特征,所以网络只能机械地反复记忆。当使用深度生成网络重建原始地震数据时,网络的输出首先重建有用信号,然后开始重建随机噪声。换言之,存在一系列连续的迭代区间,其中网络拟合了几乎所有有效信号的能量,但只拟合了少数随机噪声的能量。通过选择特定的迭代次数,采用提前停止策略,网络可以滤除有效信号中的随机噪声。虽然可以通过更精确地调整迭代来获得最佳去噪结果,但本文发现,在一个较大的迭代区间内网络得到的去噪结果差异不明显,这使得大规模的工业应用成为可能。




图2 深度生成网络分别重构含噪地震数据、随机噪声和有效信号得到的能量曲线

Fig.2 Energy curves for the reconstruction task using seismic (C) useful signals, random noise and noisy seismic data set

1.4 深度神经网络的低频优先原则

有效信号的能力主要是低频成分,深度神经网络之所以能够从含噪信号中提取有效信号,是因为深度学习网络具有低频优先原则,即在训练过程中,深度学习网络通常从低频到高频拟合目标函数^[17]。下面以含有一个隐含层的深度神经网络为例来证明,该网络有 m 个节点,一维输入 x 和一维输出:

$$h(x) = \sum_{j=1}^m a_j \sigma(w_j x + b_j) \quad a_j, w_j, b_j \in \mathbb{R} \quad (6)$$

式中: a_j, w_j, b_j 为网络参数,具体而言, a_j 和 w_j 为网络权重参数, b_j 为网络偏置。假设激活函数为 $\sigma(x) = \tan h(x)$,则:

$$\sigma(x) = \tan h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}, \quad x \in \mathbb{R} \quad (7)$$

由于 $\sigma(x)$ 傅里叶变换为 $\hat{\sigma}(k) = -\frac{i\pi}{\sin h(\pi k/2)}$,

因此,可得:

$$\hat{h}(k) = \sum_{j=1}^m \frac{2\pi a_j i}{|w_j|} \exp\left(\frac{i b_j k}{w_j}\right) \frac{1}{\exp\left(-\frac{\pi k}{2w_j}\right) - \exp\left(\frac{\pi k}{2w_j}\right)} \quad (8)$$

定义深度神经网络的输出和目标函数 $f(x)$ 在频率 k 的幅度差为:

$$D(k) \triangleq \hat{h}(k) - \hat{f}(k) \quad (9)$$

将 $D(k)$ 写为 $D(k) = A(k)e^{i\phi(k)}$,其中 $A(k)$ 和 $\phi(k)$ 分别为幅度和相位。在频率 k 点的能量函数为 $L(k) = \frac{1}{2} |D(k)|^2$,总损失函数为 $L = \int_{-\infty}^{+\infty} L(k) dk$ 。根据帕斯瓦尔定理可知,频率域的总损失函数等同于时间域的均方误差 $L = \int_{-\infty}^{+\infty} \frac{1}{2} (h(x) - f(x))^2 dx$ 。对于在频率 k 点的偏导数为:

$$\frac{\partial L(k)}{\partial a_j} = \frac{2\pi}{w_j} \sin\left(\frac{b_j k}{w_j} - \phi(k)\right) E_0 \quad (10)$$

$$\frac{\partial L(k)}{\partial w_j} = \left[\sin\left(\frac{b_j k}{w_j} - \phi(k)\right) \left(\frac{\pi^2 a_j k}{w_j^3} E_1 - \frac{2\pi a_j}{w_j^2} \right) - \frac{2\pi a_j b_j k}{w_j^3} \cos\left(\frac{b_j k}{w_j} - \phi(k)\right) \right] E_0 \quad (11)$$

$$\frac{\partial L(k)}{\partial b_j} = \frac{2\pi a_j b_j k}{w_j^2} \cos\left(\frac{b_j k}{w_j} - \phi(k)\right) E_0 \quad (12)$$

其中, All rights reserved. <http://www.cnki.net>

$$E_0 = \frac{\text{sgn}(w_j) A(k)}{\exp\left(\frac{\pi k}{2w_j}\right) - \exp\left(-\frac{\pi k}{2w_j}\right)}$$

$$E_1 = \frac{\exp\left(\frac{\pi k}{2w_j}\right) + \exp\left(-\frac{\pi k}{2w_j}\right)}{\exp\left(\frac{\pi k}{2w_j}\right) - \exp\left(-\frac{\pi k}{2w_j}\right)} \quad (13)$$

频率 k 对 θ_{ij} 的偏导数为:

$$\left| \frac{\partial L(k)}{\partial \theta_{ij}} \right| \approx A(k) \exp(-|\pi k / 2w_j|) F_{ij}(\theta_j, k) \quad (14)$$

式中: $\theta_j \triangleq \{w_j, b_j, a_j\}$, $\theta_{ij} \in \theta_j$, $F_{ij}(\theta_j, k)$ 是关于 θ_j 和 k 的函数, 分别如式(10)、式(11)、式(12)所示。

可以证明, 对于频率轴上的两个非零的频率成分 k_1 和 k_2 , 其中 $|k_2| > |k_1| > 0$, 可以得到 $\left| \frac{\partial L(k_1)}{\partial \theta_{ij}} \right| > \left| \frac{\partial L(k_2)}{\partial \theta_{ij}} \right|$, 即网络对于低频成分的能量学习较快^[17]。


本文以一个东部某油田实际叠前地震成像道集为例说明深度神经网络的低频优先原则, 图 3 为使

用本文网络对含噪地震数据进行重构得到的不同迭代次数的结果, 可以看到迭代次数较少时, 网络主要重构 3 数据中的低频成分, 随着迭代次数的增加, 越来越多的精细结构被网络重构出来, 同时, 也重构了更多的噪声成分。图 4 为图 3 对应的 FK 谱, 也可以观察到, 网络优先学习低频特征, 随着训练迭代次数的增加, 越来越多的高频成分被重构出来。

2 算例分析

2.1 叠前地震成像道集

图 5a 是一个东部某油田叠前地震成像道集, 包括 200 道数据, 每道数据具有 3 001 个时间采样点, 采样率为 2 ms。可以看到图中有效信号被大量的背景噪声所污染, 使得一些微弱的有效信号变得模糊。同时, 可以观察到同相轴是近似水平的, 这与本文方法善于提取低频的、具有多尺度自相似的特征相匹配。DDTF(Data-drive Tight Frame)^[18]是一种常用的地震数据噪声压制方法, 本文选择 DDTF 方法作为对比。图 5b 显示了 DDTF 的去噪结果, 可以看出到仍然存在一些残余噪声。然后利用深度生成网络




(a)~(l)分别为 100~1 200 次迭代的结果

(a)~(l) are results of 100~1 200 iterations respectively

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

Fig.3 The different reconstruction results of CRP with the deep generative network




(a)~(l)分别为 100~1 200 次迭代的 FK 谱

(a)-(l) are FK spectrum of 100-1 200 iterations respectively

图 4 深度生成网络重构叠前地震成像道集的不同迭代次数结果的 FK 谱

Fig.4 The different reconstruction FK spectrum of CRP with the deep generative network



(a)为含噪数据集;(b)和(c)分别为 DDTF 和本文方法的去噪结果;

(d)和(e)为 DDTF 和本文方法去除的噪声

(a) Noisy dataset; (b) DDTF denoised results; (c) Denoised results using the proposed method; (d) DDTF removed noise; (e) Removed noise using the proposed method

图 5 叠前地震成像道集的去噪结果

Fig.5 Denoising comparisons of CRP

从原始地震数据中提取自相似特征。经过大约 1 500 次迭代,得到了网络的去噪结果,如图 5c 所示。可以看出,本文方法的没有明显残余噪声,同相轴比 DDTF 方法更清晰。此外,本文方法在不丢失有用信号细节的情况下也去除了一些相干噪声。在如图 5d 所示 DDTF 方法相应的噪声去除部分中,可以看到一些有效信号的泄漏。然而,如图 5e 所示,除了一些异常的振幅点外,本文方法几乎找不到明显的连续同相轴,这表明本文方法在去噪过程中没有严重破坏有效信号。此外,本文方法的计算时间(79.19 s)比 DDTF(51.30 s)耗时多,但去噪效果更优,参数选择更为容易。

本文进一步从多通道归一化幅度谱来比较去噪性能研究,如图 6 所示。众所周知,随机噪声的主要能量集中在高频端。可以看出,由网络去噪后数据的高频能量幅度谱(例如高于 60 Hz 部分)低于由 DDTF 去噪数据的高频能量幅度谱,如图 6a 所示。这意味着网络抑制了更多的噪声能量。从图 6b 所示的去除噪声的幅度谱也可以得到相同的结论。

为了更清楚地进行比较, 图 6c 显示了图 6a 红色圆圈所示的放大区域, 可以更清楚地观察到网络的去噪结果在高频段能量较低。可以得出结论, 与 DDTF 相比, 该方法具有更高的保真度和更强的噪声抑制能力。

下面从叠加剖面上观察本文方法的噪声压制效

果。图 7a 所示是 200 道原始叠前地震成像道集经过叠加而成的叠加剖面。图 7b 所示是 200 道网络去噪后的叠前地震成像道集经过叠加而成的叠加剖面, 可以看到波形一致性得到了增强, 图 7c 为图 7a 与图 7b 的差剖面, 从图 7c 中观察不到明显的有效信号损伤, 这证明了本文方法的保真性。





图 6 多道归一化振幅谱

Fig.6 Multichannel normalized amplitude spectrum



(a) 原始数据; (b) 去噪后数据; (c) 去除的噪声数据

(a) Original data; (b) Denoised data; (c) Removed noise


图 7 由 200 个叠前地震成像道集叠加而成的叠加数据

Fig.7 Stack data from 200 pre-stack seismic imaging gathers

2.2 叠后地震成像数据

为了进一步说明本文方法的有效性, 以如图 8a 所示的叠后地震成像数据为例进行噪声压制。该数据来自东部某油田, 图示 600 道数据和 1 200 个时间采样点, 采样时间为 2 ms。可以看到, 该数据受到噪声影响严重, 尤其受到了弧状成像噪声的干扰, 对地震数据的解释造成了干扰。图 8b 所示是网络经

过 6 500 次迭代得到的去噪后的地震数据, 可以看到本文方法去除了大量的随机噪声, 去噪后同相轴的连续性得到了加强, 尤其是图中红色矩形框所示的区域, 弧状成像噪声得到了压制。从图 8c 中去除的噪声部分来看, 噪声中除了弧状噪声部分, 没有明显的地层结构成分, 说明本文方法几乎没有损伤有效信号, 具有较高的保真性。



(a) 原始数据; (b) 去噪后数据; (c) 去除的噪声数据
(a) Original data; (b) Denoised data; (c) Removed noise

图 8 叠后地震成像数据

Fig.8 Post-stack seismic imaging data

3 结 论

本文提出了一种基于深度学习的无监督随机噪声压制方法,叠前、叠后成像数据处理结果表明,该方法具有以下 3 个特点:所提方法不需要常见深度神经网络必须的训练标签;本文采用的网络具有很强的多尺度自相似特征提取能力,能够容易地从原始含噪数据中提取有效信号;此外,该方法在有效抑制随机噪声的同时,对有效信号的损伤较小,尤其可以有效压制传统方法不易去除的弧状成像噪声。

参考文献(References)

- [1] TRICKETT S. F-xy Cadzow noise suppression[C]//SEG Technical Program Expanded Abstracts 2008. Society of Exploration Geophysicists, 2008: 2586–2590.
- [2] SOUBARAS R. Signal-preserving random noise attenuation by the f-x projection[C]//SEG Technical Program Expanded Abstracts, Jan. 1994: 1576–1579.
- [3] TRICKETT S R. F-xy eigenimage noise suppression[J]. Geophysics, 2003, 68(2): 751–759.
- [4] BEKARA M, BAAN VAN DER M. Local singular value decomposition for signal enhancement of seismic data[J]. Geophysics, 2007, 72(2): 59–65.
- [5] OROPEZA V, SACCHI M. Simultaneous seismic data denoising and reconstruction via multichannel singular spectrum analysis[J]. Geophysics, 2011, 76(3): 25–32.
- [6] KREIMER N, SACCHI M D. A tensor higher-order singular value decomposition for pre-stack seismic data noise reduction and interpolation[J]. Geophysics, 2012, 77(3): 113–122.
- [7] YU Z, ABMA R, ETGEN J, et al. Attenuation of noise and simultaneous source interference using wavelet denoising[J]. Geophysics, 2017, 82(3): 179–190.
- [8] WANG Xiaojing, MA Jianwei. Adaptive dictionary learning for blind seismic data denoising[J]. IEEE Geoscience and Remote Sensing Letters, 2019: 1–5.
- [9] WANG Shen, LI Jianchao, CHIU S K, et al. Seismic data compression and regularization via wave packets[C]//SEG Technical Program Expanded Abstracts 2010. 2010: 3650–3655.
- [10] ZHANG Yinxue, TIAN Xuemin, DENG Xiaogang, et al. Seismic denoising based on modified BP neural network[C]//2010 Sixth International Conference on Natural Computation. 2010: 1825–1829.
- [11] WANG Enning, NEALON J. Applying machine learning to 3D seismic image denoising and enhancement[J]. Interpretation, 2019, 7(3): 131–139.
- [12] LIU Dawei, WANG Wei, WANG Xiaokai, et al. Poststack seismic data denoising based on 3-D convolutional neural network[J]. IEEE Trans. Geosci. Remote Sens., 2020, 58(3): 1598–1629.
- [13] CHEN Yangkang, ZHANG Mi, BAI Min, et al. Improving the signal-to-noise ratio of seismological datasets by unsupervised machine learning[J]. Seismol. Res. Lett., 2019, 90(4): 1552–1564.
- [14] ULYANOV D, VEDALDI A, LEMPITSKY V. Deep image prior[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2018: 9446–9454[2020-03-19].
- [15] HERRMANN F J, WANG DeLi, HENNENFENT G, et al. Curvelet-based seismic data processing: A multiscale and nonlinear approach[J]. Geophysics, 2008, 73(1): 1–5.
- [16] BUNKS C, SALECKF M, ZALESKI S, et al. Multiscale seismic waveform inversion[J]. Geophysics, 1995, 60(5): 1457–1473.
- [17] XU Z-Q J. Frequency principle: Fourier analysis sheds light on deep neural networks[J]. Commun. Comput. Phys., 2020, 28(5): 1746–1767.
- [18] LIANG Jianwei, MA Jianwei, ZHANG Xiaoqun. Seismic data restoration via data-driven tight frame[J]. Geophysics, 2014, 79(3): 65–74.