

8-25-2024

Seismic data denoising based on the convolutional neural network with an attention mechanism in the curvelet domain

BAO Qianzong

School of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China; Key Laboratory of Mine Geological Hazards Mechanism and Control, Ministry of Natural Resources, Xi'an 710054, China; National Engineering Research Center of Offshore Oil and Gas Exploration, Beijing 100028, China, qzbao@chd.edu.cn

ZHOU Mei

School of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China, zhoumei4801@163.com

QIU Yi

PowerChina Northwest Engineering Corporation Limited, Xi'an 710065, China

Follow this and additional works at: <https://cge.researchcommons.org/journal>



Part of the [Earth Sciences Commons](#), [Mining Engineering Commons](#), [Oil, Gas, and Energy Commons](#), and the [Sustainability Commons](#)

Recommended Citation

BAO Qianzong, ZHOU Mei, QIU Yi, et al. (2024) "Seismic data denoising based on the convolutional neural network with an attention mechanism in the curvelet domain," *Coal Geology & Exploration*: Vol. 52: Iss. 8, Article 16.

DOI: 10.12363/issn.1001-1986.24.02.0133

Available at: <https://cge.researchcommons.org/journal/vol52/iss8/16>

This Intelligent Geophysical Exploration is brought to you for free and open access by Coal Geology & Exploration. It has been accepted for inclusion in Coal Geology & Exploration by an authorized editor of Coal Geology & Exploration. For more information, please contact 380940179@qq.com.



移动阅读

包乾宗,周梅,邱怡. 基于 Curvelet 域的注意力机制卷积网络地震数据去噪[J]. 煤田地质与勘探, 2024, 52(8): 165–176. doi: 10.12363/issn.1001-1986.24.02.0133

BAO Qianzong, ZHOU Mei, QIU Yi. Seismic data denoising based on the convolutional neural network with an attention mechanism in the curvelet domain[J]. Coal Geology & Exploration, 2024, 52(8): 165–176. doi: 10.12363/issn.1001-1986.24.02.0133

基于 Curvelet 域的注意力机制卷积网络地震数据去噪

包乾宗^{1,2,3}, 周梅¹, 邱怡⁴

(1. 长安大学地质工程与测绘学院, 陕西西安 710054; 2. 自然资源部矿山地质灾害成灾机理与防控重点实验室, 陕西西安 710054; 3. 海洋油气勘探国家工程研究中心, 北京 100028; 4. 中国电建集团西北勘测设计研究院有限公司, 陕西西安 710065)

摘要: 【目的】地震资料中的噪声严重影响着对地下地层信息的准确解释。基于地震资料中横向相关性较强的有效信号在 Curvelet 域分布在特定系数上, 而随机噪声在 Curvelet 域通常会均匀分布于所有系数, 可对信号进行更有效的分离。【方法】基于注意力机制卷积神经网络能够聚焦图像的重要特征, 自适应提取关键信息的特点, 提出一种基于 Curvelet 变换和注意力机制卷积神经网络 (Curvelet-AU-Net) 的地震数据噪声衰减方法。首先, 将含噪声的地震数据通过 Curvelet 变换得到 Curvelet 变换系数, 分析有效信号和噪声在 Curvelet 域的分布情况。其次, 使用加入 CBAM(Convolutional block attention module) 注意力机制的 U-Net 网络, 以含噪地震数据的 Curvelet 变换系数制作训练集作为输入数据, 用无噪地震数据的 Curvelet 变换系数作为标签, 通过比较实际输出与标签的损失函数值, 并逐层反向传播梯度来更新网络参数, 当损失函数值达到最小时, 网络训练完成。最后, 将测试数据输入训练好的网络模型中, 再对网络输出数据进行 Curvelet 反变换即可得到地震数据去噪结果。【结果和结论】模拟数据与实际数据处理结果表明, 与传统方法和普通卷积网络相比, 该方法在不同噪声水平和尺度条件下对常见噪声(如随机噪声等)的衰减效果更优, 获得的地震信号信噪比和保真度更高。由于该方法融合了 Curvelet 变换的稀疏表示优势和深度学习模型的自适应性, 将为地震数据噪声衰减提供一种新的解决途径。

关键词: 地震数据去噪; 深度学习; U-net 网络; Curvelet 变换; 注意力机制

中图分类号: P631 **文献标志码:** A **文章编号:** 1001-1986(2024)08-0165-12

Seismic data denoising based on the convolutional neural network with an attention mechanism in the curvelet domain

BAO Qianzong^{1,2,3}, ZHOU Mei¹, QIU Yi⁴

(1. School of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China; 2. Key Laboratory of Mine Geological Hazards Mechanism and Control, Ministry of Natural Resources, Xi'an 710054, China; 3. National Engineering Research Center of Offshore Oil and Gas Exploration, Beijing 100028, China; 4. PowerChina Northwest Engineering Corporation Limited, Xi'an 710065, China)

Abstract: [Objective] Noise in seismic data significantly affects the accurate interpretation of subsurface stratigraphic information. Given that effective signals with pronounced lateral correlations in seismic data are distributed in specific coefficients but random noise typically spreads uniformly over all coefficients in the curvelet domain, more effective separation of signals can be achieved. [Methods] The convolutional neural network based on the attention mechanism can adaptively extract key information by focusing on important features of images. Hence, this study proposed a noise attenuation method for seismic data using a convolutional neural network based on the curvelet transform and attention mechanism (Curvelet-AU-Net). First, the curvelet coefficients of noise-containing seismic data were obtained through

收稿日期: 2024-02-27; 接收日期: 2024-05-14

基金项目: 国家重点研发计划项目课题(2022YFC3003402); 陕西省自然科学基金项目(2021JM-156)

第一作者: 包乾宗, 1972 年生, 男, 甘肃庆阳人, 博士, 副教授, 硕士生导师, 从事地震数据处理、深度学习、全波形反演和高铁地震学等方面的研究工作. E-mail: qzbao@chd.edu.cn

curvelet transform to analyze the distributions of effective signals and noise in the curvelet domain. Second, a U-Net network with a convolutional block attention module (CBAM) was employed, with the curvelet coefficients of noise-containing seismic data as input data for training and the curvelet coefficients of noise-free seismic data as labels. Then, the parameters of the network were updated by comparing the loss function values of actual outputs and labels and back-propagating gradients layer by layer. The network training was completed as the loss function value reached its minimum. Finally, the test data were put into the trained network model. The denoising results of seismic data were obtained by performing inverse curvelet transform on the network output data. **[Results and Conclusions]** The processing results of simulation and actual data show that compared to conventional methods and ordinary convolutional networks, the method proposed in this study demonstrates superior attenuation effects on common noise (e.g., random noise) under different noise levels and scales, achieving higher signal-to-noise ratios and fidelity for seismic signals. This method, integrating the sparse representation of the Curvelet transform and the adaptability of deep learning models, provides a novel approach for the noise attenuation of seismic data.

Keywords: Seismic data denoising; Deep learning; U-net network; Curvelet transform; Attention mechanism

在地震数据处理中,噪声衰减是非常重要的步骤之一。在野外进行地震数据采集时,由于受到地形、环境、设备及人为因素等干扰,采集得到的地震数据中往往含有随机噪声、面波、声波、多次波等噪声影响,会干扰到数据分析和解释的准确性。因此,去除这些噪声,提高信噪比,能够更准确地对地下岩层进行分析解释。

目前,传统的噪声衰减方法主要是基于模型驱动类的方法,包括基于傅氏变换的滤波方法^[1],如 F-k 域滤波、聚束滤波、中值滤波、预测滤波等^[2];基于稀疏变换的去噪方法^[3],如小波变换^[4]、Curvelet 变换^[5]、Radon 变换^[6]、Seislet 变换^[7]等;基于模态分解类的方法,如经验模态分解(Empirical mode decomposition, EMD)方法^[8]、变分模态分解(Variational mode decomposition, VMD)方法^[9]等。但这些方法对模型的依赖程度很高,虽然具有可解释性,但是模型建立通常需要依赖先验信息,若先验信息不准确则模型将会出现较大误差;且通用性不强,建立的模型对新数据的适用性较差。

随着字典学习和深度学习研究的逐渐深入,数据驱动类方法为地震资料去噪引领了一个新的方向。基于压缩感知理论, M. Aharon 等^[10]使用字典代替传统变换域方法的基函数,通过在变换域中选择基函数的最佳组合分离噪声和有效信号。然而,字典学习仍然是基于稀疏性假设,为了获得良好的去噪质量,需要根据经验对参数进行微调。

随着深度学习的发展,神经网络作为一种机器学习算法出现在大众视野中,不断出现许多典型的神经网络结构,如 AlexNet^[11]、VGGNet (Visual geometry group network)^[12]、U-Net^[13]、ResNet (Residual network)^[14]、GAN^[15](Generative adversarial networks)、堆叠自编码器^[16]和深度置信网络^[17]等,这些网络在图像识别、医学成像、信号处理以及人工地震等领域发挥了巨大的作用。

近年来,深度学习在地震波初至拾取、地震数据去噪、插值、波场分离、数据压缩等方面^[18]均取得了显著的成效。在地震去噪方面,随着残差学习的去噪卷积神经网络(Denoising convolutional neural network, DnCNN)的提出^[14], DnCNN 网络被应用于对随机噪声、线性噪声、面波和多次波进行噪声衰减,与传统方法进行对比,具有更高的信噪比,并且能够自适应调节参数^[19]。随后,许多学者在 DnCNN 网络的基础上对地震去噪进行优化研究,提出三维去噪卷积神经网络(3-D denoising convolutional neural network, 3-D-DnCNN)^[20]、约束去噪卷积神经网络(Constrained denoising convolutional neural network, Constrained-DnCNN)^[21]、多尺度去噪卷积神经网络(Multiscale denoising convolutional neural network, MSDCNN)^[22]、多尺度卷积和密集连接去噪卷积神经网络(Multiscale convolution and densely connected denoising convolutional neural network, MCDDCNN)^[23]等。基于 U-net 网络^[13]的基本结构,地球物理方向的专家学者研究出了许多针对地震去噪方法进行优化的网络,例如,加入基于分支结构的去噪网络(Branch construction-based denoising network, BCD-Net)^[24]、增加 dropout 层的 U-net 网络^[25]、使用 Huber 范数约束替代 L2 范数约束作为误差函数的 Huber-U-Net 网络^[26]、结合 Res-Net 网络和 U-net 网络优势特点提出的 RU-net 卷积神经网络^[27]、在多级混叠噪声污染的数据集上进行训练的多尺度残差 U 形网络(Multiscale residual U-Net, MultiresUNet)^[28]等。除此之外,还有结合卷积神经网络(Convolutional neural network, CNN)和生成对抗网络(GAN)的深度卷积生成对抗网络(Deep convolutional generative adversarial network, DCGAN)^[29]、基于深度卷积自编码网络的数据驱动的去噪方法^[30]等。

上述基于深度学习的地震数据噪声衰减方法都是

依据地震资料中信号与噪声在时空域的分布特征不同, 利用深度神经网络训练和学习时空域的地震数据特征, 从而达到噪声压制的目的。然而将地震数据转换到变换域, 在变换域同样可利用深度学习进行去噪处理。例如通过短时傅里叶变换将时空域地震信号变换到时频域, 可以使用 DeepDenoiser 深度神经网络实现地震信号的去噪和分解^[31], 也可以使用 U-Net 网络在时频域实现地震数据的信噪分离^[32]; 利用短时离散余弦变换 (Short-time discrete cosine transform, STDCT) 得到时频域频谱, 基于 U-net 网络构建的有监督学习深度分段去噪神经网络 (Deep segmental denoising neural network, Deep Seg), 对比 DeepDenoiser 方法信噪比有显著提高^[33]。基于 U-Net 网络, 使用离散小波变换实现下采样操作的多级小波卷积神经网络 (Multi-level wavelet convolutional neural networks, MWCNN)^[34], 能够成功提取图像的频域特征; 利用二维小波域地震数据的稀疏性和多尺度性, 联合二维离散小波变换与 U-Net 网络得到的离散小波变换 U 形网络 (Discrete wavelet transform U-Net, Dwt-U-Net)^[35], 不仅能够提高信噪比, 并且能节约一半以上的网络训练及测试时间。基于注意力机制的 U-net 网络, 使用小波变换作为池化层, 逆小波变换 (Inverse Wavelet Transform, IWT) 用于上采样层提出的基于注意力的小波卷积神经网络 (Attention-based wavelet convolutional neural network, AWUN) 能够对不完整地震数据同时进行噪声衰减和重建的方法, 并且对信噪比和均方误差均有显著改善^[36]。

Curvelet 变换可以认为是小波变换的二维各向异性扩张, 具有多角度特性, 在一定程度上比小波变换去噪效果更好。因此, 基于以上学者的研究成果, 笔者利用 Curvelet 域地震数据具有稀疏性、多尺度性和方向性的特点, 使用加入卷积块和注意力模块 (Convolutional block attention module, CBAM) 的 U-net 网络, 建立了一套 Curvelet 域注意力机制 U-net 网络 (Curvelet domain attention mechanism U-net, Curvelet-AU-Net), 并与传统的模型驱动类去噪方法及普通的卷积神经网络进行理论模型测试及实际数据处理的对比分析, 对提出方法的有效性进行验证。

1 Curvelet-AU-Net 网络模型原理和方法

1.1 二维离散 Curvelet 变换基本原理

Curvelet 变换是由 E. J. Candès 等^[37]提出的一种具有多尺度多方向几何特性的新变换, 可以认为是小波原子的二维各向异性扩张。但第一代 Curvelet 变换的构造复杂, 冗余度高。于是 E. J. Candès 等提出了直接利用频域划分来构造 Curvelet 原子的方法, 即第二代

Curvelet 变换^[5]。

Curvelet 变换可以将地震信号的能量集中到某几个尺度和方向上, 能够减弱噪声, 提高噪声衰减效果。Curvelet-AU-Net 网络模型首先将地震数据从时空域通过 Curvelet 变换到 Curvelet 域, 随后再进行卷积网络的训练及测试。

图 1 为二维离散 Curvelet 变换在频域的分块, 在直角坐标系中, 空间变量为 $x = (x_1, x_2)$, 频域变量为 $\xi = (\xi_1, \xi_2)$, Curvelet 变换是将函数 $f(x)$ 与它的一个母函数 $\tilde{\varphi}_{j,k,l}$ 内积^[38], 即:

$$\tilde{c}(j, l, k) = \langle f, \tilde{\varphi}_{j,l,k} \rangle = \int_{\mathbb{R}^2} f(x) \overline{\tilde{\varphi}_{j,l,k}(x)} dx \quad (1)$$

Curvelet 变换的径向窗函数 $\tilde{W}_j(\xi)$ 和角度窗函数 $\tilde{V}_j(\xi)$ 的容许性条件为:

$$\tilde{W}_j(\xi) = \tilde{W}_j(2^{-j}\xi) \quad (2)$$

$$\tilde{V}_j(\xi) = \tilde{V}_j\left(\frac{2^{\frac{j}{2}}\xi_2}{\xi_1}\right) \quad (3)$$

则直角坐标系下的频域窗 \tilde{U}_j 定义为:

$$\tilde{U}_j(\xi) = \tilde{W}_j(\xi)\tilde{V}_j(\xi) \quad (4)$$

其在频率域的公式为:

$$\tilde{c}(j, l, k) = \int \tilde{f}(\xi) \tilde{U}_j(S_{\theta_j}^{-1}\xi) \exp(i\langle x_k^{(j,l)}, \xi \rangle) d\xi \quad (5)$$




图 1 二维离散 Curvelet 变换频域覆盖

Fig.1 Coverage of the 2D discrete curvelet transform in the frequency domain

1.2 CBAM 注意力机制

注意力机制的主要目的是聚焦图像的重要特征, 抑制不必要的区域响应。CBAM 是由 S. Woo 等^[39]提出的一种卷积神经网络注意力模块, 它融合了通道注意力机制和空间注意力机制, 具备简洁高效的特点。其结构如图 2 所示, 运算过程主要分为 2 个部分。

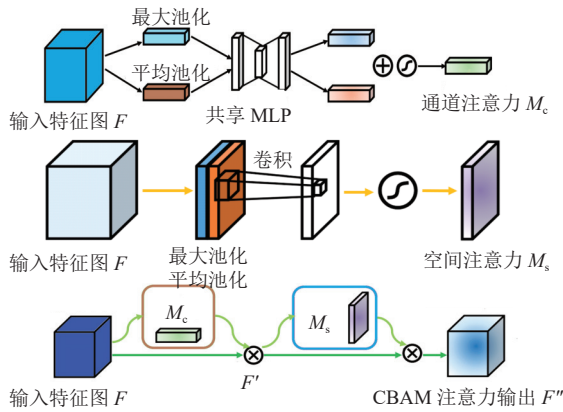


图 2 CBAM 注意力机制模型
Fig.2 CBAM model

首先,针对输入特征图的第一部分,通过对 $F \in \mathbb{R}^{C \times H \times W}$ 按照不同的通道进行全局最大池化和全局平均池化计算,生成 2 个一维向量,将这 2 个向量输入全连接层进行运算后相加,得到一维通道注意力 $M_c \in \mathbb{R}^{C \times 1 \times 1}$ 。然后,将通道注意力与输入的原始特征图相乘,得到经通道注意力调整后的特征图 F' 。

其次,第二部分对输入特征图 F' 按空间维度进行全局最大池化和均值池化,生成 2 个二维向量,将这 2 个向量拼接后进行卷积操作,最终生成二维空间注意力 $M_s \in \mathbb{R}^{1 \times H \times W}$ 。将空间注意力与经过通道注意力调整的特征图与 F' 按元素相乘,得到 CBAM 调整后的特征图 F'' 。

即, CBAM 生成注意力的过程可表示为:

$$F' = M_c(F) \otimes F \tag{6}$$

$$F'' = M_s(F') \otimes F' \tag{7}$$

其中,通道注意力公式为:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \tag{8}$$

空间注意力公式为:

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) \tag{9}$$

因此,任意给定一个中间特征图, CBAM 能将注意力沿特征图的通道与空间 2 个独立的维度进行映射,输入的特征图进行自适应特征细化,以提高网络的表示能力。

1.3 注意力机制 U-net 网络结构

U-Net 网络是由 O. Ronneberger 等^[13] 在 2015 年提出的一种对称网络,因为结构形似“U”型而得名,主要由卷积、池化、上采样和跳跃连接组成。该网络的压缩通道充当编码器,用于提取图像在不同层次上的结构特征,如边角、颜色、线条、纹理等;而扩展通道则相当于解码器,主要用于还原图像的结构信息。

Curvelet-AU-Net 神经网络中使用的加入了注意力机制的 U-Net 网络框架(图 3)。这个改进在原始 U-Net 网络的下采样之前引入了 CBAM 注意力模块。通过将 CBAM 模块融入 U-Net 网络,增强网络在通道和空间上的注意力,进一步提升网络的特征提取能力。这种改进的 U-Net 结构以增强注意力为基础,能更有效地捕捉图像中的关键信息。

1.4 Curvelet-AU-Net 网络模型架构

Curvelet-AU-Net 神经网络模型是基于 U-Net 神经网络模型进行改造的一种新模型,在预处理阶段将地震数据通过 Curvelet 变换得到 Curvelet 变换系数,然后再进行加入 CBAM 注意力机制的 U-net 神经网络模型训练及测试,因此称之为 Curvelet-AU-Net 神经网络模型。

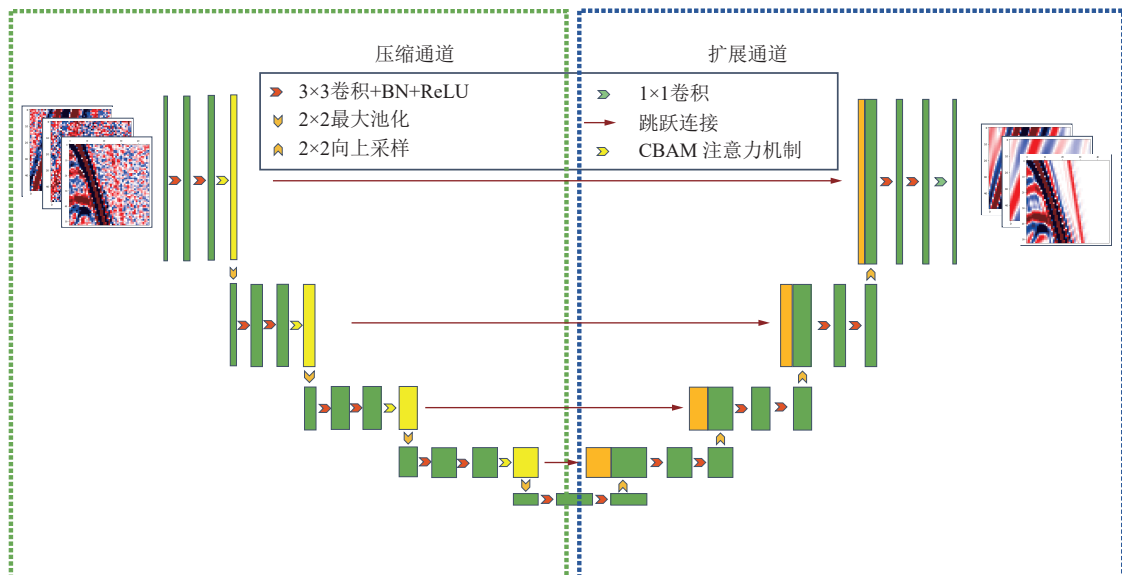


图 3 CBAM 注意力机制 U-Net 结构框架
Fig.3 U-Net structural framework with a CBAM

该网络对随机噪声进行噪声衰减的过程如图 4 所示。结合了 Curvelet 变换与注意力机制 U-Net 网络，首先，将含噪地震数据进行 Curvelet 变换，得到 Curvelet 变换系数，并分析有效信号和噪声在 Curvelet 域的分布情况。其次，采用注意力机制 U-Net 网络，以含噪地震数据的 Curvelet 变换系数作为输入数据，以无噪地震数

据的 Curvelet 变换系数作为标签，经过网络训练学习后，生成去噪结果。通过比较输出图像与标签的损失函数值，并逐层反向传播梯度值来更新网络参数，当损失函数值达到最小时，网络训练完成。最后，将测试集输入训练好的网络中，再对网络输出进行 Curvelet 反变换即可得到去噪结果。

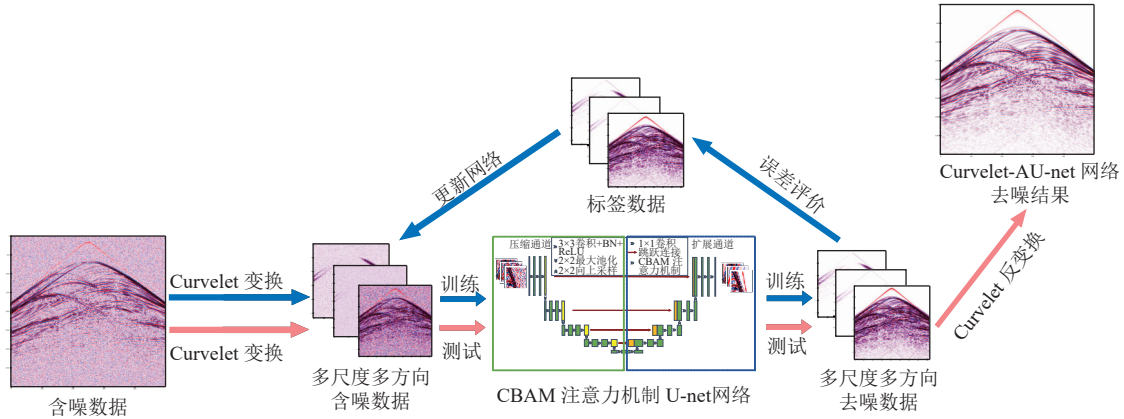


图 4 Curvelet-AU-Net 噪声衰减方法的去噪过程

Fig.4 Denoising process of the Curvelet-AU-Net noise attenuation method

2 模型实验及分析

2.1 地震数据预处理和数据集的构建

此次模型训练及测试均采用 marmousi 模型，共正演模拟了 51 幅不同炮点的单炮地震剖面，采样间隔为 1 ms，每炮 500 道，采样时间为 4 s。选取其中后 25 幅剖面制作训练集和标签，前 26 个剖面作为测试集。

Curvelet-AU-Net 网络随机噪声衰减方法首先对模型数据进行预处理，将后 25 幅测试单炮地震剖面 X_{train} 通过程序设计，加入噪声均值为 0，标准差范围在 0.1~0.5 的加权高斯随机噪声(Add weight gaussian random noise, AWGN)，含噪的样本 X_{noise} 信噪比位于 -5~12 dB。

$$X_{noise} = X_{train} + randn \times P_r \quad (10)$$

对地震数据整体加入随机噪声后，对标签数据和含噪数据进行 Curvelet 变换，将数据分为 3 个尺度，其中第二个尺度共有 8 个(1—8 角度)角度，第一个尺度以及第三个尺度不进行角度划分。第一个尺度的数据大小为 1 333×167，第二个尺度中 1、2、5、6 角度的数据大小为 1 167×333，第二尺度中 3、4、7、8 角度的数据大小为 2 667×146，第三个尺度的数据大小为 4 000×500。得到标签数据和含噪数据的 Curvelet 变换后，分析含噪数据在 Curvelet 不同尺度不同角度中分布情况发现，有效数据主要集中在第一个尺度中，故将第一个尺度中的数据划分成 64×64 的 11 375 个无噪-含噪样本对进行网络训练，训练集和标签如图 5 所示，训练时

训练集与验证集分别占 90% 和 10%。测试时将第一个尺度中的含噪数据输入 Curvelet-AU-Net 网络，得到第一个尺度的去噪结果，然后将其余尺度中的噪声进行赋零去除处理，最后将去噪之后的各个尺度及角度中的 Curvelet 域数据进行重构得到相应的去噪结果。




图 5 训练集及标签对比

Fig.5 Comparison of training and validation sets

2.2 注意力机制 U-net 模型训练

在进行网络训练的过程中，除了网络模型的搭建，还需要有大量的数据集充分挖掘模型中的非线性映射关系，在模型实验中，已经制作完成了第一个尺度需要的训练集和标签。在计算机硬件选择中，选择将训练集和数据标签封装之后，将模型从 CPU 上的运算调到 GPU 上运算，所采用 GPU 为 RTX 3060，运行内存为 6 GB，使用 Pytorch 软件的深度学习框架进行训练。在 64 位 Microsoft Windows11 的笔记本电脑上进行。

网络训练的参数设置为：① 学习率为 0.001；② 衰

减系数为 0.9, 采用多步长衰减, 衰减步长为 30、60、90; ③ 卷积核大小 3×3, 步长为 1; ④ 激活函数为 ReLU 函数; ⑤ 损失函数为 SmoothL1 损失函数; ⑥ 优化算法采用 Adam 随机梯度下降法; ⑦ 模型的训练次数设置为 100。

实验分别使用 DnCNN 网络、U-net 网络和新提出的 Curvelet-AU-Net 网络进行对比, 设置相同的训练集和标签、相同的超参数完成模型参数的学习和优化, 训练集和验证集的误差精度见表 1。整体分析来看, 3 种方法中 Curvelet-AU-Net 模型训练误差和验证误差, 泛化误差最小。

表 1 不同网络模型训练误差精度
Table 1 Training errors of different network models

网络训练模型	训练时间/s	训练集的误差/ 10^{-7}	验证集的误差/ 10^{-7}
Curvelet-AU-Net	2 969	0.678	1.417
DnCNN	2 761	2.081	2.699
U-net	3 944	1.152	1.792

在收敛速度方面, Curvelet-AU-Net 网络的收敛速度最快, 在 100 次的循环迭代中, 在第 3 次左右就能够实现收敛, 而 U-net 网络则需要第 10 次左右才能够收敛。在效率方面, 神经网络主要耗时在模型的训练上, 在实验中, Curvelet-AU-Net 网络进行 100 次训练迭代的时间为 2 969 s, 而普通 U-net 网络为 3 944 s。虽然 DnCNN 训练时间为 2 761 s, 但是在训练过程中能够看到 DnCNN 网络的误差曲线存在明显的振荡, 稳定性较差且误差相对较大, 而 Curvelet-AU-Net 网络和 U-net 网络的误差曲线较为平滑。

综上, Curvelet-AU-Net 网络模型在训练效率、收敛速度及误差精度上都具有优势, 能够提高去噪处理的效


率和误差精度。

2.3 Curvelet-AU-Net 模型测试结果分析

模型测试使用相同的 marmousi 模型正演地震测试数据, 使用传统的去噪方法(FxDecon 去噪、Curvelet 去噪)和普通的深度学习去噪方法(DnCNN 网络、U-net 网络)及新提出的 Curvelet-AU-Net 网络模型的去噪结果进行实验对比, 对 3 个不同炮点的单炮地震记录加入 3 种不同水平的高斯随机噪声, 共 9 组数据进行去噪处理。图 6、图 7 仅以加入随机噪声为 0.2 的 Test3 的测试数据为例进行对比分析。

图 6 为原始地震记录与分别使用 5 种不同方法进行去噪处理的结果剖面。对比分析可知, FXDECON 去噪、DnCNN 网络、Curvelet 去噪方法得到的剖面图 6b、图 6c、图 6d 还存在着明显的背景噪声, 随机噪声去除能力较弱, 而使用 U-net 网络、Curvelet-AU-Net 网络进行去噪的图 6e、图 6f 剖面的背景噪声去除较为完全, 无明显随机噪声。图 6b、图 6c、图 6d 局部放大的反射波同相轴较为模糊, 信噪比较低, 而图 6e 虽然较为清晰, 但是有效信号存在扰动, 保真度较低, 部分深部信号存在空白, 而 Curvelet 域 U-net 网络去噪结果优于其他几种方法, 反射波同相轴清晰, 连续性更好, 并且信噪比更高、保真度更好。

图 7 为使用 5 种不同方法进行去噪的残差剖面, 对比加入的随机噪声图 7a 可知, 图 7b 所示的 FXDECON 去噪方法对有效信号的损失最大, 图 7c 所示的 DnCNN 网络次之, 图 7e 所示的 U-net 网络模型去除的噪声中能够看到部分清晰的同相轴, 说明该模型对有效信号的损失较大, 而图 7f 构建的 Curvelet-AU-Net 网络几乎看不到清晰的地震记录同相轴, 对有效信号的损失较小。



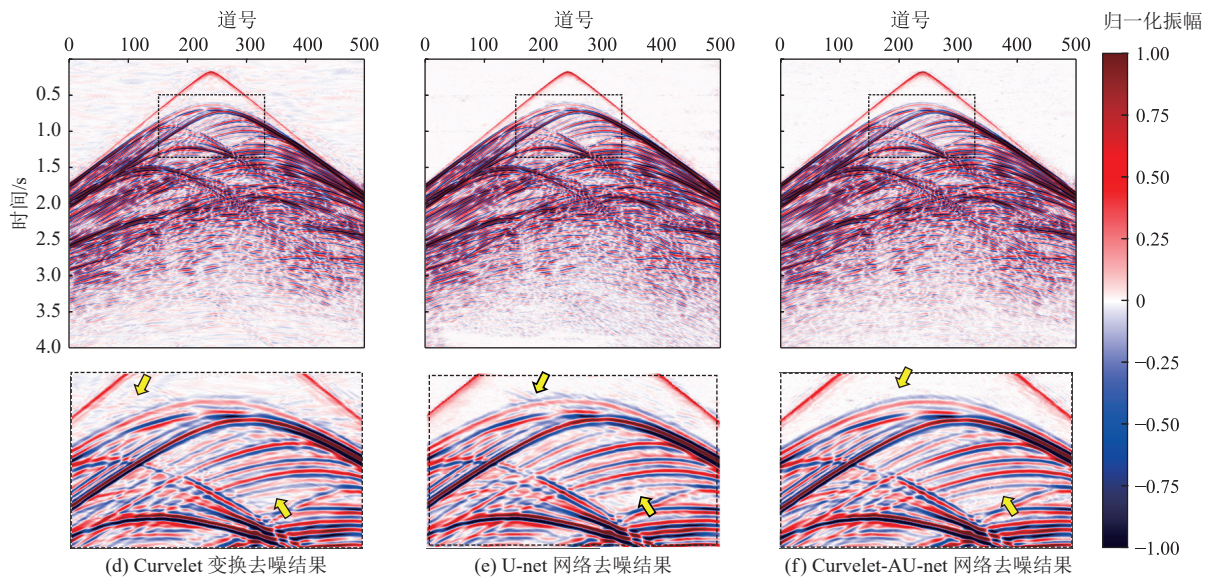


图 6 不同方法模拟数据去噪结果对比

Fig.6 Comparison of denoising results of simulated data based on different methods




图 7 不同方法模拟数据去噪结果残差剖面对比

Fig.7 Comparison of residual profiles for the denoising results of simulated data derived using different methods

为了对不同方法的去噪效果进行量化比较,分别计算了不同去噪方法在不同剖面加入不同程度噪声的信噪比(表 2)及结构相似度(表 3)。

通过对信噪比进行分析, Curvelet-AU-Net 网络去噪剖面的信噪比对比原始剖面的信噪比提高 14~20 dB, 低水平噪声衰减结果信噪比基本大于 20 dB, 且最高可达 27.97 dB。而 U-net 网络去噪剖面的信噪比提高 12~19 dB, Curvelet 去噪剖面的信噪比提高 12~17 dB, DnCNN

去噪剖面的信噪比提高为 9~17 dB, FxDecon 去噪方法去噪剖面的信噪比提高 3~11 dB, 总体来看, 所有的 Curvelet-AU-Net 网络去噪剖面的信噪比都优于其余 4 种方法, 对随机噪声的压制能力更强。

结构相似度是对图像的亮度、对比度、结构 3 个方面进行评估比较, 通过对去噪剖面的结构相似度进行计算, 可以看到 5 种方法的去噪剖面与无噪剖面的结构相似度都较高, 但是 Curvelet-AU-Net 网络去噪剖面的结

表 2 不同噪声水平下不同方法去噪结果的信噪比
Table 2 Signal-to-noise ratios of denoising results derived using different methods under different noise levels

测试剖面	加入噪声	信噪比/dB					
		含噪数据	FxDecon	DnCNN网络	Curvelet去噪	U-net网络	Curvelet-AU-Net
Test1	0.1	8.25	14.77	17.67	20.82	19.78	22.15
	0.2	2.23	11.90	15.76	16.62	17.73	19.00
	0.5	-5.73	3.21	11.36	11.71	13.06	14.34
Test2	0.1	11.52	15.94	21.10	23.83	22.91	25.19
	0.2	5.50	12.98	18.70	19.24	20.83	21.55
	0.5	-2.46	9.16	13.56	14.14	15.82	16.75
Test3	0.1	12.73	16.38	23.61	24.91	26.36	27.97
	0.2	6.71	13.52	20.68	21.09	23.32	23.64
	0.5	-1.25	9.84	15.19	16.03	17.43	18.38

表 3 不同噪声水平下不同方法去噪结果的结构相似度
Table 3 Structural similarity of denoising results derived using different methods under different noise levels

测试剖面	加入噪声	结构相似度					
		含噪数据	FxDecon	DnCNN网络	Curvelet去噪	U-net网络	Curvelet-AU-Net
Test1	0.1	0.970 0	0.992 0	0.997 0	0.997 6	0.997 9	0.998 4
	0.2	0.889 5	0.983 5	0.992 2	0.993 0	0.994 8	0.995 0
	0.5	0.555 9	0.865 3	0.969 4	0.973 5	0.978 8	0.983 3
Test2	0.1	0.971 4	0.989 0	0.996 6	0.997 4	0.997 3	0.998 1
	0.2	0.894 4	0.977 4	0.991 3	0.992 3	0.994 0	0.994 9
	0.5	0.570 9	0.942 1	0.965 1	0.970 2	0.976 6	0.980 7
Test3	0.1	0.971 1	0.987 2	0.996 6	0.997 4	0.997 3	0.998 1
	0.2	0.893 7	0.974 2	0.991 2	0.992 3	0.993 9	0.994 2
	0.5	0.568 7	0.935 9	0.966 1	0.970 7	0.976 0	0.980

构相似度与无噪剖面最为接近。

因此, Curvelet-AU-Net 网络去噪结果信噪比和结构相似度都具有明显的提升, 对比其他方法均具有明显优势, 去噪效果相对而言最好。综上所述, 提出的 Curvelet-AU-Net 网络去噪对于图像重建和地震数据信噪比的提升上都具有一定优势。

3 野外实测资料应用

3.1 数据准备及测试

为了进一步测试 Curvelet-AU-Net 网络的去噪性能, 将该方法应用于我国西部某油田的一条实测的叠后地震剖面, 剖面为 1 801 ms×1 435 道。该地区由于地形复杂, 施工成本高, 导致叠加次数较少, 信噪比较低。

实验用的地震叠后剖面如图 8 所示, 使用该剖面前 500 条道, 采样时间在 1 000~1 500 ms 的剖面数据用于模型的训练, 约占总剖面数据的 9.67%。并且从中选择了训练数据外的 4 组不同尺度大小的剖面数据用于模型的测试, 其中, 测试数据 4 为 1 801 ms×1 435 道全剖面数据。

由于野外资料都含有噪声, 难以从中找到完全无噪的数据作为标签进行有监督学习, 因此, 需要选择模型驱动类去噪方法对部分数据进行处理, 以构建 Curvelet-AU-Net 网络。在模型测试阶段可知, Curvelet 变化去噪虽然使用时对参数设置要求较高, 且运行速度对比深度学习较慢, 但是由于其具有多尺度性、多方向性、稀疏性, 去噪效果相对来说较好, 因此, 本次测试使用 Curvelet 变换对选定的 9.67% 的训练剖面数据进行去噪, 作为训练的标签, 以构建网络模型对全部的剖面数据中的随机噪声进行衰减。其中, 使用软阈值 Curvelet 去噪方法, 尺度数设置为 4, 角度数设置为 16。

训练数据集的构建方法及流程与模型测试部分相同, 通过 Curvelet 变换将数据分为 3 个尺度, 其中第二个尺度共有 8 个角度, 第一、第三尺度不进行角度划分。由于剖面的有效数据主要集中在第一个尺度, 故将 Curvelet 变换后第一个尺度中的数据划分成 64×64 的 10 816 个无噪-含噪样本对进行 Curvelet-AU-Net 网络的训练及验证。测试时将第一个尺度中的含噪测试数据输入 Curvelet-AU-Net 网络, 得到第一个尺度的去噪

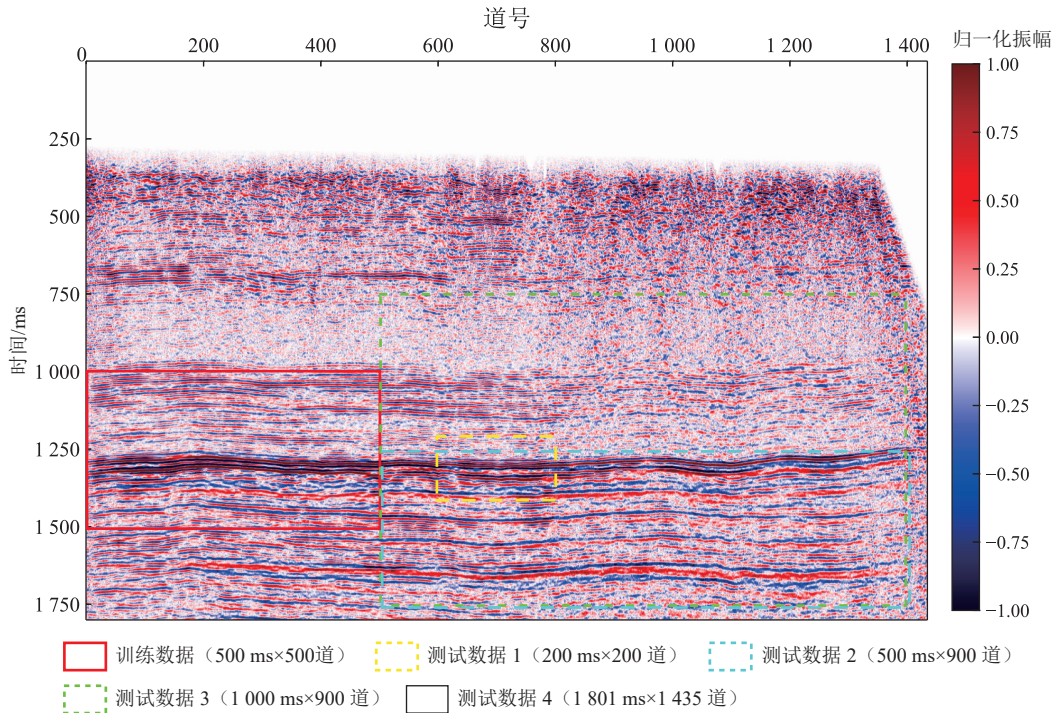


图 8 某油田叠后地震资料剖面
Fig.8 Profile of the post-stack seismic data of a certain oilfield

结果,将其余尺度中的噪声进行赋零去除处理,最后将去噪之后的各个尺度及角度中的 Curvelet 域数据进行重构可得到相应的去噪结果。

3.2 结果分析与模型评价

图 9a 为测试数据 2 的地震剖面,在图 8 中道号为 500~1 400 道,采样时间 1 250~1 750 ms,数据大小为 500 ms x 900 道,含有该油田的主要目标层。综合对比分析可知, DnCNN 网络去噪得到的剖面(图 9b)存在明

显的背景噪声,随机噪声去除能力较弱,而使用 U-net 网络、Curvelet-AU-Net 网络去噪的剖面(图 9c、图 9d)的背景噪声去除较为完全,无明显的随机噪声。通过局部放大的剖面可以看出,在叠加剖面的细节部分, Curvelet-AU-Net 网络对被噪声干扰部分的信号恢复效果更好,能量更为连续,这是因为普通的 U-net 网络在升维与降维时存在信号丢失,而加入了 Curvelet 变换的 U-net 网络能够对信号进行更有效的恢复,因此,同

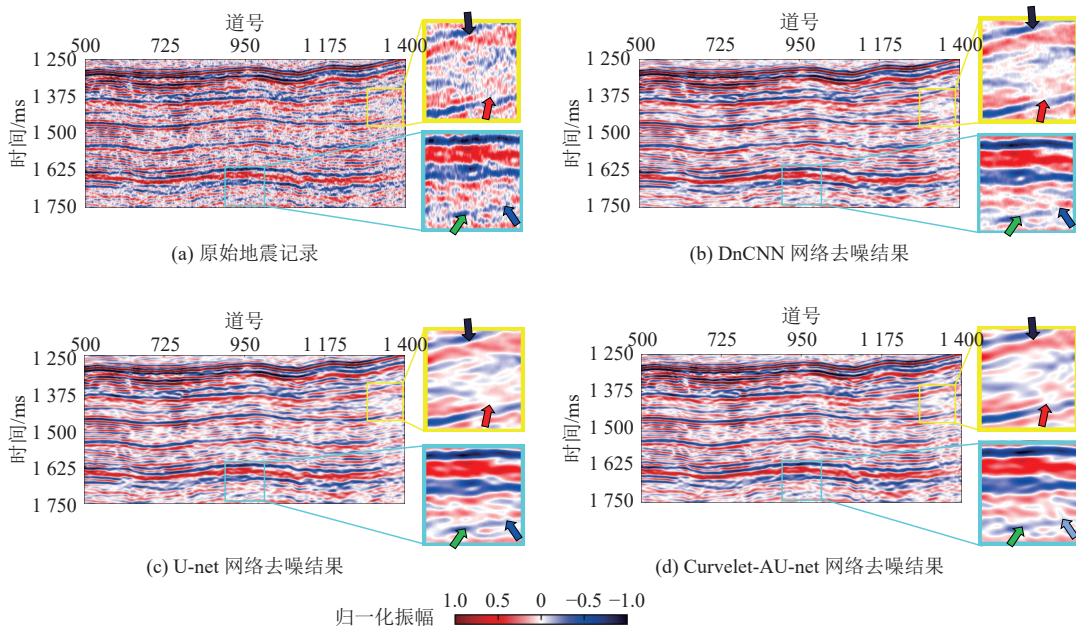


图 9 野外实测剖面不同方法去噪结果
Fig.9 Denoising results of field measured profiles derived using different methods

相轴表现得更连续,信噪比更高。

考虑到不同尺度大小的剖面的处理结果可能存在差异性,本次设置了 4 组不同大小的测试组进行测试分析,多种方法联合去噪后的结果比较理想,能够满足野外实测资料去噪要求,因此可以视为无噪数据,对 4 种不同的去噪结果计算信噪比(表 4)及结构相似度(表 5)来进行质量评价。对比分析可知,使用的 4 种方法对不

同尺度大小的地震剖面的信噪比和结构相似度都有了显著提升,当尺度越小时,信噪比提升越明显,尺度越大,信噪比提高幅度相对而言变小。但总体而言,实验中约 10% 的训练数据构建的 Curvelet-AU-Net 网络能够实现对整个剖面甚至更大的剖面数据进行高效率的去噪处理,并且去噪效果优于所选的其他几种前沿去噪方法。

表 4 不同尺度下采用不同方法去噪结果的信噪比
Table 4 Signal-to-noise ratios of denoising results derived using different methods under different scales

测试剖面	剖面大小	信噪比/dB				
		含噪数据	FXDECON	DnCNN网络	U-net网络	Curvelet-AU-Net网络
1	200 ms×200道	13.52	14.76	18.24	19.35	20.89
2	500 ms×900道	9.77	12.72	15.8	17.51	18.21
3	1 000 ms×900道	6.93	10.83	12.91	15.03	15.72
4	1 801 ms×1 435道	6.61	10.79	11.28	13.63	13.86

表 5 不同尺度下采用不同方法去噪结果的结构相似度
Table 5 Structural similarity of denoising results derived using different methods under different scales

测试剖面	剖面大小	结构相似度				
		含噪数据	FXDECON	DnCNN网络	U-net网络	Curvelet-AU-Net网络
1	200 ms×200道	0.788 7	0.818 8	0.903 4	0.923 4	0.92 37
2	500 ms×900道	0.703 4	0.801 9	0.879 1	0.912 8	0.919 0
3	1 000 ms×900道	0.620 3	0.762 5	0.818 2	0.873 8	0.877 6
4	1 801 ms×1 435道	0.689 0	0.798 1	0.818 2	0.872 3	0.873 3

4 结论

(1) 提出一种基于 Curvelet 域注意力机制卷积网络(Curvelet-AU-Net)的地震数据噪声衰减新方法,融合了 Curvelet 变换和注意力 U-Net 网络的优势。

(2) 该方法将地震数据转换到具有稀疏性、多尺度性和方向性特征的 Curvelet 域,并结合 U-Net 网络的自适应调参和注意力增强机制,实现了常见噪声的高效分离和衰减。

(3) 模拟数据和实际油田数据实验表明:该方法对常见噪声(如随机噪声等)的衰减效果较传统方法和普通卷积网络更优,获得的信号信噪比和保真度更高。

符号注释:

BN(Batch normalization)为批标准化; \tilde{c} 为 Curvelet 变换后的曲波系数; C 、 H 、 W 分别为图像的通道数、高度和宽度; F 为输入特征图; F' 为经通道注意力调整后的特征图; F'' 为经空间注意力调整后的特征图; f 为输入的地震信号; $f^{7 \times 7}$ 为卷积核大小为 7×7 的卷积运算; i 为虚数单位; j 为尺度因子; k 为位置参数; l 为方向参数; P_r 为加入噪声占最大归一化振幅的比例,文中设置

为 0.1~0.5; R^2 表示二维欧几里得实数空间; \mathbb{R} 为实数域; M_c 为一维通道注意力; M_s 为二维空间注意力; S_θ 为剪切矩阵, $S_\theta = \begin{pmatrix} 1 & 0 \\ -\tan\theta & 1 \end{pmatrix}$; $S_{\theta,l}^{-1}$ 为在 j 尺度, l 方向上剪切矩阵的逆矩阵; $\tilde{W}_j(\xi)$ 为径向窗函数; $\tilde{V}_j(\xi)$ 为角度窗函数; X_{noise} 为含噪的地震数据; X_{train} 为无噪的原始地震记录; x 为空间变量; ξ 为频域变量; x_k 为旋转矩阵的逆; $\tilde{\varphi}_{j,k,l}$ 为母函数; $\tilde{\varphi}_{j,k,l}^*$ 为母函数的共轭复数; σ 为 sigmoid 激活函数;AvgPool 为平均池化;MaxPool 为最大池化;MLP 为多层感知机;randn 为产生正态分布的二维随机数矩阵的函数。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

参考文献(References)

- [1] 张军华,吕宁,田连玉,等.地震资料去噪方法技术综述[J].地球物理学进展,2006,21(2):546-553.
ZHANG Junhua, LÜ Ning, TIAN Lianyu, et al. An overview of the methods and techniques for seismic data noise attenuation[J]. Progress in Geophysics, 2006, 21(2): 546-553.

- [2] 国陇予, 刘财, 刘洋. 滤波类方法衰减地震数据噪声[J]. 地球物理学进展, 2018, 33(5): 1890–1896.
GUO Longyu, LIU Cai, LIU Yang. Filtering methods attenuate seismic data noise[J]. *Progress in Geophysics*, 2018, 33(5): 1890–1896.
- [3] 张博. 基于稀疏变换的地震数据去噪方法研究[D]. 杭州: 浙江大学, 2013.
ZHANG Bo. Research of seismic data denoising methods based on sparse transform[D]. Hangzhou: Zhejiang University, 2013.
- [4] 朱光明, 高静怀, 王玉贵. 小波变换及其在一维滤波中的应用[J]. 石油物探, 1993, 32(1): 1–10.
ZHU Guangming, GAO Jinghuai, WANG Yugui. Wavelet transform and its application to 1-d filtering[J]. *Geophysical Prospecting for Petroleum*, 1993, 32(1): 1–10.
- [5] CANDÈS E, DEMANET L, DONOHO D, et al. Fast discrete curvelet transforms[J]. *Multiscale Modeling & Simulation*, 2006, 5(3): 861–899.
- [6] 胡浩. Radon 变换及其在地震资料去噪中的应用研究[D]. 成都: 成都理工大学, 2014.
HU Hao. Research on radon transform and its application in seismic data noise elimination[D]. Chengdu: Chengdu University of Technology, 2014.
- [7] 刘洋, FOMEL Sergey, 刘财, 等. 高阶 seislet 变换及其在随机噪声消除中的应用[J]. 地球物理学报, 2009, 52(8): 2142–2151.
LIU Yang, SERGEY F, LIU Cai, et al. High-order seislet transform and its application of random noise attenuation[J]. *Chinese Journal of Geophysics*, 2009, 52(8): 2142–2151.
- [8] 颜中辉, 栾锡武, 王赟, 等. 基于经验模态分解的分数维地震随机噪声衰减方法[J]. 地球物理学报, 2017, 60(7): 2845–2857.
YAN Zhonghui, LUAN Xiwu, WANG Yun, et al. Seismic random noise attenuation based on empirical mode decomposition of fractal dimension[J]. *Chinese Journal of Geophysics*, 2017, 60(7): 2845–2857.
- [9] 胡瑞卿, 何俊杰, 李华飞, 等. 时频域变分模态分解地震资料去噪方法[J]. 石油地球物理勘探, 2021, 56(2): 257–264.
HU Ruiqing, HE Junjie, LI Huafei, et al. Seismic data de-noising method based on VMD in time-frequency domain[J]. *Oil Geophysical Prospecting*, 2021, 56(2): 257–264.
- [10] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311–4322.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84–90.
- [12] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[M/OL]. arXiv, 2015. <http://arxiv.org/abs/1409.1556>.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[M]//Lecture notes in computer science. Cham: Springer International Publishing, 2015: 234–241.
- [14] ZHANG Kai, ZUO Wangmeng, CHEN Yunjin, et al. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising[J]. *IEEE Transactions on Image Processing*, 2017, 26(7): 3142–3155.
- [15] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview[J]. *IEEE Signal Processing Magazine*, 2018, 35(1): 53–65.
- [16] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. *Journal of Machine Learning Research*, 2010, 11: 3371–3408.
- [17] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, 18(7): 1527–1554.
- [18] YU Siwei, MA Jianwei. Deep learning for geophysics: Current and future trends[J]. *Reviews of Geophysics*, 2021, 59(3): e2021RG000742.
- [19] YU S, MA J, WANG W. Deep learning for denoising[J]. *GEO-PHYSICS*, 2019, 84(6): V333–V350.
- [20] LIU Dawei, WANG Wei, WANG Xiaokai, et al. Poststack seismic data denoising based on 3-D convolutional neural network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(3): 1598–1629.
- [21] 张超铭, 文晓涛, 张晓琦, 等. 基于 DnCNN 与约束卷积的地震数据去噪方法[J/OL]. 地球物理学进展, 2022; 1–18. (2022-03-18). <https://kns.cnki.net/kcms/detail/11.2982.P.20220316.1806.032.html>.
ZHANG Chaoming, WEN Xiaotao, ZHANG Xiaoqi, et al. Seismic data denoising method based on DnCNN and constrained convolution[J/OL]. *Progress in Geophysics*, 2022; 1–18. (2022-03-18). <https://kns.cnki.net/kcms/detail/11.2982.P.20220316.1806.032.html>.
- [22] ZHONG Tie, CHENG Ming, DONG Xintong, et al. Seismic random noise attenuation by applying multiscale denoising convolutional neural network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5905013.
- [23] GUO Liang, LUO Renze, LI Xingyu, et al. Seismic random noise removal based on a multiscale convolution and densely connected network for noise level evaluation[J]. *IEEE Access*, 2022, 10: 13911–13925.
- [24] LIN Hongbo, WANG Shifu, LI Yue. A branch construction-based CNN denoiser for desert seismic data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(4): 736–740.
- [25] BAI Tingting, ZHAO Haixia, WANG Zhiqiang. A U-net based deep learning approach for seismic random noise suppression[C]//IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium. Kuala Lumpur, Malaysia. IEEE, 2022: 6165–6168.
- [26] 欧炳霖, 曾同生, 柳天成, 等. 基于 Huber-U-Net 网络的地震数据重建与去噪[J]. 地球物理学进展, 2023, 38(6): 2540–2552.
OU Binglin, ZENG Tongsheng, LIU Tiancheng, et al. Seismic data reconstruction and de-noising based on Huber-U-Net network[J]. *Progress in Geophysics*, 2023, 38(6): 2540–2552.
- [27] 罗仁泽, 李阳阳. 一种基于 RUnet 卷积神经网络的地震资料随机噪声压制方法[J]. 石油物探, 2020, 59(1): 51–59.
LUO Renze, LI Yangyang. Random seismic noise attenuation

- based on RUnet convolutional neural network[J]. *Geophysical Prospecting for Petroleum*, 2020, 59(1): 51–59.
- [28] WANG Yu, SHAO Zhenfeng, LU Tao, et al. Remote sensing image super-resolution *via* multiscale enhancement network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 3248069.
- [29] 俞若水, 张勇, 周创. 基于深度卷积生成对抗网络的瑞雷波信号随机噪声去除[J]. *地球物理学进展*, 2020, 35(6): 2276–2283.
YU Ruoshui, ZHANG Yong, ZHOU Chuang. Deep convolutional generative adversarial network for random noise attenuation in Rayleigh wave signal[J]. *Progress in Geophysics*, 2020, 35(6): 2276–2283.
- [30] 滑世辉, 韩立国. 基于深度卷积自编码网络地震数据去噪方法[J]. *地球物理学进展*, 2023, 38(2): 654–661.
HUA Shihui, HAN Ligu. Seismic data denoising method based on deep convolutional auto-encoder network[J]. *Progress in Geophysics*, 2023, 38(2): 654–661.
- [31] ZHU Weiqiang, MOUSAVI S M, BEROZA G C. Seismic signal denoising and decomposition using deep neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(11): 9476–9488.
- [32] CHIRTU M A, RADOI A. Seismic signal denoising using U-net in the time-frequency domain[C]//2022 45th International Conference on Telecommunications and Signal Processing (TSP). Prague, Czech Republic. IEEE, 2022: 6–10.
- [33] IQBAL N. DeepSeg: Deep segmental denoising neural network for seismic data[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(7): 3397–3404.
- [34] LIU Pengju, ZHANG Hongzhi, LIAN Wei, et al. Multi-level wavelet convolutional neural networks[J]. *IEEE Access*, 2019, 7: 74973–74985.
- [35] 邱怡, 包乾宗, 马铭, 等. 基于 U-Net 网络的二维小波域地震数据随机噪声衰减[J]. *石油物探*, 2023, 62(5): 878–890.
QIU Yi, BAO Qianzong, MA Ming, et al. Seismic data random noise attenuation using U-Net network in the 2D discrete wavelet domain[J]. *Geophysical Prospecting for Petroleum*, 2023, 62(5): 878–890.
- [36] DODDA V C, KURUGUNTLA L, MANDPURA A K, et al. Simultaneous seismic data denoising and reconstruction with attention-based wavelet-convolutional neural network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5908814.
- [37] CANDÈS E J, DONOHO D L. New tight frames of curvelets and optimal representations of objects with C2 singularities[J]. *Communications on Pure and Applied Mathematics*, 2004, 57(2): 219–266.
- [38] 包乾宗, 陈文超, 高静怀. 基于第二代 Curvelet 变换的地震资料随机噪声衰减[J]. *煤田地质与勘探*, 2010, 38(1): 66–70.
BAO Qianzong, CHEN Wenchao, GAO Jinghuai. Seismic data random noise attenuation based on the second generation Curvelet transform[J]. *Coal Geology & Exploration*, 2010, 38(1): 66–70.
- [39] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[M]//Computer vision—ECCV 2018. Cham: Springer International Publishing, 2018: 3–19.

(责任编辑 聂爱兰)