

文章编号: 1671-7449(2024)02-0210-11

# 基于多阶段渐进式UNet压制地震勘探随机噪声

贺守峰, 李光辉, 宁旭亮

(山西大学 物理工程学院, 山西 太原 030006)

**摘要:** 数据处理是地震勘探的关键环节, UNet网络作为典型的神经网络架构之一, 近年来也被用于地震勘探领域, 作为一种压制随机噪声的手段。UNet网络基于其对称的编码和解码结构, 可以提取广泛的上下文信息, 但由于其编码部分过度使用下采样操作, 容易丢失输入图像的空间细节部分。其次, UNet架构是一种单阶段模型, 网络结构简单, 在空间精确度和多尺度信息之间难以达到平衡。基于此, 提出多阶段渐进式UNet网络(MPUNet), 网络前两个阶段采用编码器-解码器学习丰富的多尺度信息, 最后一个阶段通过原始分辨率子网络保留精确的空间细节。每两个阶段之间引入监督注意模块, 用来重新校准进入下一阶段的特征, 以及引入跨阶段特征融合机制, 使整个网络框架连接更加紧密, 避免有效信息的丢失。人工合成记录和实际地震数据实验结果表明: 相比于时频峰值滤波(TFPF)、残差密集网络(RDNet)、传统UNet和加入残差密集块的UNet(RDBUNet), MPUNet具有更显著的去噪效果, 能够有效提高地震数据的信噪比和分辨率, 为后续地震资料的分析解释提供了有利的依据。

**关键词:** UNet; 噪声压制; MPUNet; 神经网络; 地震勘探

**中图分类号:** TN911.7 **文献标识码:** A **doi:** 10.3969/j.issn.1671-7449.2024.02.015

**引用格式:** 贺守峰, 李光辉, 宁旭亮. 基于多阶段渐进式UNet压制地震勘探随机噪声[J]. 测试技术学报, 2024, 38(2):210-220.

HE Shoufeng, LI Guanghui, NING Xuliang. Suppressing random noise in seismic exploration based on multi-stage progressive UNet[J]. Journal of Test and Measurement Technology, 2024, 38(2):210-220.

## Suppressing Random Noise in Seismic Exploration Based on Multi-Stage Progressive UNet

HE Shoufeng, LI Guanghui, NING Xuliang

(College of Physical and Electronic Engineering, Shanxi University, Taiyuan 030006, Shanxi, China)

**Abstract:** Data processing is a key link in seismic exploration, and the UNet network, as one of the typical neural network architectures, has also been used in the field of seismic exploration in recent years as a means of suppressing random noise. The UNet network is based on its symmetric encoding and decoding structure, which can extract a wide range of contextual information. However, due to the excessive use of down-sampling operations in its encoding part, it is easy to lose the spatial details of the input image. Secondly, the UNet architecture is a single-stage model with a simple network structure, making it difficult to achieve a balance between spatial accuracy and multi-scale information. Based on this, a multi-stage progressive UNet network (MPUNet) is proposed. The first two-stages of the network use an encoder-decoder to learn rich multi-scale information, and the last stage preserves accurate spatial details through

收稿日期: 2023-05-11

基金项目: 山西省自然科学基金面上资助项目(202103021224012)

作者简介: 贺守峰(1998-), 女, 汉, 硕士生, 主要从事地震信号处理的研究。E-mail: 2391176753@qq.com。

the original resolution sub network. Introducing supervised attention modules between each two-stages to recalibrate features entering the next stage, and introducing cross stage feature fusion mechanisms to make the entire network framework more tightly connected and avoid the loss of effective information. The experimental results of artificial synthetic records and actual seismic data show that compared to time-frequency peak filtering (TFPF) and residual dense networks (RDNet), traditional UNet and UNet with residual dense blocks (RDBUNet), MPUNet has a more significant denoising effect, which can effectively improve the signal-to-noise ratio and resolution of seismic data, providing a favorable basis for subsequent analysis and interpretation of seismic data.

**Key words:** UNet; noise suppression; MPUNet; neural networks; seismic exploration

## 0 引言

在地震信号处理中,噪声压制一直是一项关键任务。由于地震资料中的随机噪声与有效信号相互混叠,如何在有效压制随机噪声的同时不损伤有效信号,是地震数据处理的一个难点,也是保证后续地震资料高准确度的基础工作。

为了提高地震数据的信噪比,科研工作者提出一系列噪声压制的方法。常用的去噪方法有: $f-k$ 域滤波<sup>[1]</sup>、时频峰值滤波(TFPF)<sup>[2,3]</sup>、小波变换<sup>[4]</sup>、曲波变换<sup>[5]</sup>、奇异值分解(SVD)<sup>[6]</sup>等。 $f-k$ 域滤波法去噪原理是利用有效波和各种噪声,视速度不同的性质去噪,但 $f-k$ 域滤波会出现空间假频现象,影响后续地震资料的处理。时频峰值滤波可以分为两个步骤,先对含噪信号进行调制编码,然后再对瞬时频率做出估计。存在的一个问题是TFPF中单一窗长会损失部分有效信号,信号的波形会产生畸变,不能达到很好的去噪效果。变换域滤波法的基本思想是地震数据中的有效信号和干扰波在某一个域空间有明显的差异,先将原始数据变换到这一域中,通过设置一个合适的阈值,最大化地分离噪声和有效信号。奇异值分解是基于有效信号和噪声的能量大小不同,一般假定认为大的奇异值表示有效信号,小的奇异值表示噪声。但当地震数据所含噪声的能量很大或者秩的选择不合适时,很难将有效信号和噪声分离。这些传统地震去噪算法在一定程度上可以衰减噪声,但都存在自身的局限性,需要很多滤波约束条件或者需要设置合适的参数。

随着神经网络在图像去噪<sup>[7-9]</sup>、语音识别<sup>[10]</sup>以及医学领域<sup>[11]</sup>都表现出不错的效果,也打开了地震勘探领域的新思路。例如:韩卫雪等<sup>[12]</sup>将深度学习卷积神经网络用于地震数据随机噪声的压

制,得到了比传统算法更好的去噪效果;王钰清等<sup>[13]</sup>提出数据增广和CNN网络方法,利用U型神经网络(UNet)有效去除了地震记录中的随机噪声;李海山等<sup>[14]</sup>基于残差网络(RESNet)做了进一步的改进,实现了对叠前地震数据中随机噪声的压制;Zhang等<sup>[15]</sup>设计出一种残差密集块(RDB),这种连接结构有利于提取更丰富的局部特征,进而提高了图像分辨率;Gao等<sup>[16]</sup>基于残差密集块提出一种新颖模型DnRDB用于去除地震记录中的噪声,该网络将多个RDB模块串联,可以充分提取地震数据中有效信号对应的特征,提高了地震资料的信噪比。Cai等<sup>[17]</sup>基于U-Net网络结合残差密集块设计了一种地震同带去噪模型,为了解决现有地震信号去噪方法在去除同带噪声时波形失真的问题。

UNet作为在地震数据处理中广泛使用的网络,其对称的编码与解码部分以及特征拼接操作能够有效提取广泛的上下文信息,但由于其频繁使用下采样操作,容易丢失部分空间细节。为了解决这一问题,有一些去噪模型是将UNet架构与一些功能单元,比如残差学习,密集连接等搭建在一起。然而这些去噪模型都是基于单阶段设计的,网络结构简单,难以在空间精确度和多尺度信息之间取得复杂平衡。

本文基于此,将UNet网络和原始分辨率子网(ORSNet)相结合,提出多阶段渐进网络(MPUNet),并将其应用于地震勘探随机噪声压制中。网络共包含3个阶段,前两个阶段是基于UNet的编码器-解码器结构,为了提取丰富的上下文信息,最后阶段通过原始分辨率子网保留输入图像的空间细节。阶段之间引入跨阶段特征融合,整合了网络框架,简化了信息流,上一阶段学习到的特征可以丰富下一阶段的特征。通过加入监督注意模块,有利于提高网络去噪性能,最大程度

地恢复出原始信号。

### 1 方法原理

#### 1.1 UNet网络结构

UNet 网络是基于对称的收缩通道和扩展通道，并通过跳跃连接构成的体系架构，典型的UNet结构如图 1 所示。其中，编码部分通过重复使用 $3\times 3$ 的

卷积层，ReLU 激活函数和 $2\times 2$ 的最大池化层对输入图像进行特征提取，每经过一次下采样操作，特征图维度变为原来的 $1/2$ ，通道数变为原来的2倍。解码部分的主要作用是将编码后的低分辨率表示，通过转置卷积反向映射恢复高分率，收缩通道和扩展通道之间通过一组跳跃连接，将低分辨率和高分率特征进行融合，允许模型更好地捕捉图像中的局部特征和全局特征。




图 1 UNet网络结构

Fig. 1 UNet network structure

#### 1.2 原始分辨率子网(ORSNet)

原始分辨率子网由3个原始分辨率块(ORB)组成，每个ORB又包含8个通道注意模块(CAB)和一个卷积层，ORB模块与其内部CAB模块的结构如图 2 所示。通道注意模块由4个 $3\times 3$ 卷积层、1个全局平均池化层和3个激活函数构成，目的在于提高有用特征的代表能力。该子网不再进行任何下采样过程，可以保留具有高分辨率的空间细节。




图 2 原始分辨率块

Fig. 2 Original resolution block

#### 1.3 MPUNet网络结构

MPUNet的网络结构如图 3 所示，网络共包含3个阶段，是一个由粗到细的去噪过程。网络的输入基于多补丁分层模型<sup>[18]</sup>，将含噪数据划分为互不重叠的几个补丁。第1个阶段将含噪数据分为4个补丁；第2个阶段分为2个补丁；第3个阶段输入为原图。网络早期的两个阶段采用基于标准UNet网络的编码器-解码器结构，但在其编码和解码的每一层都加入2个CAB模块，充分提取每一个尺度的有用特征。传统UNet网络的解码部分使用反卷积进行上采样操作，反卷积的不均匀重叠会引起棋盘效应，可能导致在去噪地震记录中的同相轴附近出现假轴。为了减少这种现象，改进的UNet结构中解码器不在使用反卷积操作，而是采用双线性插值上采样和卷积层来恢复空间分辨率。第3个阶段将输入与ORSNet连接，提取高分率特征，保留输入图像的空间细节部分。3个阶段不是独立存在，每两个阶段之间引入

监督注意模块(SAM)加权有用特征,并通过跨阶段特征融合机制(CSFF)紧密级联起来,CSFF如图3中虚线所示。MPUNet网络中SAM和CSFF

中的卷积层是 $1\times 1$ 的,其它所有卷积层都是 $3\times 3$ 的。

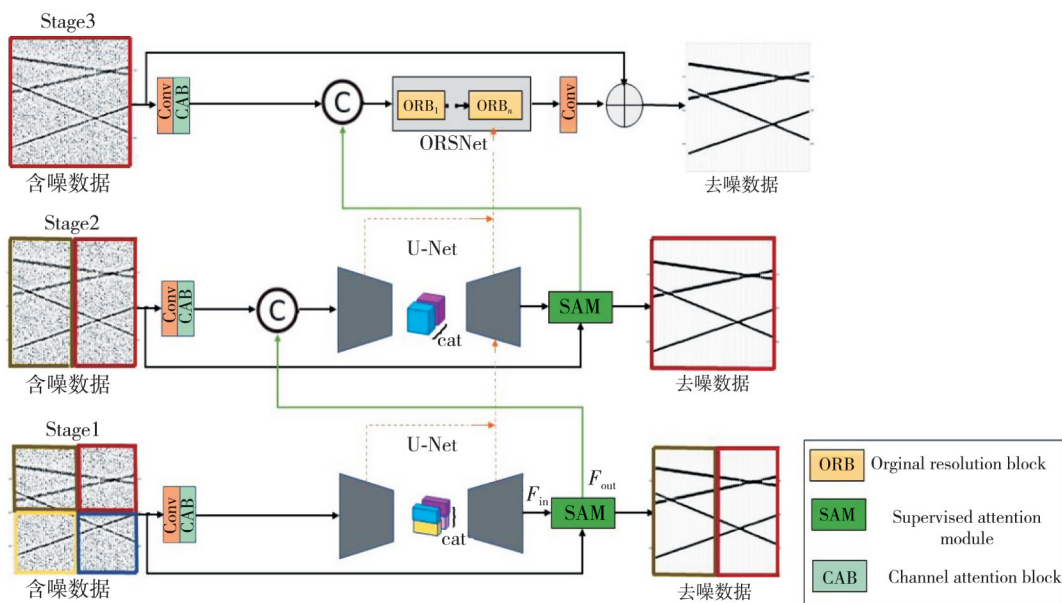


图3 MPUNet网络结构

Fig. 3 MPUNet network structure

在第1, 2两个阶段的UNet, 以及第2阶段的UNet和第3阶段的ORSNet之间, 都引入跨阶段特征融合机制, 分别如图4所示。具体操作方法是

将UNet编码器和解码器的输出都先经过一个 $1\times 1$ 的卷积层, 将提取到的所有特征进行细化, 之后再

两部分特征融合到下个阶段进行处理。跨阶段特征融合可以充分结合每一阶段提取到的特征进行学习, 避免信息丢失, 也增大了网络的健壮性。同时使阶段之间的信息流动更加清晰明确, 分析网络故障、增减网络阶段个数的难度降低。

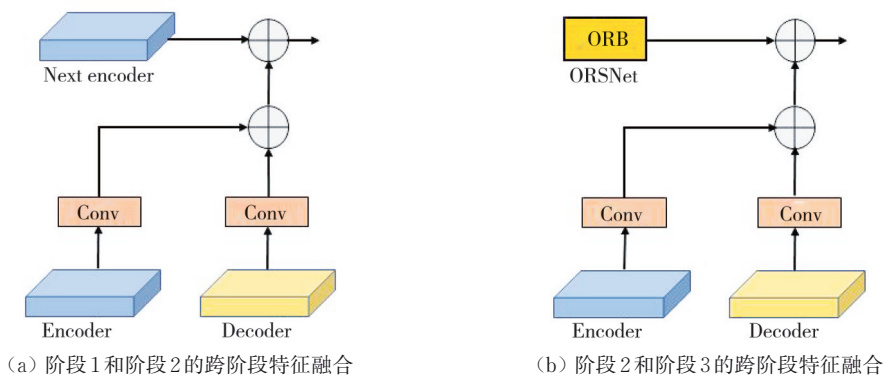


图4 跨阶段特征融合

Fig. 4 Cross stage feature fusion

在前两个阶段的编码器-解码器子网络后面各连接一个SAM, 结构图如图5所示。

SAM首先将前一模块的输出特征 $F_{in}$ 经过一个 $1\times 1$ 的卷积网络生成残差图像 $R_s$ , 含噪地震记录通过对残差图像的学习, 得到去噪后的记录 $X_s$ 。消噪后的地震记录经过简单的 $1\times 1$ 卷积和

Sigmoid函数激活后可以对特征进行重新校准, 抑制无用特征, 只允许有效信号对应的特征进入到下一个阶段, 提高网络去噪性能。

3个阶段通过监督注意模块和跨阶段特征融合机制紧密级联起来, 充分利用到每个阶段提取到的特征信息, 达到更好的学习效果。

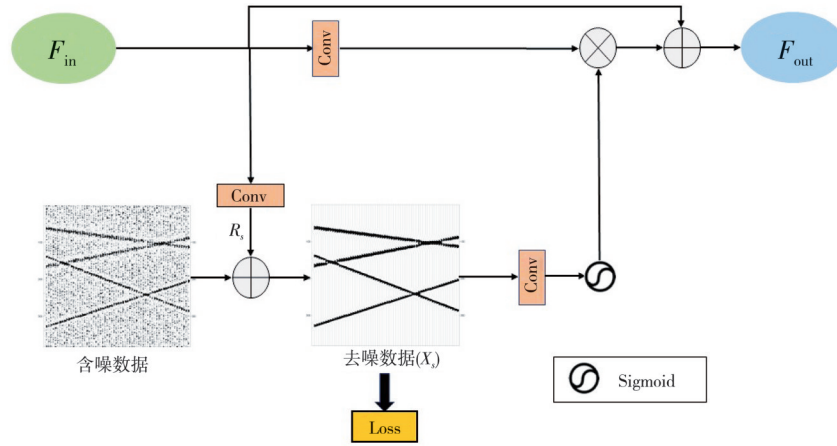


图5 监督注意模块

Fig. 5 Supervised attention module

## 2 MPUNet去噪原理

地震数据随机噪声压制是从噪声和信号混合的地震记录中将噪声除去,带有噪声的地震数据可以表示为

$$d = x + n, \quad (1)$$

式中:  $d$  为含噪数据;  $x$  为纯净地震信号;  $n$  为随机噪声。本文采用噪声学习法,将含噪地震记录输入神经网络MPUNet中,通过残差学习训练得到网络输出为预测噪声,然后用输入网络的含噪地震记录减去预测噪声得到去噪后的地震记录。具体过程为

$$Nt = R(d; \theta), \quad (2)$$

$$\hat{x} = d - Nt, \quad (3)$$

式中:  $Nt$  是网络输出的预测噪声;  $R$  是残差映射过程;  $\theta$  是网络的参数,包括权重  $\omega$  和偏置项  $b$ ;  $\hat{x}$  代表预测地震记录。选择由纯净噪声和预测噪声的均方误差(MSE)作为损失函数优化参数。损失函数表达式为

$$L_{\text{loss}}(\theta) = \frac{1}{M} \sum_{i=1}^M \|R(d_i; \theta) - n_i\|_{\text{MPUNet}}^2, \quad (4)$$

式中:  $M$  是训练集样本的个数;  $\|\cdot\|_{\text{MPUNet}}^2$  是 Frobenius 范数;  $d_i$  是含噪地震数据;  $n_i$  是纯净噪声。损失函数是一个非负实值函数,不断训练网络就是为了让损失函数达到最小值,  $L_{\text{loss}}(\theta)$  越小,说明预测噪声和实际噪声的误差越小,得到的去噪后的地震记录越接近理想地震记录。

本文训练网络使用的数据集来自 Model94\_shots.segy, 这是1994年的加拿大逆掩岩综合数据集,将大小不同的高斯白噪声加入到数据集构成含噪数据,作为网络的输入。该数据集一共有

278炮,通过32的滑动步长将数据划分为  $64 \times 64$  的分块(patch size)大小,经过归一化后生成包含41776个样本的数据集,其中31656个样本用于训练,10120个样本用于测试。网络的训练过程选择MSE作为损失函数,使用Adam优化算法,设置训练轮数(epoch)为60,批次(batch size)大小设置为8,学习率从  $2e-4$  逐渐降低到  $2e-6$ 。本实验是在Pytorch深度学习框架下训练网络,并搭载Windows 11操作系统,在配有Intel(R)Core(TM) i5-12500H处理器,16 GB内存,CUDA-11.6, NVIDIA RTX 3050Ti显卡的服务器上完成。

具体实验方案为:

- 1) 准备地震信号的数据集并进行预处理;
- 2) 对纯净地震记录加噪,通过MPUNet进行训练;
- 3) 调试网络超参数,使得网络输出趋近于所加的噪声;
- 4) 用加噪记录减去网络输出的纯噪声,得到去噪后的地震记录;
- 5) 用含噪合成地震记录和实际地震数据对训练好的网络测试;
- 6) 绘制合成记录去噪后的  $f-k$  谱图和单道记录的时频域波形对比图;
- 7) 与TFPF, RDNet, 传统UNet和RDBUNet对比去噪效果。

## 3 实验结果

### 3.1 合成记录处理结果

先利用MATLAB合成一张干净地震记录,如图6(a)所示,记录中包含4条同相轴,61道地

震道, 每条道包含 384 个采样点, 采样间隔为 1 ms, 雷克子波主频为 40 Hz 和 60 Hz。在干净地震记录中加入 70% 的高斯白噪声, 生成的含噪记录如图 6(b) 所示, 分别用传统去噪算法 TFPF 和神经网络 RDNNet, UNet, RDBUNet 以及 MPUNet 对加噪后的地震记录进行处理, 去噪结果如图 6(c)~图 6(g) 所示, 图 7 是各方法处理后的残差图对比。由图 6(c) 可以看出 TFPF 滤波后的地震记录与加噪记录相比, 背景噪声得到一定程度的抑制, 但在其对应的残差图 7(a) 中同相轴有明显的残留。由图 6(d) 可以看到, RDNNet 去噪后的

效果明显比传统去噪算法 TFPF 好很多, 但去噪记录中仍然存在大量的随机噪声。图 6(e) UNet 去噪结果显示, 有效信号同样还是受到大量噪声的干扰, 同相轴淹没在随机噪声中。由图 6(f) 可以看出, RDBUNet 去噪后的记录比 UNet 的更加干净, 但仍然有部分噪声没有得到压制。由图 6(g) 可以看出, 经过 MPUNet 处理过的地震记录明显几乎不含任何随机噪声, 比 UNet 和 RDBUNet 网络去噪效果显著很多, 尽管在其残差图 7(e) 中可以看到少量同相轴, 但其对噪声的压制能力远远优于 UNet 和其它去噪方法。

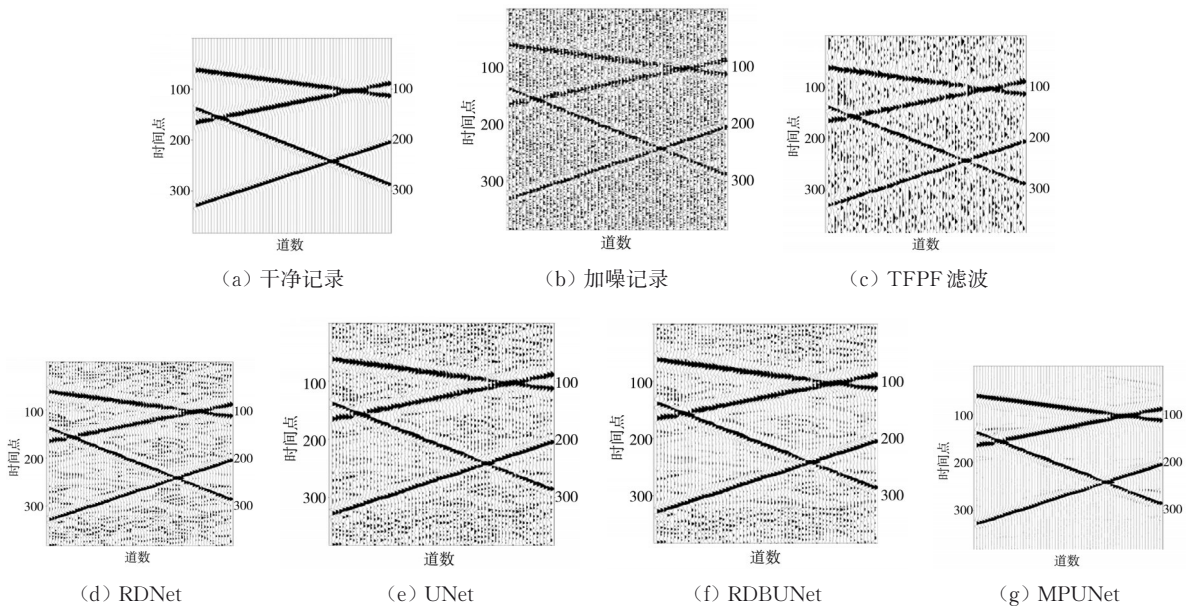


图 6 合成地震记录去噪结果

Fig. 6 Denoising results of synthetic seismic records




图 7 合成地震记录的残差结果

Fig. 7 Residual results of synthetic seismic records

图 6 所示的干净记录、加噪记录以及各种去噪方法的  $f-k$  谱图如图 8 所示。从图 8(b) 可以看到, 噪声对有效信号的干扰非常严重, 噪声遍布在整个频率范围; 从图 8(c) 中可以看出, 传统去噪算法 TFPF 抑制了噪声中大部分高频成分, 但低频噪声仍然和有效信号混叠在一起, 没有得到抑制; 从图 8(d)~图 8(f) 中可以看出, 神经网络的去噪效果优于 TFPF 滤波, 但还是存在一小部

分低频噪声和有效信号混叠在一起; 图 8(g) 为 MPUNet 处理后的结果图, 从图中可以看出, 经过 MPUNet 处理之后的  $f-k$  谱图比 RDBUNet 网络处理后的  $f-k$  谱图更接近干净记录, 噪声和有效信号得到充分的分离, 证明了 MPUNet 对噪声的抑制能力以及对有效信号的保幅能力都优于 UNet 和其它去噪算法。

单道时频域波形对比图可以直观地检验各去

噪方法的保幅性能,从图6所示的合成模拟记录中随机选取一道记录进行分析处理,这里抽取了第50道做对比分析。图9(a)为含噪信号、纯净信号、TFPF, UNet, RDNet, RDBUNet 和 MPU-

Net的单道时域波形对比图,图9(b)为时域波形第一个峰值放大图,图9(c)是各方法对应的频域波形对比图,将50~120 Hz这一频段进行了放大。

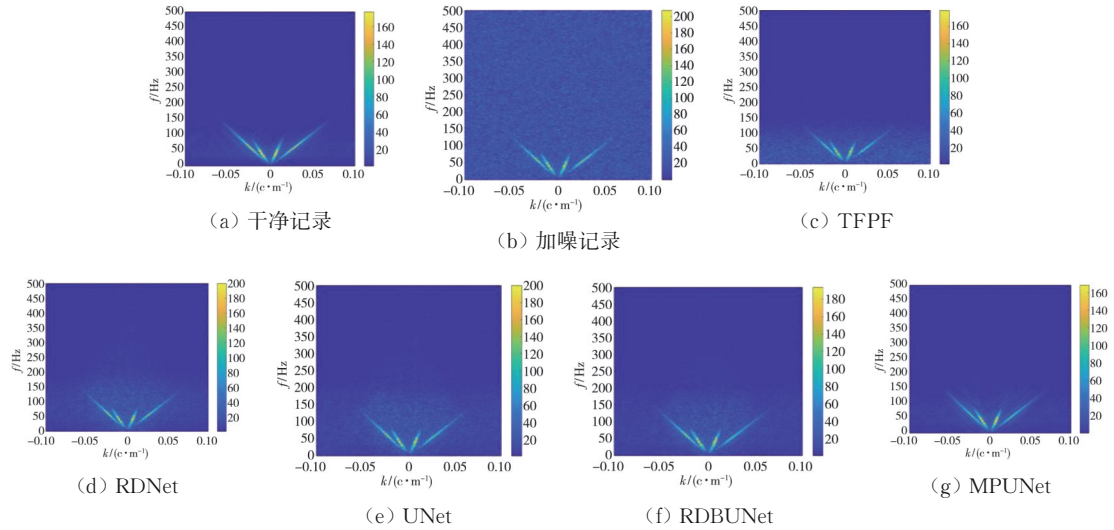


图8 合成记录的 $f-k$ 谱图

Fig. 8  $f-k$  spectra of synthetic seismic record

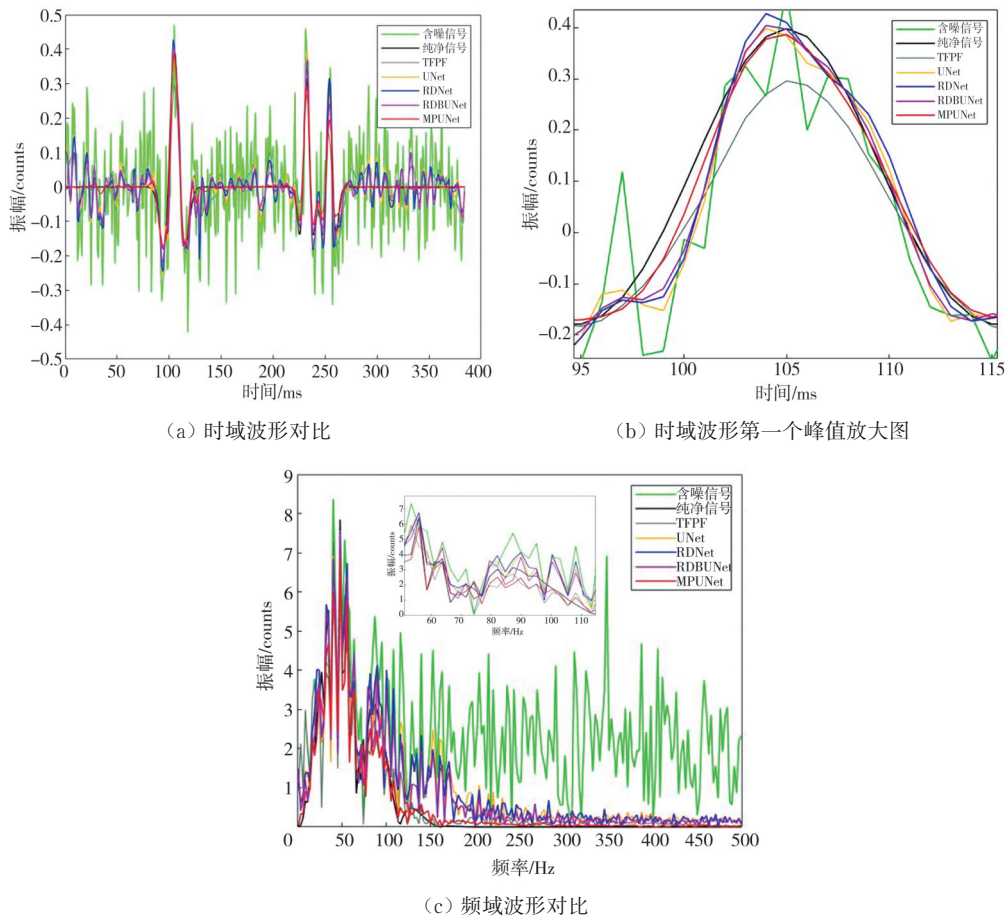


图9 单道记录对比

Fig. 9 Single track record comparison

从图 9 中明显可以看出,通过 MPUNet 处理过的单道信号不管在时域还是频域,波形都比其它方法处理后的更接近原始信号的波形。实验进一步证明了 MPUNet 对随机噪声的压制能力以及对有效信号的保幅能力都优于 UNet 和其它网络。

本文对去噪效果的定量分析选择信噪比(SNR)和均方误差(MSE),信噪比是衡量降噪程度最直观的一个量,信噪比越大,说明信号中包含的噪声越小,去噪效果越好。均方误差是反应

真实值与估计值的偏差程度,均方误差越小,说明去噪后的信号越接近原始信号。表 1 是各种去噪方法对加入 70% 噪声后的合成记录的处理结果,从表 1 中可以看出,加噪记录的信噪比非常低,均方误差较大,经各方法处理后的信噪比都得到提升,通过实验数据分析对比,MPUNet 去噪后的信噪比明显高于其他去噪算法,再次说明了 MPUNet 有更好的去噪效果和较高的保真度。

表 1 不同方法去噪后参数对比

Table 1 Comparison of parameters after denoising of different methods

	含噪信号	TFPF	UNet	RDNet	RDBUNet	MPUNet
信噪比/dB	-5.175 3	2.862 0	3.668 1	4.076 3	5.517 1	11.090 8
均方误差	0.016 1	0.002 5	0.002 1	0.001 9	0.001 4	3.795 9e-04

### 3.2 实际记录处理结果

为进一步验证 MPUNet 去噪方法的适用性,将 TFPF 滤波法、UNet, RDNet, RDBUNet 和 MPUNet 用于处理实际地震资料。图 10(a) 是从野外实际数据中截取的部分数据,该记录包含 128 道,每道 5 952 个采样点,采样间隔为 4 ms,从图中可以看到,有效信号淹没在背景噪声中,几乎看不到同相轴;图 10(b) 为 TFPF 滤波法处

理后的记录,从图中可以看出,背景噪声得到一定程度的抑制,但面波和低频随机噪声的干扰还是很严重;从图 10(c)~图 10(e) 可以看出,UNet, RDNet 和 RDBUNet 进一步抑制了随机噪声,恢复出部分同相轴,但同相轴模糊,分辨率还需要进一步提高,对噪声的压制不够彻底;由图 10(f) 中可以看出,经过 MPUNet 处理后,大部分背景噪声被去除,同时保留了更多局部细节,恢复出来的同相轴更加清晰连贯。

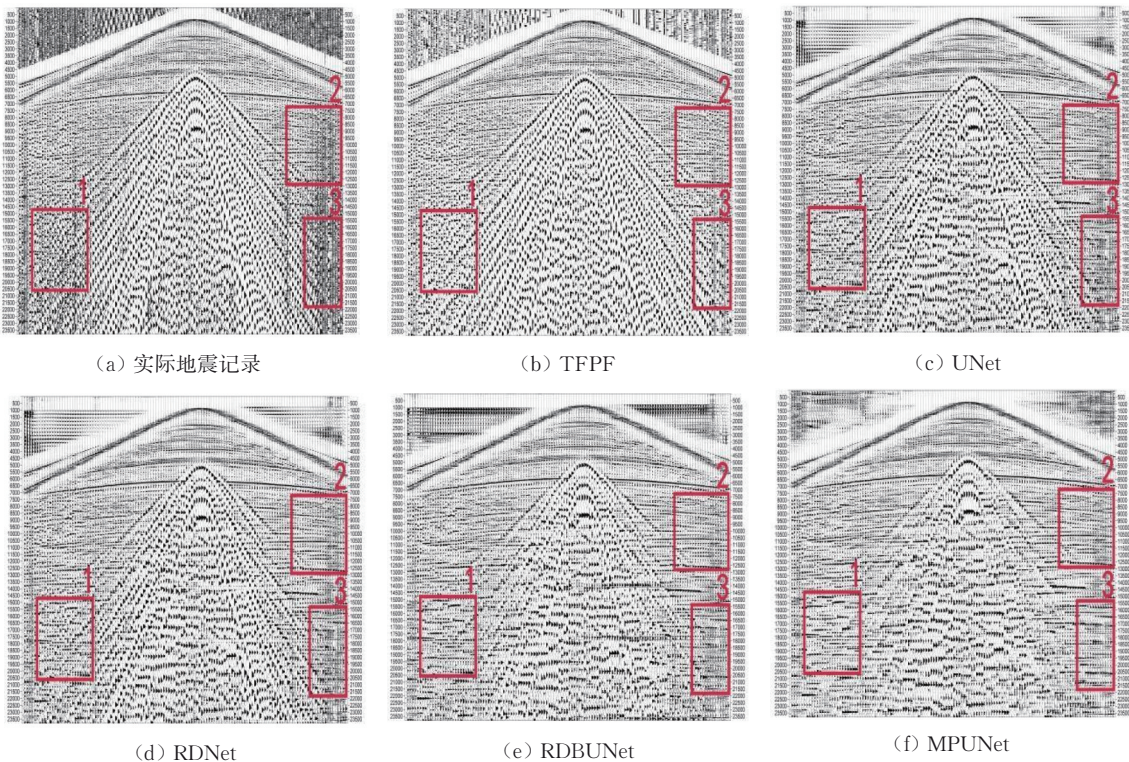


图 10 实际地震记录去噪结果

Fig. 10 Denoising results of real seismic record

为了更清楚地观察去噪结果,将图 10 的 3 个红框部分进行放大,分别为图 11~图 13。图 11、图 12、图 13(a)为原始实际地震记录,图 11(a)和图 13(a)中布满了噪声,几乎看不到有效信号,图 12(a)可以看到模糊的同相轴,但混有大量的随机噪声。从图 11、图 13(b)中可以看出,TFPF 去除了大部分随机噪声,但仍然看不到同相轴,图 12(b)恢复出部分同相轴,但同相轴不连贯;从图 11、图 12、图 13(c)~图 13(e)可以看出,经过 UNet, RDNet 和 RDBUNet 处理后的实际地震

记录恢复出更多的同相轴,但还残留部分随机噪声;由图 11、图 12、图 13(f)中可以看出,经过 MPUNet 处理后的地震记录比经过 UNet, RDNet 和 RDBUNet 处理后的记录更加干净,随机噪声被压制的更加彻底,同相轴分辨率提高,同相轴清晰平滑,例如图 11(c)~图 11(f)箭头所指的这条同相轴经过 MPUNet 处理后更清晰连贯。通过以上对比证明了多阶段渐进式 UNet 网络去噪性能的优越性,为地震数据处理提供了新的方向和思路。

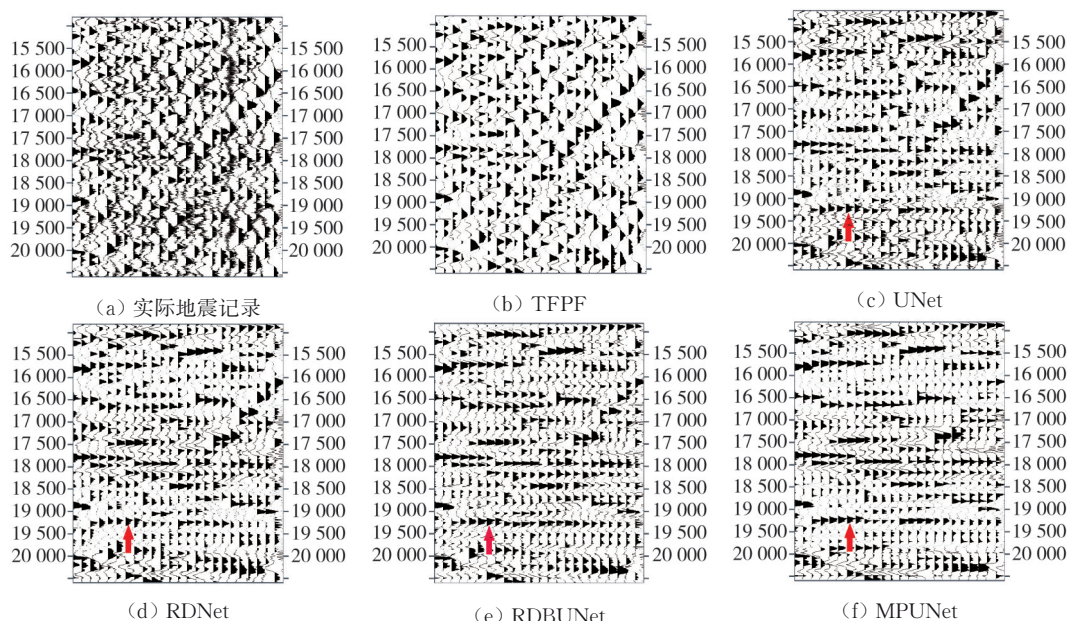


图 11 图 10 红框 1 处放大对比

Fig. 11 Enlarged comparison at one point of red box in figure 10

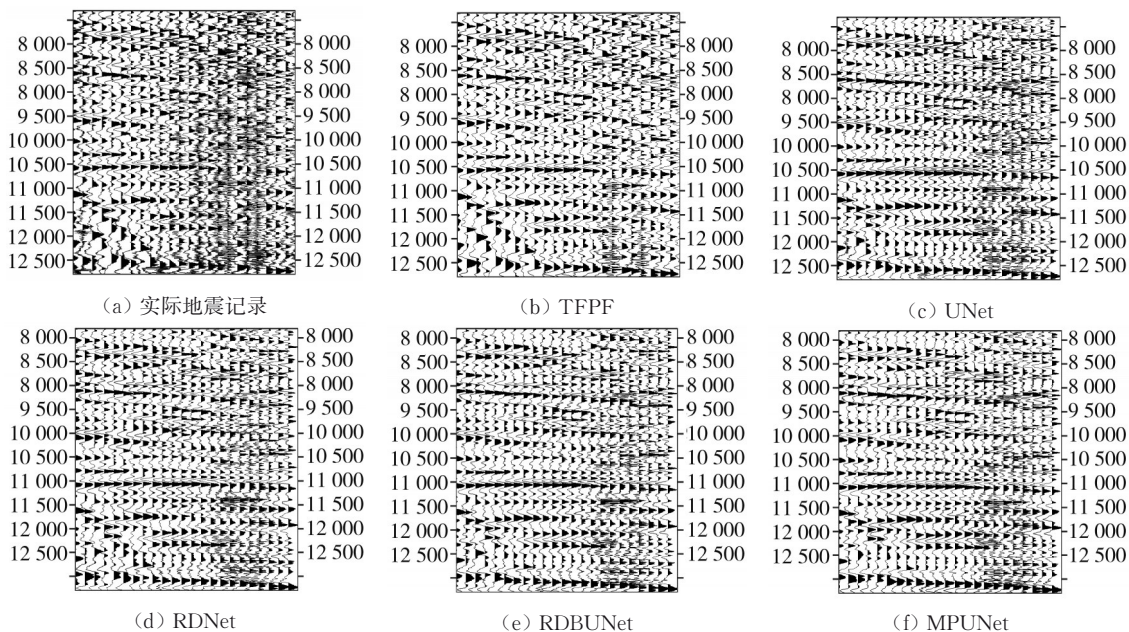


图 12 图 10 红框 2 处放大对比

Fig. 12 Enlarged comparison at two point of red box in figure 10

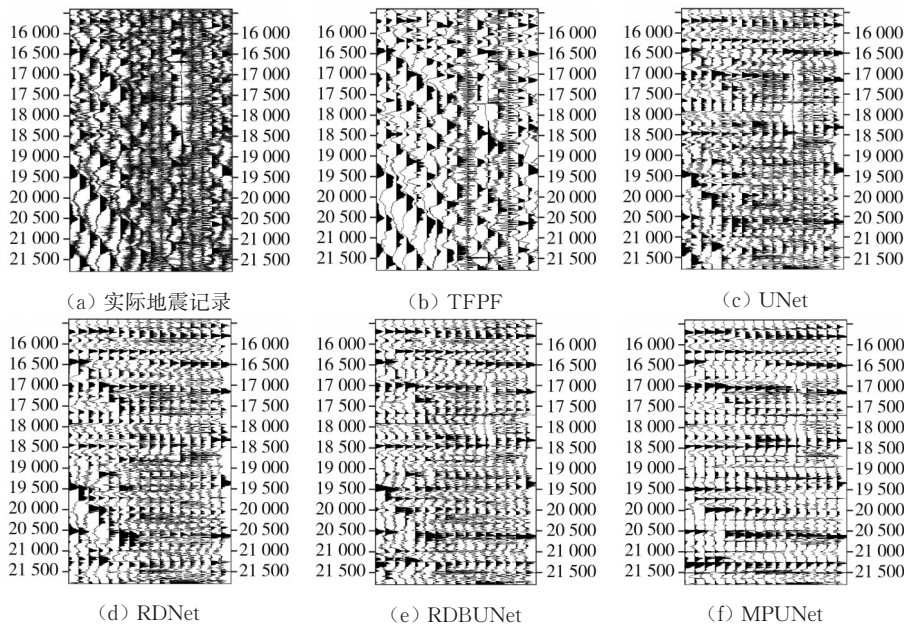


图 13 图 10 红框 3 处放大对比

Fig. 13 Enlarged comparison at three point of red box in figure 10

### 4 结论

针对 UNet 网络是单阶段网络且在保留空间细节方面不可靠这一缺点,将 UNet 和 ORSNet 相结合,提出一个多阶段渐进 UNet 网络并应用于地震勘探随机噪声压制中。MPUNet 网络中前两个阶段的 UNet 结构可以提取丰富的多尺度信息,最后阶段用 ORSNet 提高地震记录的空间精确度。通过对实际地震数据的处理,实验结果证明了 MPUNet 不仅可以恢复出更多的同相轴而且恢复出的同相轴更加清晰连贯。网络中每两个阶段之间通过引入 SAM 来引导校准提取到的特征,抑制无用特征进入到下一阶段,进一步优化了网络的去噪性能。每个阶段并不是独立存在,通过跨阶段特征融合机制可以将前一阶段的中间特征传递到下一阶段,有效避免了多尺度信息的丢失。通过对模拟合成记录和实际地震记录的处理,同时也对比了其它去噪方法,证明了 MPUNet 可以显著提升地震数据的信噪比,比 UNet 和 RDBUNet 网络去噪效果更优。同时 MPUNet 的  $f-k$  谱图比其他网络的  $f-k$  谱图更接近原始记录,说明了该网络对有效信号的保幅能力更强,为下一步地震资料的分析解释工作提供了强有力的依据。

#### 参考文献:

[ 1 ] 牛永效. 基于频率及 FK 域联合应用的地震波去噪技术研究[J]. 铁道标准设计, 2017, 61(2): 47-49.

NIU Yongxiao. Research on seismic wave denoising technology based on frequency and F-K domain joint application. Railway [J]. Standard Design, 2017, 61 (2): 47-49. (in Chinese)

[ 2 ] LI Z, GAO J, LIU N, et al. Random noise suppression of seismic data by time-frequency peak filtering with variational mode decomposition [J]. Exploration Geophysics, 2019, 50(6): 634-644.

[ 3 ] LIU N, YANG Y, LI Z, et al. Seismic signal denoising using time-frequency peak filtering based on empirical wavelet transform [J]. Acta Geophysica, 2020, 68(2): 425-434.

[ 4 ] LU Y, HUANG Y, XUE W, et al. Seismic data processing method based on wavelet transform for denoising[J]. Cluster Computing, 2019, 22(3): 6609-6620.

[ 5 ] SIWEI Z, DAYONG Z, XIAOKANG Y, et al. Noise reduction method based on curvelet theory of seismic data[J]. Petroleum Science and Technology, 2023, 41(24): 2344-2361.

[ 6 ] JI G, WANG C. A Denoising method for seismic data based on SVD and deep learning [J]. Applied Sciences, 2022, 12(24): 12840.

[ 7 ] ZHANG F, CAI N, WU J, et al. Image denoising method based on a deep convolution neural network [J]. IET Image Processing, 2018, 12(4): 485-493.

[ 8 ] 崔亮, 徐玉冰, 程耀瑜. 一种改进的 FCM 聚类算法在噪声图像分割中的应用[J]. 中北大学学报(自然科学版), 2016, 37(1): 76-82.

CUI Liang, XU Yubing, CHEN Yaoyu. Application

- of an improved FCM clustering algorithm in noise image segmentation[J]. *Journal of North University of China (Natural Science Edition)*, 2016, 37(1): 76-82. (in Chinese)
- [9] YANG Yang, CHEN Guangwu, WANG Jingwen. Research on train combination positioning method based on grey neural network[J]. *Journal of Measurement Science and Instrumentation*, 2019, 10(2): 143-149.
- [10] WU Z, ZHAO D, LIANG Q, et al. Dynamic sparsity neural networks for automatic speech recognition[C]// *ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2021: 6014-6018.
- [11] BABKEN A, HIDDE B, MAA W. Towards Advanced diagnosis and management of inherited arrhythmia syndromes: harnessing the capabilities of artificial intelligence and machine learning[J]. *Heart Rhythm*, 2023, 20(10): 1399-1407.
- [12] 韩卫雪, 周亚同, 池越. 基于深度学习卷积神经网络的地震数据随机噪声去除[J]. *石油物探*, 2018, 57(6): 862-869.  
HAN Weixue, ZHOU Yatong, CHI Yue. Deep learning convolutional neural networks for random noise attenuation in seismic data[J]. *Geophysical Prospecting for Petroleum*, 2018, 57(6): 862-869. (in Chinese)
- [13] 王钰清, 陆文凯, 刘金林, 等. 基于数据增广和 CNN 的地震随机噪声压制[J]. *地球物理学报*, 2019, 62(1): 421-433.  
WANG Yuqing, LU Wenkai, LIU Jinlin, et al. Earthquake random noise suppression based on data augmentation and CNN[J]. *Journal of Geophysics*. 2019, 62(1): 421-433. (in Chinese)
- [14] 李海山, 陈德武, 吴杰, 等. 叠前随机噪声深度残差网络压制方法[J]. *石油地球物理勘探*, 2020, 55(3): 493-503.  
LI Haishan, CHEN Dewu, WU jie, et al. Pre-stack random noise suppression with deep residual network [J]. *Oil Geophysical Prospecting*, 2020, 55(3): 493-503. (in Chinese)
- [15] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image super-resolution [J]. *IEEE Access*, 2018, 43: 2472-2481.
- [16] GAO Z, ZHANG S, CAI J, et al. Research on deep convolutional neural network time-frequency domain seismic signal denoising combined with residual dense blocks[J]. *Frontiers in Earth Science*, 2021, 9: 1-14.
- [17] JIANXIAN C, LI W, JIANGSHAN Z, et al. Denoising method for seismic co-band noise based on a u-net network combined with a residual dense block [J]. *Applied Sciences*, 2023, 13(3): 1324-1324.
- [18] ZHAO Z, XIONG B, GAI S, et al. Improved deep multi-patch hierarchical network with nested module for dynamic scene deblurring[J]. *IEEE Access*, 2020, 8: 62116-62126.