doi: 10.11720/wtyht.2023.1386

周慧,孙成禹,刘英昌,等. 基于 DC-UNet 卷积神经网络的强噪声压制方法[J]. 物探与化探,2023,47(5):1288-1297. http://doi.org/10.11720/ wtyht. 2023.1386

Zhou H, Sun C Y, Liu Y C, et al. A method for strong noise suppression based on DC-UNet[J]. Geophysical and Geochemical Exploration, 2023, 47(5): 1288-1297. http://doi.org/10.11720/wtyht.2023.1386

# 基于 DC-UNet 卷积神经网络的强噪声压制方法

# 周慧,孙成禹,刘英昌,蔡瑞乾

(中国石油大学(华东)地球科学与技术学院,山东 青岛 266580)

摘要:在成熟工业区采集地震数据的过程中,由于生产设备的持续运转,使得采集到的地震数据含有大量振幅很强的局部强噪声,难以用常规的去噪方法压制。将 U-Net 网络与空洞卷积结合,建立了适用于局部强噪声压制的空洞卷积 DC-UNet 网络。DC-UNet 网络前端的循环空洞卷积块使用循环扩张的空洞卷积核提取不同尺度的强噪声特征信息,并且扩大了感受野;网络后端使用编码器提取强噪声特征,编码器还原强噪声细节特征。DC-UNet 网络实现从含噪数据到噪声的非线性映射,通过从含噪数据减去学习到的强噪声,达到压制强噪声的目的。在 GPU 环境使用 Pytorch 框架进行训练,合成数据和实际数据实验结果表明,相较于 DnCNN、U-Net、PCA-UNet 网络,DC-UNet 网络能更好地压制局部强噪声并且提高了信噪比。

关键词:局部强噪声;空洞卷积;卷积神经网络

中图分类号: P631.4 文献标识码: A 文章编号: 1000-8918(2023)05-1288-10

# 0 引言

随着地震勘探技术的发展,对地震资料处理后 的质量要求越发严格,处理地震数据朝着高信噪比、 高分辨率、高保真度的"三高"标准发展。深度学习 在图像去噪<sup>[1]</sup>、图像语义分割、故障诊断方向得到 了广泛应用。近年来,由于深度学习在各个方向的 优异表现,逐渐将其引入地震资料处理,应用于断层 识别、地震数据去噪等方面。

常规去噪算法包括利用傅里叶变换的 F-X 域 去噪<sup>[2-4]</sup>、利用 Radon 变换的 *τ-p* 域去噪<sup>[5]</sup>以及曲波 域去噪<sup>[6]</sup>、小波变换去噪等算法<sup>[7-8]</sup>,这些算法通常 为将原始数据进行某种变换处理,在变换域识别噪 声与有效信号的差异,并设置阈值压制噪声所处区 域,然后进行反变换达到去噪的目的。

深度学习利用现有数据中噪声与信号的关系进行智能去噪,基于深度学习的图像去噪方法也被应用于地震数据去噪中。Zhang等<sup>[9]</sup>提出去噪卷积神

经网络(DnCNN),利用残差学习和批量归一化提高 去噪能力和计算效率。韩卫雪等[10]利用卷积神经 网络去除地震随机噪声。Alwon<sup>[11]</sup>提出了用生成对 抗网络(GANs)进行地震随机噪声压制。于四伟 等<sup>[12]</sup>利用 CNN 对随机噪声、线性噪声、多次波进行 压制。Wang 等<sup>[13]</sup>通过 CNN 利用合成数据中的噪 声作为模型训练时期的标签,让模型学会识别数据 中的噪声。张攀龙等<sup>[14]</sup>使用改进的 U-Net 去除随 机噪声。罗仁泽等<sup>[15]</sup>将 U-Net 网络加入残差块增 强对随机噪声的压制。Li 等<sup>[16]</sup>采用多尺度扩张网 络消除沙漠地震噪声来避免特征细节缺失。Yu 等[17] 首次将空洞卷积聚合多尺度上下文信息用于 密集预测。随后逐渐有学者将空洞卷积结合 U-Net,用于改进 U-Net 网络。这种将空洞卷积结合 U-Net 的改进网络可以叫作 DC-UNet 网络(dilate convolution Unet),在图像分割领域得到了广泛应用。 张华博<sup>[18]</sup>、薛海洋<sup>[19]</sup>都是将 U-Net 编码器输出结 果使用多个空洞卷积进行不同尺度的特征提取融 合.再输入编码器。

**第一作者**:周慧(1997-),女,硕士研究生,主要从事基于深度学习的地震强噪声压制方面的研究工作。Email:2577156309@qq.com 通讯作者:孙成禹(1968-),男,教授,主要从事地震波传播理论和地震勘探方法的教学和研究工作。Email:suncy@upc.edu.cn

收稿日期: 2022-10-13; 修回日期: 2023-08-08

基金项目:国家自然科学基金项目(42174140)

局部强噪声与有效信号在视速度、频率范围难 以区分,没有一个明确的函数表达。工业区使用节 点仪器采集地震信号,在长时间记录地震信号的过 程中,相邻两炮的间隔期间,记录下的数据没有反射 信号,是相对纯净且数量充足的噪声数据,这些噪声 数据可以作为网络学习的标签,通过神经网络的学 习,建立出一个典型的去噪模型。DC-UNet使用空 洞卷积核代替传统卷积核,获得更大的感受野。将 循环空洞卷块添加到 U-Net 网络的前端,循环的空 洞卷积核获得的特征图通过串联融合提取不同尺度 特征,将获得的信息通过残差学习的方式输入常规 的 U-Net 的网络中。以局部强噪声作为标签,DC-UNet 网络形成含噪数据和局部强噪声的非线性映 射关系,使得训练出的强噪声更加接近于实际噪声。

1 常规 U-Net 去噪网络原理

# 1.1 常规 U-Net 的网络结构

常规 U-Net 的网络结构是 DC-UNet 网络结构的基础,该网络结构如图 1 所示。





# Fig. 1 Network structure of conventional U-Net

常规的 U-Net 网络由扩展通道和压缩通道两部 分组成。压缩通道是卷积网络的典型架构。它是由 两个卷积核尺寸为 3×3 的卷积层重复组成,此时特 征通道数由 1 变为 64,后一个卷积层跟着一个线性 整流激活函数 ReLU 和一个尺寸为 2×2 卷积核、滑 步为 2 的最大池化层。通过最大池化操作进行下采 样,此时的通道数变为上一步的两倍,即通道数从 64 变为 128,对应的特征图变为原来的一半。重复 操作直到通道数变为 1024,扩展通道每一次对特征 图进行卷积核尺寸为 2×2 的反卷积,特征通道数的 数量变为原来的一半,再与对应压通道的特征图拼 接,后面跟着两个卷积层和激活函数 ReLU,重复操 作直到通道数为 64,再进行一个卷积核为 1×1 的卷 积层,最终输出的通道数为 1。将压缩通道的高分 辦率特征图与扩张通道的上采样特征图相结合,不 仅使特征图的分辨率提高,也减少了上下层特征图 信息的丢失。

# 1.2 常规 U-Net 去噪原理及存在的问题

U-Net 的压缩通道和扩展通道相当于一个解码器和编码器,解码的过程中,通过下采样获得不同尺度的特征信息;编码的过程中,通过跳跃连接获得同层深度的特征信息,实现含噪信号到噪声或是有效信号的非线性映射。

U-Net应用到压制局部强噪声,虽然因为解码、 编码以及跳跃连接可以融合不同尺度的噪声特征, 但是噪声特征信息从1~64 通道只有一个卷积层和 激活函数 ReLU,对噪声的低维特征没有充分的学 习。说明以强噪声为标签,U-Net 网络从含噪地震 数据非线性映射学习到的局部强噪声,需要进一步 提取噪声的低维特征信息,才能更加接近实际强噪 声,从而更好地压制局部强噪声,保留地震数据的反 射信息和细节特征。

# 2 DC-UNet 网络

DC-UNet 网络是结合空洞卷积的 U-Net 网络。 使用空洞的卷积核可以获得更大的感受野,即学习 的特征信息更详尽。空洞卷积核进行卷积操作,对 强噪声的特征信息提取融合,达到充分学习强噪声 特征信息的目的。因此可以使用一组循环的空洞卷 积核提取强噪声的低维特征信息,减少强噪声特征 信息细节方面的丢失。

空洞卷积即指卷积核注入空洞,可以通过改变 空洞率将卷积核扩展到指定大小,并将原卷积核未 填充的区域填充0。感受野是特征图上一个点对应 的输入区域,感受野越大则包含的特征信息更多。 因此结合空洞卷积扩大了卷积核的有效感受野,这 有助于提高模型对强噪声特征的学习能力。

如果将 o 表示为空洞率,原始卷积核的大小表 示为 k,用 d 表示空洞卷积核的大小,则 d 可以表示 为:

 $d = \left[ o \times (k - 1) + 1 \right]_{\circ} \tag{1}$ 

如果 *s* 是无噪数据, *n* 是局部强噪声, *y* 是含噪数据, 则 *y* 可以表示为:

$$y = s + n_{\circ} \tag{2}$$

通过 DC-UNet 的网络学习,能够研究局部强噪声的 特征并进行预测。因此为了得到无噪数据 *s*,我们 只需要从含噪数据 *y* 中减去 DC-UNet 预测的局部强 噪声 *n*。

#### 2.1 循环空洞卷积

前面的学者将空洞卷积应用在解码器和编码器 之间,即下采样和上采样之间的卷积操作用的是空 洞卷积核,进行不同尺度的特征提取、融合。此外相 同尺寸的跳跃连接的方式是 concatenate,即特征图 在一个方向上堆叠。

获得局部强噪声的特征信息需要从不同的尺度 对噪声的特征进行学习,同时要求更大的感受野来 获得噪声特征信息,因此需在 U-Net 网络架构的前 端增添循环空洞卷积块。循环空洞卷积块的组成如 图 2 所示。



图 2 循环空洞卷积块

Fig. 2 Circular dilated convolution block

图 2 中的循环空洞卷积块循环使用空洞率为 1 和 2 的卷积核。当卷积核大小为 3×3,空洞率为 1 时, 此时的卷积操作与常规的卷积是相同的;当卷积核大 小依旧是 3×3,而空洞率变为 2 时,虽然实际卷积核 仍为 3×3,但空洞卷积核变为 5×5,此时感受野的大小 为 7×7。循环空洞卷积核不仅扩大了感受野,而且减 少了特征信息的丢失,保证了特征信息的连续性。各 个空洞的卷积层获得的特征图,通过数据拼接,再用 64 个大小为 3×3 的 1-空洞(空洞率为 1)的卷积核进 行特征提取,实现了特征信息的串联融合。

#### 2.2 网络结构

比起前面学者做的 DC-UNet 网络,明显的变化 是在 U-Net 前端添加了循环空洞卷积块,后端相同 尺度的特征图之间的跳跃连接是用 add 的方式,即 特征图对应位置元素相加。

DC-UNet 神经网络结构如图 3 所示。循环空洞 卷积块获得更大的感受野并学习更详细的噪声特 征,进而获得接近于标签的最佳值传入下一层网络, 有利于获得噪声的特征信息和分布规律,使去噪性 能有效提升。输入数据经过循环空洞卷积块后,通



Fig. 3 Network structure of DC-UNet

过残差学习模块输入后面的 U-Net 结构中,即输入 数据 x 进行跳跃连接和通过空洞卷积块的 f(x)相 加再输入后端的网络中,这样尽可能地保留了特征 信息。

比起常规 U-Net 用最大池化的方式进行下采 样,笔者通过滑动卷积的方式实现数据降维和数据 量的减小。此时卷积核的大小为 2,滑动步长的大 小也为 2,填充为 0。图 4 为下采样示意。最大池化 保留卷积核对应输入数据邻域最大特征点。比起最 大池化.使用滑动卷积能够更好地保留数据的特征。

DC-UNet 和 U-Net 都是过反卷积的方法实现上 采样从而使特征图的大小变为原来尺寸的两倍。这 里的卷积核和滑步大小都为 2,在输入的特征图间 隔插入填充,这样使由于下采样尺寸缩小的特征图 恢复了原始尺寸。



图 4 下采样示意

## Fig. 4 Schematic diagram of downsampling

这里的 DC-UNet 比起前人的 DC-UNet 是有区 别的。首先使用空洞卷积核提取特征信息的方式和 在网络架构的位置是不同的。前人将单一的空洞卷 积核放在下采样和上采样之间的卷积层提取高维特 征信息,然后将卷积层提取特征信息通过对应元素 相加的方式进行特征融合。而笔者是将循环的多个 空洞卷积核用于特征信息低维信息提取,拼接特征通 道之后,再用空洞卷积核提取特征信息,实现串联融 合并且用残差模块输入后端网络。循环的空洞卷积 核保证了特征信息的连续性。其次是解码器和编码 器之间的跳跃连接和下采样方式不同。前人使用的 跳跃连接是 concatenate 和最大池化,这里用 add 的方 式实现特征信息融合和使用滑动卷积进行下采样。

## 3 模型数据测试

利用有限差分声波正演合成地震记录,加入强

噪声变成含噪数据。强噪声的显著特征是振幅强且 与有效信号的频率范围重叠。由于难以通过人工合 成与实际采集相似的强噪声,所以加入的强噪声是 实际节点采集强噪声集中的部分作为噪声。工区由 两条测线组成,采样时间间隔为1ms,每道12001 个采样点。选取其中32炮地震记录含有强噪声的 部分,位于直达波上下,共有5000个大小为200× 200的强噪声标签。图5就是其中一条测线的3炮 地震数据。图5b红色方框中的强噪声按照采样时 间叠加的能量,可以看出强噪声的能量在直达波上



图 5 实际测线数据



下的变化浮动不大。图 5c 是按道叠加能量,可以看 出图 5b、c 的能量变化是基本吻合的,同时看出强噪 声的能量不随偏移距增加改变。

通过改变速度模型的地层厚度,随机生成90个 大小为(3500×1750m)的层状介质模型,采用间距 为5m的网格进行离散,震源为主频25Hz的Ricker子波(如图6星号)。一共生成90组正演数据, 每组正演数据一共700道,采样时间间隔为1ms,每 道1400个采样点,图6为具有基础的4层层状介 质模型。图7为对应的正演地震记录。





图 7 模型对应的合成地震记录

Fig. 7 Synthetic seismic record corresponding to the model 地震节点可以进行全时段、全空间的数据采集。

除了记录主动源数据,还记录了大量被动源数据。 记录下长时间的强噪声拥有足够的数据可以作为标 签来进行学习强噪声特征。图 8 为几个具有代表性的强噪声标签。

由图 8 可以看出强噪声位于不同的位置,增加 了强噪声标签的多样性,从而丰富了样本库中含噪 信号。为了清晰地表示去噪效果,可以用信噪比 (*SNR*)、峰值信噪比(*PSNR*)作为衡量去噪效果的指 标,分别定义为:

\$ 0.1

0.2

(c) 0

\$ 0.1

0.2

$$PSNR = 10 \times \lg \frac{\max(x_0^2)}{MSE} , \qquad (3)$$

$$SNR = 10 \times \lg \frac{\sum_{i=1}^{r} f(x_0^2)_i}{\sum_{i=1}^{p} f(x_0^2)_i}, \qquad (4)$$

式中: max( $x_0^2$ ) 表示信号数据中最大能量; MSE 是 均方误差, 即数据的差异程度; P 为道数;  $f(x_0^2)_i$ 、  $f(x_n^2)_i$ 分别为第 *i* 道信号数据和噪声数据的能量。

选择 80%的合成地震数据用于网络训练,选择 相似度高的样本,提高网络的去噪效果,避免从去噪 效果差的样本学到不好的特征,使最后呈现出的压 制强噪声的效果不好。将含有强噪声记录作为样 本,将强噪声作为标签,构建了含有 4 000 组样本和 标签的数据集,训练样本大小为 200×200。

DC-Unet 网络的具体参数设置为:初始学习率 0.001,使用 Adam 算法,网络的输入和输出大小设置为 200 × 200;采用 pytorch 框架, NVIDIA RTX A6000的 GPU 进行加速。





#### Fig. 8 Strong noise in different positions

图 9a 是无噪数据,加入强噪声得到图 9b 加噪数据。测试 DnCNN、U-Net、对强噪声进行主成分分析再输入 U-Net、DC-UNet 的去噪效果。

图 10、图 11 分别对应着 DnCNN、U-Net、对强噪 声进行主成分分析(PCA)再输入 U-Net(简称 PCA-UNet)、DC-UNet 这 4 种方法进行 30 轮、50 轮训练 后,去噪效果对比图 10a~d 可以看出,4 种去噪方法 在第 30 轮训练后,DnCNN、U-Net 和 PCA-UNet 对噪 声的压制效果都不好, DC-UNet 在浅层的有效信号 保留的较好,可以明显看到直达波。图 10e~f 可以 看出去除的噪声中都有有效信号, 说明在压制噪声 的过程中, 有效信号都有不同程度的损伤。

比较图 11a~d,同样可以看出 DC-UNet 对噪声的压制的去噪效果最好。从图 11b、d 的红圈看出, U-Net 恢复了浅层反射信息,DC-UNet 对噪声压制效 果最好。这一点也可以从图11e~f压制的噪声看



a-DnCNN 去嗓结果;b-U-Net 去嗓结果;c-PCA-UNet 去嗓结果;d-DC-UNet 去嗓结果;e-DnCNN 去除的噪声;f-U-Net 去除的噪声;g-PCA-UNet 去除的噪声:h-DC-UNet 去除的噪声

a-DnCNN denoising results; b-U-Net denoising results; c-PCA-UNet denoising results; d-DC-UNet denoising results; e-noise removed by DnCNN; f-noise removed by U-Net;g-noise removed by PCA-UNet;h-noise removed by DC-UNet

#### 图 10 第 30 轮训练后不同去噪方法去噪对比

#### Fig. 10 Denoising comparison of different denoising methods after the 30 training

出,DC-UNet 残留的反射信息最少。

去噪前,含噪信号的信噪比是-7.161dB,峰值 信噪比是为 17.618 dB。图 12 是 4 种方法 4 轮网络 训练后的信噪比和峰值信噪比。

可以看出4种方法随着训练轮数的增加,信噪 比和峰值信噪比呈上升趋势。在训练稳定时,DC-UNet 压制噪声后的信噪比和峰值信噪比最高。 DnCNN 压制噪声后, 信噪比是负值, 可能是 DnCNN 不适用压制强噪声,只压制了部分噪声,却压制了大 部分有效信号,使有效信号与噪声的能量比比压制

之前还小。

使用主成分分析(PCA)对噪声信号降维,考虑 噪声在经过降维之后作为标签输入网络和使用原始 数据输入是否对去噪结果产生影响。可以看出,强 噪声通过主成分分析降维再输入 U-Net 网络,和直 接输入 U-Net, 两者效果相差不大。

比较4种方法的去噪结果和对应的信噪比和峰 值信噪比,可以看出随着训练的轮数增加,每种方法 的去噪效果都有所提升。当去噪效果趋于稳定时, DC-UNet的去噪效果最好,说明DC-Unet能够学习

t/s

t/s

t/s

t/s

1.0

1.4





200

151

1.0

1.4

51

PCA-UNet 去除的噪声;h-DC-UNet 去除的噪声

51

151 200 1.0

1.4

51

a-DnCNN denoising results; b-U-Net denoising results; c-PCA-UNet denoising results; d-DC-UNet denoising results; e-noise removed by DnCNN; f-noise removed by U-Net;g-noise removed by PCA-UNet;h-noise removed by DC-UNet



图 11 第 50 轮训练后不同去噪方法去噪对比 Fig. 11 Denoising comparison of different denoising methods after 50 training





强噪声的特征,并成功的在含有强噪声的地震数据 中压制强噪声部分。对比去噪前后的残差,有效信 号和强噪声有了明显的分离,能较好地保留有效信 号,说明此时 DC-UNet 可以很好地满足去噪要求。

实际资料测试 4

对实际资料而言,强噪声的分布使得噪声比较 容易选取出来。可以选取位于直达波上下强噪声部 分作为数据标签,构建了4000组训练样本对的数 据集,样本大小为200×200。经过训练后,得到了最 终的去噪网络。实际数据一共训练50轮。

1.0

1.4 + 1

200

图 13 是训练第 30 轮时,用 U-Net、DC-UNet 对 红色方框中的地震数据进行去噪的结果和相应的 F-K 谱。当训练第 30 轮时,比较图 13b、c 可以明显 的看出,DC-UNet 压制强噪声的效果更好,还有部分 强噪声没有被压制。可以明显看出图 13e、f 的 F-K 谱中,有效信息更加明显。

200



a—实际含噪地震数据;b—U-Net 去噪结果;c—DC-UNet 去噪结果;d—含噪数据的 F-K 谱;e—U-Net 去噪结果的 F-K 谱;f—DC-UNet 去噪结果 的 F-K 谱

a-actual noisy seismic data; b-U-Net denoising results; c-DC-UNet denoising results; d-F-K spectra of noisy data; e-F-K spectra of U-Net denoising results; f-F-K spectra of DC-UNet denoising results

图 13 比较 30 训练轮后的实际地震数据去噪结果及对应的 F-K 谱

#### Fig. 13 Compare the actual seismic data denoising results after the 30 training and the corresponding F-K spectrum

图 14 是训练第 50 轮时,用 U-Net、DC-UNet 对 红色方框中的地震数据进行去噪的结果和相应的 F-K 谱。图 14a、b 对强噪声的压制效果都很好,比 较两种去噪结果的 F-K 谱(图 14c、d). 难以判断哪 种去噪结果更好,但是比较图 14e、f 去除的噪声中 的有效信号多少来看, DC-UNet 的去噪效果更好。 比较图 13 和图 14,发现随着训练轮数的增加,去噪 效果也越好。网络学习的目标是学习强噪声,使预 测的强噪声接近于实际,再从含噪数据中去掉这些 强噪声。从实际含噪数据的 F-K 谱可以看出,强噪 声频率范围和实际数据是有重叠的,难以通过频率 滤波直接滤除。比较不同训练轮数对应的去噪结果 的 F-K 谱,当去噪结果中的 F-K 谱明显看不到强噪 声对应的部分,并且随着训练轮数的增加 F-K 谱不 再明显变化时,说明学习的强噪声的效果较好,达到 了最佳训练轮数。

# 5 结论

在 DC-UNet 网络中使用了一组循环的空洞率, 串联融合特征信息,增加了不同尺度的特征信息和 扩大特征图的感受野,减少噪声细节方面的丢失,使 学习到的强噪声接近于实际强噪声,从而使压制强 噪声的效果更好。通过合成数据测试和实际数据测试,体现出具有更优越的去噪性能。结果表明,在实际数据应用中,在保留实际数据有效信号的同时,可以将强噪声很好地压制。

# 参考文献(References):

- Shahdoosti H R, Rahemi Z. Edge-preserving image denoising using a deep convolutional neural network [J]. Signal Process, 2019, 159 (3):20-32.
- [2] 冯兴强,杨长春,龙志祎.基于奇异值分解的 f-x-y 域滤波方法
  [J].物探与化探,2005,29(2):171-173.
  Feng X Q, Yang C C, Long Z Y. The filtering method in f-x-y domain based on singular value decomposition [J]. Geophysical and Geochemical Exploration,2005,29(2):171-173.
- [3] 刘婷婷,陈阳康.*f*-x 域经验模式分解与多道奇异谱分析相结合 去除随机噪声[J].石油物探,2016,55(1):67-75.
   Liu T T, Chen Y K. Random noise attenuation based on EMD and MSSA in *f*-x domain [J]. Geophysical Prospecting for Petroleum, 2016,55(1):67-75.
- [4] Canales L. Random noise reduction [C]//54<sup>th</sup> Annual International Meeting, SEG, Expanded Abstract, 1984:525-527.
- [5] 贾春梅,姜国庆,刘志成,等. 频域稀疏双曲 Radon 变换去噪方法[J]. 物探与化探,2016,40(3):527-533.
   Jia C M, Jiang G Q, Liu Z C, et al. Denising method based on sparse hyperbolic Radon transform in the frequency domain [J]. Geophysical and Geochemical Exploration,2016,40(3):527-533.



a—U-Net 去噪结果;b—DC-UNet 去噪结果;c—U-Net 去噪结果的 F-K 谱;d—DC-UNet 去噪结果的 F-K 谱;e—U-Net 去除的噪声;f—DC-UNet 去 除的噪声

a-U-Net denoising results; b-DC-UNet denoising results; c-F-K spectrum of U-Net denoising results; d-F-K spectrum of DC-UNet denoising results; e-noise removed by U-Net; f-noise removed by DC-UNet

## 图 14 比较 50 训练轮后的实际地震数据去噪结果及对应的 F-K 谱和去除的噪声

#### Fig. 14 Compare the actual seismic data denoising results after the 50

# training with the corresponding F-K spectrum and noise removal

[6] 彭才,常智,朱仕军. 基于曲波变换的地震数据去噪方法[J]. 石油物探,2008,47(5):461-464.

Peng C, Chang Z, Zhu S J. Noise elimination method based on curvelet transform [J]. Geophysical Prospecting for Petroleum, 2008, 47(5):461-464.

[7] 刘法启,张关泉.小波变换与 F-K 算法在滤波中的应用[J].石 油地球物理勘探,1996,31(6):782-791.

Liu F Q,Zhang G Q. Application of wavelet transform and F-K algorithm in filtering [ J ]. Oil Geophysical Prospecting, 1996, 31 (6):782-791.

- [8] 杨立强,宋海斌,郝天珧,等. 基于二维小波变换的随机噪声压 制方法研究[J]. 石油物探,2005,44(1):4-6. Yang L Q,Song H B,Hao T Y,et al. Method of 2-D wavelet transform in attenuating random noise[J]. Geophysical Prospecting for Petroleum,2005,44(1):4-6.
- [9] Zhang K,Zuo W,Chen Y, 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.
- [10] 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 W X, Zhou Y D, Chi Y. Deep learning convolutional neural networks for random noise attenuation in seismic data [J]. Geophysical Prospecting for Petroleum, 2018, 57(6):862–869.

- [11] Alwon S. Generative adversarial networks in seismic data processing[C]//SEG Technical Program Expanded Abstracts, 2018.
- [12] 于四伟,马坚伟. 基于深度学习的地震噪声压制[C]//SEG 北京 2018 国际地球物理会议暨展览,2018.
  Yu S W, Ma J W. Seismic noise suppression based on deep learning[C]//SEG Beijing 2018 International Geophysical Conference and Exhibition,2018.
- [13] Wang F, Chen S. Residual learning of deep convolutional neural network for seismic random noise attenuation [J]. IEEE Geosciences and Remote Sensing Letters, 2019, 16(8):1314-1318.
- [14] 张攀龙,李尧,张田涛,等. 基于 U-Net 深度神经网络的地震数 据去噪研究[J]. 金属矿山,2020(1):200-208.

Zhang P L,Li Y,Zhang T T, et al. Study on seismic data denoising based on U-Net deep neural network [J]. Metal Mine, 2020(1): 200–208.

- [15] 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 R Z,Li Y Y. Random scismic noise attenuation based on RUnet convolutional neural network [J]. Geophysical Prospecting for Petroleum,2020,59(1):51-59
- [16] Li H, Yang W, Yong X. Deep learning for ground-roll noise attenuation[C]//SEG Technical Program Expanded Abstracts, 2018.
- [17] Yu F,Koltun V. Multi-scale context aggregation by dilated convolutions[C]//ICLR,2016.
- [18] 张华博. 基于深度学习的图像分割研究与应用[D]. 成都:电子科技大学,2018.
   Zhang H B. Research and application of image segmentation by deep learning[D]. Chengdu: University of Electronic Science and Technology of China,2018.
- [19] 薛海洋. 基于深度学习的图像分割算法研究[D]. 南宁:广西 大学.2020.

Xue H Y. Research on image segmentation algorithm based on deep learning[D]. Nanning: Guangxi University, 2020.

# A method for strong noise suppression based on DC-UNet

ZHOU Hui, SUN Cheng-Yu, LIU Ying-Chang, CAI Rui-Qian

(School of Geosciences, China University of Petroleum (East China), Qingdao 266580, China)

**Abstract**: Seismic data acquired from mature industrial areas frequently contain a large amount of local strong noise with high amplitude due to the continuous operation of production equipment. However, such local strong noise can be hardly suppressed using conventional denoising methods. This study integrated dilated convolution(DC) and U-Net into a DC-UNet network for suppressing local strong noise. For the circular DC blocks at the front end of the DC-Unet network, a circularly expanded DC kernel was used to extract the features of strong noise at different scales, with the receptive field being expanded. Meanwhile, an encoder was used at the back end of the network to extract the features of strong noise and restore the details of strong noise. Subsequently, the DC-UNet network was employed to perform a nonlinear mapping from noisy data to noise. On this basis, strong noise was suppressed by subtracting the learned strong noise from the noisy data. As indicated by the experimental results of synthetic and real data obtained from the training using the Py-Torch framework in the GPU environment, the DC-UNet network can effectively suppress the local strong noise and improve the signal-to-noise ratio compared with DnCNN, U-Net, and PCA-UNet networks.

Key words: local strong noise; dilated convolution; convolutional neural network

(本文编辑:叶佩)