

文章编号: 1001-1749(2023)01-0017-11

基于前馈去噪卷积神经网络的地震数据去噪方法

王丹荔^{a,c}, 周怀来^{a,b,c}, 王元君^{a,b}, 吕芬^{a,c}, 何坪易^{a,c}

(1. 成都理工大学 a. 地球物理学院,

b. 油气藏地质及开发工程国家重点实验室,

c. 地球探测与信息技术教育部重点实验室, 成都 610059)

摘要: 随机噪声压制是提高地震数据信噪比的有效方法, 这里利用前馈去噪卷积神经网络(Denoising Convolutional Neural Network, DnCNN)的深度学习去噪方法, 对地震数据随机噪声的去除进行了研究, 同时利用 Mish 激活函数构建 M-DnCNN 网络进一步提升网络模型的去噪性能。该方法基于神经网络与统计学原理, 通过卷积神经网络自动提取特征, 利用单个残差单元来预测噪声, 即输入含噪地震数据, 经过 M-DnCNN 学习后输出预测的噪声, 将输入与输出噪声作差, 得到去噪后的地震数据。在实验部分, 首先利用合成地震数据对该方法的去噪效果进行验证, 同时将 M-DnCNN 与均值滤波和 $f-x$ 域预测滤波方法进行去噪对比, 结果表明: M-DnCNN 在去除地震数据随机噪声方面优于原始 DnCNN, 与其他两种去噪方法相比能够更有效地压制随机噪声; 随后将 M-DnCNN 用于实际地震数据去噪实验, 实验证明 M-DnCNN 在实际地震数据去噪处理中同样适用, 其在保留并突出有效信号的同时可达到较好的去噪效果。

关键词: 随机噪声; 地震数据去噪; Mish 激活函数; M-DnCNN

中图分类号: P 631.4 **文献标志码:** A **DOI:** 10.3969/j.issn.1001-1749.2023.01.03

0 引言

目前已有较多的去噪方法可将地震数据中规则干扰波进行去除, 如一维频率域滤波、 $f-k$ 滤波、Randon 变换、预测反褶积等, 不规则干扰波即随机噪声由于其无相似特征与规律, 难以从地震记录中有效分离。为解决这一问题, 国内、外学者进行了大量的尝试, 并提出了许多去除随机噪声的方法, 这些方法大多将高斯随机噪声假设为随机噪声进行去噪实验。其中常见的方法有: $f-x$ 域预测滤波, 小波变换, 均值滤波, 奇异值分解, 双树复小波域双变量法等^[1-5]。上述方法基于地震信号空间相干性, 在

非水平或弯曲同相轴信号的处理中存在一定的局限, 更适用于水平同相轴信号的处理。此外, 信号稀疏表示在地震随机噪声去除中也有广泛地应用, 主要分为稀疏编码与词典学习, 这类方法基于数据驱动, 利用地震数据自身特点进行去噪处理^[6-7]。现有的去噪方法虽取得了较好效果, 但仍存在有效信号损伤、参数难调、参数限制等问题。

深度学习在近几年引起了广泛关注, 在图像处理、语言识别、目标检测领域均有优异表现^[8]。卷积神经网络(Convolutional Neural Networks, CNN)是深度学习的代表算法之一, 能够从输入信息中自动提取高阶特征, 学习到高度复杂的非线性关系。与传统方法相比, 训练好的网络模型可直接用于相

收稿日期: 2021-09-23

基金项目: 四川省科技厅重点研发项目(21ZDYF2939)

第一作者: 王丹荔(1997-), 女, 硕士, 主要研究方向为地球物理软件技术, E-mail: 1015342250@qq.com。

通信作者: 周怀来(1978-), 男, 教授, 主要从事油气勘探教学与科研工作, E-mail: 271980681@qq.com。

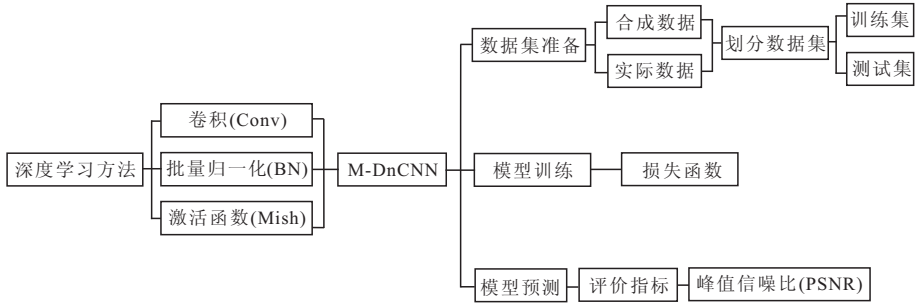


图 1 技术路线

Fig. 1 Technical route

应问题的解决,无需复杂的手动调参。现已有学者将深度学习引入地震数据去噪中,韩卫雪等^[9]构建了一种适合于地震信号去噪的卷积神经网络,并将其用于地震数据随机噪声的去除,与常规去噪算法相比具有更强的去噪能力;王钰清等^[10]提出了基于数据增广和 CNN 的地震随机噪声压制方法,可以直接从无标签实际有噪数据生成标签数据集,为实际数据标签获取提供了新思路;YU 等^[11]利用 DnCNN 网络进行地震数据随机噪声和线性噪声的去除,具有一定的效果,此论文引发了思考是否可以在此基础上对去噪效果进一步提升。

DnCNN 网络是 Zhang Kai^[12]提出的一种基于残差学习和批量归一化处理的深度卷积神经网络去噪方法。该算法在图像去噪中效果突出,在地震数据去噪方面也有良好表现,笔者基于 DnCNN 进行了地震数据随机噪声去除研究,在 DnCNN 基础上对网络进行了优化。MISRA^[13]提出了平滑非单调的 Mish 激活函数,通过多个任务与训练集的验证证明 Mish 激活函数对最终结果均有明显提高。笔者将 Mish 激活函数应用到 DnCNN 网络中,对其进行优化,并通过峰值信噪比(Peak Signal to Noise Ratio, PSNR)、信噪比(Signal to Noise Ratio, SNR)、均方误差(Mean Square Error, MSE)以及结构相似度(Structural Similarity, SSIM)对优化后的网络 M-DnCNN 的去噪能力进行验证。笔者构建好网络模型后,利用合成地震数据,添加高斯随机噪声作为标签进行模型训练,得到适用于地震数据的去噪网络。将含噪地震数据输入训练好的去噪网络可有效分离随机噪声与有效信号,达到去噪目的。

1 方法原理

笔者深度学习方法部分主要研究了 DnCNN 网

络,并在该网络基础上进行了优化,优化后的网络命名为 M-DnCNN, M-DnCNN 网络由卷积(Convolution, Conv)、批量归一化(Batch Normalization, BN)、激活函数 Mish 三部分组成。深度学习过程为:准备数据集并对数据集进行划分,通常将数据集划分为训练集与测试集;构建 M-DnCNN 网络,进行深度学习模型训练,利用损失函数不断迭代更新学习到的网络参数;对网络模型进行预测即输入含噪地震数据,输出去噪后的地震数据,使用 PSNR 作为评价指标对去噪效果进行评价,后续还添加 SNR、MSE、SSIM 对去噪效果进行进一步评价。具体技术路线如图 1 所示。

1.1 DnCNN 地震数据去噪原理

包含随机噪声的地震数据可由公式(1)表示。

$$y = x + n \quad (1)$$

其中: y 为含噪地震数据; x 为干净地震数据; n 表示随机噪声^[10]。去噪过程为从含噪地震数据 y 中恢复出干净地震数据 x 。常规的图像去噪任务如多层感知机(Multi-Layer Perception, MLP),旨在学习 $F(y) = x$ 映射函数对干净图像进行预测,DnCNN 则利用残差学习的思想训练 $R(y) \approx n$ 映射函数来学习噪声,再利用 $x = y - R(y)$ 得到干净地震数据。残差学习思想的引入解决了网络深度增加导致的性能下降问题,同时由于学习的噪声数据远小于干净数据,数据特征更容易被网络拾取,加快了网络训练速度,提高了去噪性能^[14]。

1.2 批量归一化

在训练深度神经网络过程中,为防止网络输入数据的剧烈变化使神经网络难以快速收敛,需对数据进行归一化处理。批量归一化操作可看作一个特殊的神经网络层,该层加在每一层非线性激活函数之前。深度学习中现有许多归一化方法:BN(Batch Normalization)、LN(Layer Normalization)、IN(In-

stance Normalization)、GN(Group Normalization)、SN(Switchable Normalization)等^[15-19]。其中 BN 是训练模型最常用的归一化方式,其算法流程为:①计算均值 μ_β ;②计算方差 σ_β^2 ;③做归一化;④加入缩放和平移变量 γ, β , 重构出这一层网络所学到的数据分布,具体数学表达为式(2)^[15]。

$$\begin{cases} \mu_\beta = \frac{1}{m} \sum_{i=1}^m x_i \\ \sigma_\beta^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_\beta)^2 \\ \hat{x}_i = \frac{x_i - \mu_\beta}{\sqrt{\sigma_\beta^2 + \epsilon}} \\ y_i = \gamma \hat{x}_i + \beta \equiv \text{BN}_{\gamma, \beta}(x_i) \end{cases} \quad (2)$$

式中: m 为批处理大小; x_i 为上一层神经元的输出数据; \hat{x}_i 为归一化的结果; ϵ 为避免归一化时分母为 0 加入的微小常数; y_i 为归一化后的网络响应。

1.3 Mish 激活函数

激活函数指在神经网络神经元上运行的函数,将神经元的输入映射到输出端,增加神经网络模型的非线性变化。原始 DnCNN 网络中采用的激活函数是 ReLU(Rectified Linear Unit),假设激活层的激活函数为 $f(\cdot)$,则 ReLU 函数的数学表达为式(3)。

$$f(x) = \max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \in [0, +\infty) \quad (3)$$

ReLU 激活函数如图 2 蓝色线条所示,该函数的作用为单侧抑制,当输入负值时,输出为 0,神经元不会被激活,正值时则保持不变,这使得同一时间内只有部分神经元被激活,从而使计算网络稀疏化,提高了计算效率。但这也使 ReLU 存在明显的缺点,即当 $x < 0$ 时,梯度为“0”,那么这个神经元及之后的神经元梯度永远为“0”,导致相应参数之后都不会被更新。

Mish 激活函数是平滑非单调的激活函数,具有无上界、有下界、平滑、非单调的特性,这对提高网络训练结果起到了重要作用。Mish 激活函数上无界特性可以避免训练速度急剧下降问题,下有界产生很强的正则化效果,平滑使训练模型具有更好的泛化能力,非单调特性则有助于保持小部分负值,稳定网络的梯度,避免 ReLU 出现的梯度消失风险。MISRA^[13]在论文中做了大量实验表明,该激活函数在图像分类、图像分割等 70 多个任务中与 15 种不同的激活函数相比,均表现出明显优势。Mish 激活函数如图 2 红色线条所示,数学表达为式(4)。




图 2 激活函数(ReLU、Mish)

Fig. 2 Activation function (ReLU, Mish)

$$f(x) = x \cdot \tanh(\ln(1 + e^x)) \in [0, +\infty) \quad (4)$$

1.4 网络结构

DnCNN 网络共 17 层,第 1 层为卷积(Convolution, Conv)与激活函数(ReLU),其中卷积核数量为 64,卷积核大小为 $3 \times 3 \times c$, c 为通道数,灰度图像通道数设为“1”,彩色图像通道数设置为 3。通过卷积操作生成特征映射,使用 ReLU 作为线性修正单元进行非线性处理,提高网络的非线性表达。第 2 层到第 16 层具有相同的网络结构,每一层为 Conv、批量归一化(batch normalization, BN)、ReLU 级联的结构,卷积核数量同样为 64,大小为 $3 \times 3 \times 64$,并加入 BN,使每一层的输入具有相似分布,有效避免梯度消失问题,进一步提高了网络收敛速度。第 17 层为 Conv,使用 1 个 $3 \times 3 \times 64$ 的卷积核对地震数据进行重构并输出。具体网络结构如图 3 所示。

鉴于 Mish 激活函数的优越性能,笔者考虑在 DnCNN 网络结构的基础上更换 ReLU 激活函数为 Mish 激活函数,对原始 DnCNN 网络进行优化,为在文中进行区分,将优化后的网络命名为 M-DnCNN。由于地震数据更接近于图像处理中的灰度图像,遂将通道数设置为“1”,具体的网络结构如图 4 所示:

1.5 损失函数与评价指标

M-DnCNN 去噪网络使用的损失函数如公式(5)所示。

$$l(\Theta) = \frac{1}{2N} \sum_{i=1}^N \|R(y_i; \Theta) - (y_i - x_i)\|_F^2 \quad (5)$$

式中: $R(\cdot)$ 表示深度学习网络; $\Theta = \{W, b\}$ 为网络训练的参数; W 为权重; b 为偏置。 $\{(y_i, x_i)\}_i^N = 1$

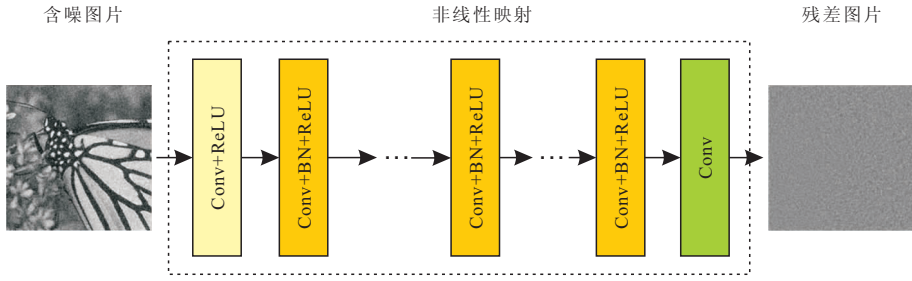


图 3 DnCNN 网络结构

Fig. 3 The architecture of the DnCNN network

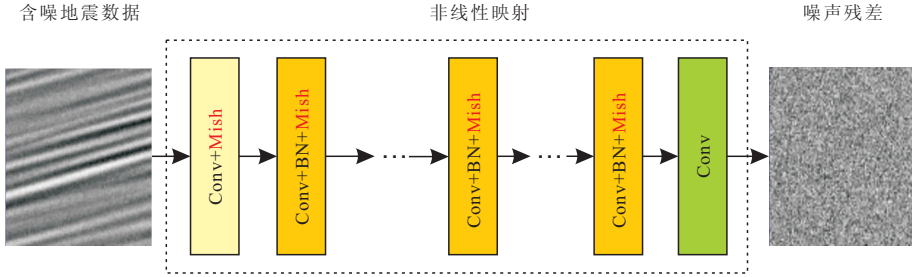


图 4 M-DnCNN 网络结构

Fig. 4 The architecture of the M-DnCNN network




图 5 训练数据

Fig. 5 Training data




图 6 损失函数下降曲线

Fig. 6 Decline curve of loss function

表示 N 个成对训练样本, $\|\cdot\|_F$ 表示 Frobenius 范数。通过网络训练,提取噪声 $R(y)$,计算噪声与原始输入的含噪地震数据的均方误差,实现去噪目的。为了加快网络收敛速度,使损失函数最小化,提出了损失函数优化算法。Adam(Adaptive Momentum Estimation)优化算法^[20]基于训练数据迭代地更新神经网络权重,是一种可替代传统随机梯度下降的一阶优化算法,对于各类问题均具有较好的适应性,所以 M-DnCNN 选用 Adam 优化算法进行网络参数优化。

为评价深度学习去噪性能,选用了 PSNR 作为评价标准进行评价。其对应的数学表达为:

$$PSNR(dB) = 10 \lg \frac{\max(x)^2 m}{\|x - x_d\|_F^2} \quad (6)$$

其中: x 为干净地震数据; x_d 为去噪后的地震数据; m 为地震数据采样点。PSNR 值越大,表明失真越小,去噪效果越好。

2 合成数据去噪

本文训练和测试网络模型的环境为: Inter Xeon CPU E5-2650, 具有 48 个核心, 主频为 2.20 GHz, 32 G 内存, 主显卡为 Nvidia Quadro P4000, 4

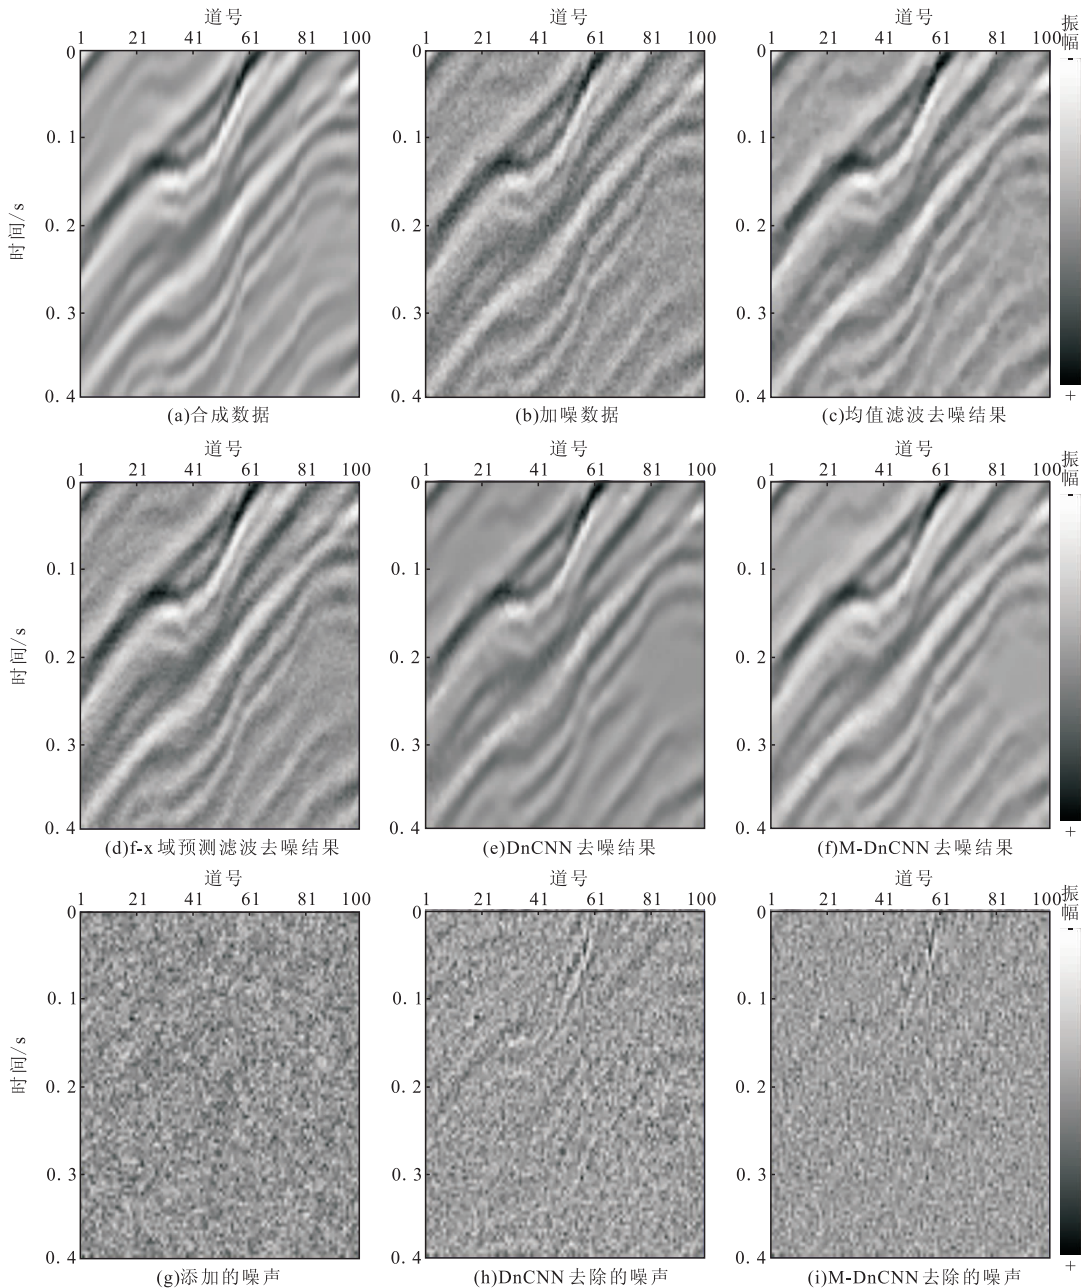


图7 合成数据去噪

Fig. 7 Synthetic data denoising

GB 显存,深度学习框架为 PyTorch 1.7.0。

2.1 网络模型训练

深度学习的实质是利用海量训练数据,来学习更有用的特征,从而提升最终预测的准确性。深度学习将数据集划分为训练集和测试集两部分。训练集在深度学习模型训练的过程中使用,用于网络模型拟合。测试集则用于判断网络模型是否足够有效,评估最终网络模型的泛化能力。为验证 M-DnCNN 网络的去噪效果,选用了 SEG 网站公开的合成数据([https://wiki.seg.org/wiki/1994 BP mi-](https://wiki.seg.org/wiki/1994_BP_mi)

gration from topography)作为深度学习数据集。该数据由 Joe Dellinger 提供,与真实数据十分接近,其数据类型为叠前数据,格式为 SEG Y,共 123 600 道,每道 2 000 个采样点,时间采样间隔为 4 ms。取前 500 道数据展示,如图 5 所示。

笔者对该数据手动添加 25% 高斯随机噪声作为噪声标签,制作样本进行深度学习模型训练与测试。将该数据以 8:2 的比例划分为训练集与测试集,为使测试更具真实性,取前 10 000 道与后 10 000 道地震数据作为测试数据,中间部分数据则

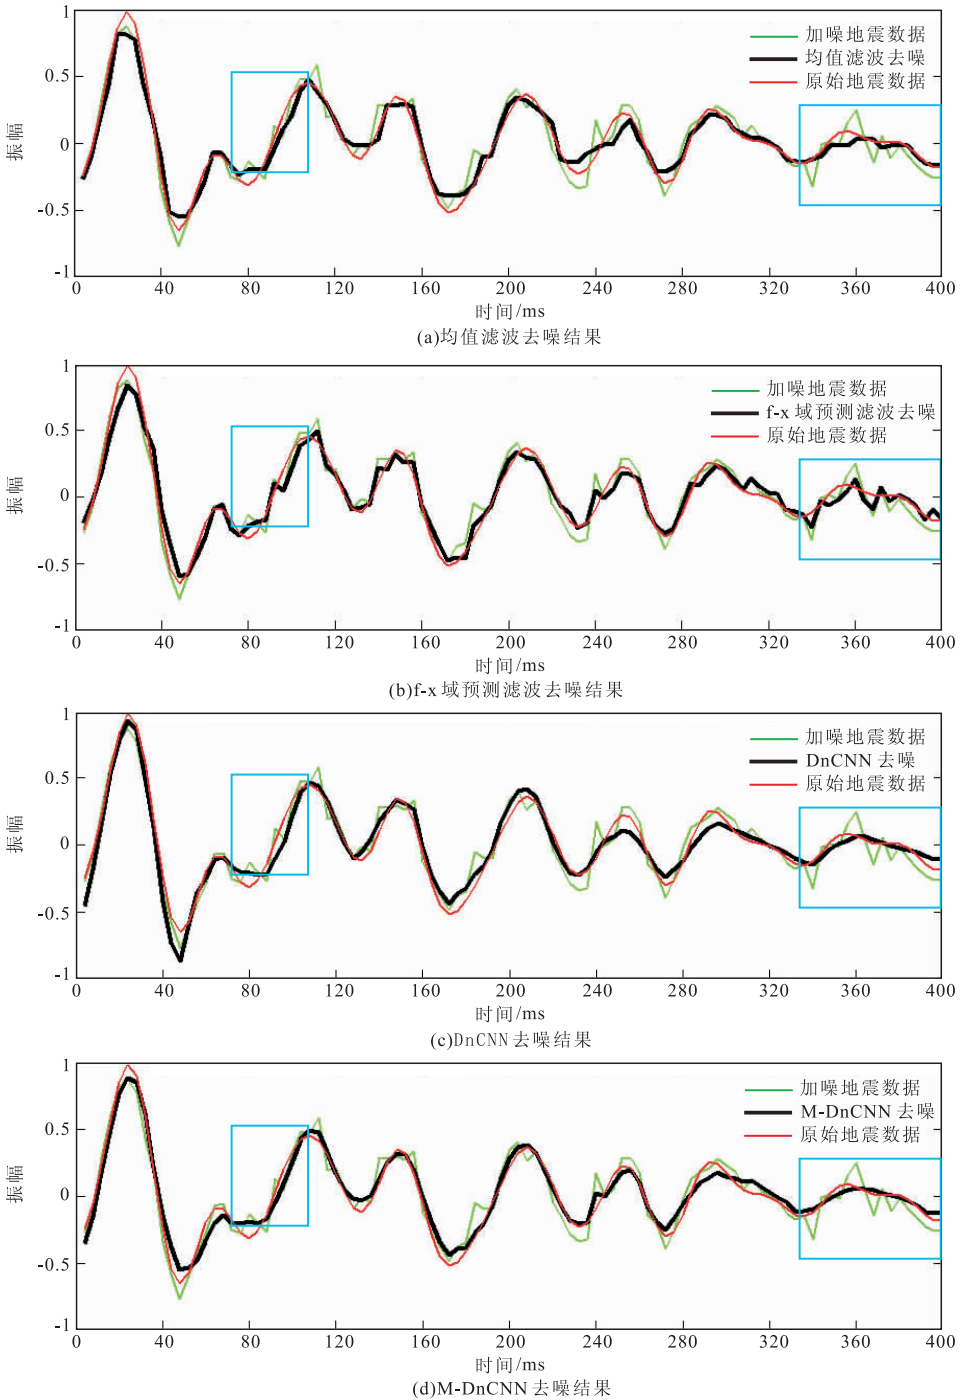


图 8 单道时域比较

Fig. 8 Single channel time domain comparison

用于训练网络。设置迭代次数(epoch)为 50, 初始学习率(learning rate)为 0.001, 在经过 30 次迭代之后学习率降为 0.0002。采用 Adam 优化算法进行优化, 批处理大小(batch size)为 128, 为加快网络训练速度与节省内存将地震数据切割成 40×40 的小块(patch size)。在训练数据生成过程中对数据进行上下翻转、旋转 90° 、旋转 180° 、旋转 270° 等处

理, 增强数据。网络模型训练过程如图 6 所示。

从图 6 中可以看出, M-DnCNN 与 DnCNN 相比损失函数下降得更快, 趋于稳定的损失值更小, 说明在损失函数的表现上 M-DnCNN 优于 DnCNN。

2.2 合成数据去噪

采用合成地震数据的测试集对网络模型进行测试, 取测试集中变化明显的 100 道进行局部展示, 如

图 7 所示。图 7(a)为原始地震数据,对其添加 25% 高斯随机噪声后的地震资料如图 7(b)所示。对比图 7(a)和图 7(b),可看出合成数据加噪后噪点严重,同相轴变得模糊。利用传统的 $f-x$ 域预测滤波与均值滤波方法进行去噪,虽然压制了部分随机噪声,但地震数据仍有较多清晰可见的随机噪点,还出现了部分细节损失。两种深度学习方法的去噪效果明显优于传统的滤波方法,随机噪声残余较少,与加噪前的干净地震数据更接近。对比图 7(e)和 7(f),可以看出 M-DnCNN 的去噪结果将细节保留得更好。对比图 7(g)、7(h)、7(i)添加的噪声与去除的噪声,可发现 M-DnCNN 去噪结果有效信号损失更少。为了对去噪性能进一步分析,采用第 60 道地震数据进行单道记录比较,如图 8 所示。对比蓝色方框内数据,可以看出在有效信号与随机噪声混叠部分,深度学习去噪方法效果优于传统去噪方法,能去除更多的随机噪声。M-DnCNN 恢复原始信号的能力优于 DnCNN。

利用 PSNR 评价指标对比了 4 种不同的去噪方法在该测试地震数据中的去噪性能(表 1)。可以看出,M-DnCNN 优于原始 DnCNN,且优于传统的均值滤波与 $f-x$ 域预测滤波。相比于 $f-x$ 域预测滤波方法在 SNR 上提高了 1.9 dB,相比于 DnCNN 方法同样有 1.1 dB 的提高。

此外,本次研究还加入 SNR、MSE、SSIM 对四种方法的去噪效果进行进一步评价。其对应的数学表达式为:

$$SNR(dB) = 10 \lg \frac{\|x\|_F^2}{\|x - x_d\|_F^2} \quad (7)$$

$$MSE = \frac{\|x - x_d\|_F^2}{m} \quad (8)$$

$$SSIM(x, x_d) = \frac{(2\mu_x \mu_{x_d} + C_1)(2\sigma_{xx_d} + C_2)}{(\mu_x^2 + \mu_{x_d}^2 + C_1)(\sigma_x^2 + \sigma_{x_d}^2 + C_2)} \quad (9)$$

其中: x 为干净地震数据; x_d 为去噪后的地震数据; m 为地震数据采样点; μ_x, μ_{x_d} 为 x, x_d 的均值; σ_{xx_d} 为 x, x_d 的协方差; $\sigma_x^2, \sigma_{x_d}^2$ 为 x, x_d 的方差; C_1, C_2 为避免分母为零加入的调整常数。

SNR 值越大,表明处理后的地震数据失真越小,去噪效果越好。MSE 是两个数据差值的平方和,范围为 $[0, +\infty)$,当两个数据完全相同时 MSE 为“0”,所以当误差越小时 MSE 越小,去噪效果也越好。SSIM 是衡量两幅图像相似度的指标,取值范围为 $[0, 1]$,值越大去噪效果越好。

可以看出表 1 中 M-DnCNN 在 SNR、MSE、SSIM 三项评价指标中仍表现最优,均值滤波在各评价指标数值上表现仅次于 M-DnCNN,细节保留较好,但随机噪声残留均高于深度学习方法。

表 1 地震数据去噪性能对比

Tab. 1 Comparison of seismic data denoising performance

评价指标 去噪方法	PSNR	SNR	MSE	SSIM
均值滤波	25.039307	11.889714	0.003134	0.777533
$f-x$ 域预测滤波	23.708991	10.559424	0.004257	0.734415
DnCNN	24.487991	11.338423	0.003558	0.740221
M-DnCNN	25.635424	12.485857	0.002732	0.780236

表 2 地震数据去噪性能对比

Tab. 2 Comparison of seismic data denoising performance

评价指标 去噪方法	PSNR	SNR	MSE	SSIM
DnCNN	29.440891	16.633981	0.001137	0.826410
M-DnCNN	30.907340	18.100429	0.000811	0.867155

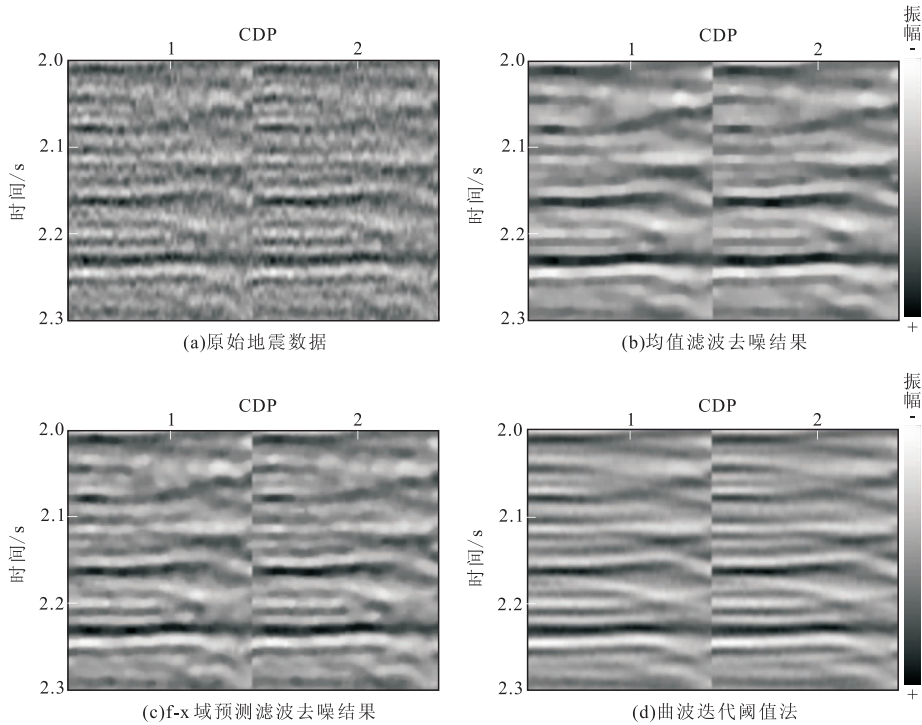


图 9 对(a)使用不同方法的去噪结果

Fig. 9 Denoising results using different methods for (a)

3 实际数据去噪

笔者采用 M-DnCNN 对合成叠前地震数据进行去噪实验,并与 DnCNN 去噪方法以及经典传统去噪方法进行对比发现 M-DnCNN 具有明显优势。现将 M-DnCNN 应用到实际地震数据中,进一步检验其去噪效果。

3.1 网络模型训练

为使网络模型即保留从合成地震数据学习到的特征,又能学习到实际地震数据的特征,笔者在合成数据训练好的模型基础上,进行网络训练用于解决实际地震数据的去噪问题。合成地震数据可直接添加指定等级的高斯随机噪声作为标签进行网络训练,此时标签数据已知,实际地震数据中随机噪声为未知,所以在进行实际地震数据去噪网络训练前需完成噪声标签的获取。选取 A 地区陆上叠前偏移距道集进行 M-DnCNN 方法去噪验证。该数据为三维数据体,随机抽取其 inline1500、inline1501 两条测线数据构建二维数据样本。数据共 424 个 CDP 道集,每个 CDP 下有 64 道,其偏移距范围在

100 m~6 211 m 之间,时间采样间隔为 2 ms,采样点为 3 000。分别利用均值滤波、f-x 域预测滤波、曲波迭代阈值法对图 9(a)数据进行去噪处理,截取其中 300×128 大小的地震记录进行展示,如图 9 (b)、图 9(c)、图 9(d)所示。对其频谱与信噪比进行分析对比可知曲波迭代阈值法的去噪与保幅能力优于 f-x 域预测滤波与均值滤波方法,但其运算效率远低于 f-x 域预测滤波与均值滤波。由于曲波迭代阈值法经过精细调参对原始含噪地震数据进行去噪处理的去噪效果最优,遂将其去噪结果作为噪声标签。

制作好样本后,将该实际地震数据以 8:2 的比例划分为训练集与测试集。学习率、优化算法、批处理大小等网络超参数均与合成地震数据训练 DnCNN、M-DnCNN 网络所用超参数相同,网络模型在合成地震数据训练好的模型基础上进行再训练,迭代次数为 20。

3.2 实际数据去噪

图 10(a)为实际含噪地震数据,图 10(b)、10(c)、10(d)为传统方法去噪后地震数据。从图 10




图 10 实际数据去噪

Fig. 10 Actual data denoising

(a)可以看出,原始叠前地震数据被随机噪声干扰,整体存在同相轴模糊,信噪比低的特点,强烈的背景噪声影响地震数据拾取精度,对后续的地震数据处理产生影响。图 10(b)为曲波迭代阈值法去噪结果,去除了大部分的随机噪声,但仍存在部分噪点。图 10(c)为经过 DnCNN 网络模型去噪后的地震数据,明显看出随机噪声得到了有效压制,信噪比提高,同相轴变得更清晰,DnCNN 与 M-DnCNN 的去噪效果优于传统的曲波迭代阈值法。这是由于网络在保留从合成地震数据学到特征的同时,也学习到了曲波迭代阈值法去噪后地震数据的特征,所以 DnCNN 与 M-DnCNN 的去噪结果较曲波迭代阈值法更优,可以去除更多的随机噪声。图 10(d)为 M-DnCNN 方法去噪结果,剖面上与 DnCNN 去噪效果差异较小,但通过计算其 PSNR 等评价指标进行对比可以看出 M-DnCNN 去噪效果优于 DnCNN 方法的去噪效果,具体如表 2 所示。

表 2 中对深度学习去噪方法的去噪性能进行对比,M-DnCNN 方法去噪后的 PSNR 与 SNR 均比 DnCNN 方法高 1.47 dB。在结构相似度指标中 M-DnCNN 方法也高出 DnCNN 方法 0.04。表 2 可说明 M-DnCNN 方法在 PSNR、SNR、MSE、SSIM 四项评价指标中均优于 DnCNN。

4 结论

在 DnCNN 卷积神经网络的基础上更改激活函数 ReLU 为 Mish,优化了原始网络,优化后的网络命名为 M-DnCNN。利用该网络对地震数据随机噪声进行压制,通过合成地震数据与实际地震数据的去噪验证,证明该方法能在提高地震数据信噪比的同时,保留地震数据细节,有效去除地震数据随机噪声。在本次研究的测试数据中 M-DnCNN 与 DnCNN 相比,M-DnCNN 方法在 PSNR 上有

1.15 dB~1.47 dB 的提升,在 SNR、MSE、SSIM 评价指标中均优于 DnCNN 方法。M-DnCNN 方法与均值滤波、 $f-x$ 域预测滤波等传统去噪算法相比仍具有更好的去噪性能。深度学习训练好的去噪网络可以直接用于地震数据去噪,无需人工调参,操作简单。下一步工作为分析 M-DnCNN 方法的泛化性,构建更多高质量样本进行网络训练,并尝试利用 M-DnCNN 方法对面波、声波、线性干扰、多次波、侧面波等规则噪声进行去噪研究。

参考文献:

- [1] CANALES L L. Random noise reduction[J]. *Geophys*,1984,54(1): 525-527.
- [2] 夏洪瑞,朱勇,周开明.小波变换及其在去噪中的应用[J].*石油地球物理勘探*,1994,29(3):274-285.
XIA H R, ZHU Y, ZHOU K M. Wavelet transform and its application to noise elimination[J]. *OGP*,1994, 29(3):274-285. (In Chinese)
- [3] HOEBER H, BRANDWOOD S, WHITCOMBE D N. Structurally consistent filtering[C]. 68th EAGE Conference and Exhibition incorporating SPE EUROPEC, 2006(2):375-381.
- [4] LU W K. Adaptive noise attenuation of seismic images based on singular value decomposition and texture direction detection[J]. *Journal of Geophysics and Engineering*, 2006,3(1): 28-34.
- [5] 汪金菊,袁力,刘婉如,等.地震信号随机噪声压制的双树复小波域双变量方法[J].*地球物理学报*,2016,59(08):3046-3055.
WANG J J, YUAN L, LIU W R, et al. Dual-tree complex wavelet domain bivariate method for seismic signal random noise attenuation[J]. *Geophys*,59(8): 3046-3055. (In Chinese)
- [6] HERRMANN F J, HENNENFENT G. Non-parametric seismic data recovery with curvelet frames[J]. *Geophysical Journal International*,2008,173(1): 233-248.
- [7] LIANG J W, MA J W, ZHANG X Q. Seismic data restoration via data-driven tight frame[J]. *Geophysics*, 2014, 79(3): V65-V74.
- [8] 刘迪,贾金露,赵玉卿,等.基于深度学习的图像去噪方法研究综述[J].*计算机工程与应用*,2021,57(7): 1-13.
LIU D, JIA J L, ZHAO Y Q et al. Overview of image denoising methods based on depth learning[J] *Computer Engineering and Application*, 2021, 57 (7): 1-13. (In Chinese)
- [9] 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 T,CHI Y. Deep learning convolutional neural networks for random noise attenuation in seismic data[J].*Geophysical Prospecting for Petroleum*,2018,57(6): 862-869. (In Chinese)
- [10] 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 Y Q,LU W K,LIU J L,et al. Random seismic noise attenuation based on data augmentation and CNN [J]. *Geophys*,2019,62(1):421-433. (In Chinese)
- [11] YU S W, MA J W, WANG W L. Deep learning for denoising[J]. *Geophysics*, 2019, 84 (6): V333 - V350.
- [12] ZHANG K. Beyond a gaussian denoiser:Residual learning of deep cnn for image denoising[J]. *IEEE Transactions on Image Processing*,2017,26(7):3142-3155.
- [13] MISRA D. Mish: A self regularized non-monotonic neural activation function[J]. *ArXiv Preprint ArXiv*, 2019, 4(2): 1908-08681.
- [14] ZHAO Y X. Low-frequency noise suppression method based on improved DnCNN in desert seismic data [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018,16(5): 811-815.
- [15] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. *International Conference on Machine Learning PMLR*,2015:448-456.
- [16] BA J L, KIROS J R, HINTON G E. Layer normalization[J]. *ArXiv Preprint ArXiv*,2016,2(4):1607-06450.
- [17] ULYANOV D, VEDALDI A, LEMPITSKY V. In-

- stance normalization; The missing ingredient for fast stylization[J]. ArXiv Preprint ArXiv,2016,2(5):1607-08022.
- [18] WU Y X, HE K M. Group normalization[C]. Proceedings of the European Conference on Computer Vision (ECCV),2018;3-19.
- [19] LUO P. Differentiable learning - to - normalize via switchable normalization[C]. ICLR,2019;38-57.
- [20] KINGMA D P, BA J. Adam: A method for stochastic optimization[C]. ICLR,2015;1-41.

Seismic data denoising method based on feedforward denoising convolution neural network

WANG Danli^{a,c}, ZHOU Huailai^{a,b,c}, WANG Yuanjun^{a,b}, LU Fen^{a,c}, HE Pingyi^{a,c}

(1. Chengdu University of Technology a. College of Geophysical,

b. State Key Laboratory of Oil and Gas Reservoir Geology and Exploitation,

c. Key Laboratory of Earth Exploration and Information Technology of Ministry of Education, Chengdu 610059, China)

Abstract: Random noise suppression is an effective method to improve the signal-to-noise ratio of seismic data. This paper studies the removal of random noise of seismic data using the depth learning denoising method of feedforward denoising convolution neural network(DnCNN). At the same time, M-DnCNN network is constructed by using a mish activation function further to improve the denoising performance of the network model. This method is based on neural network and statistical principles, automatically extracts features through convolution neural network, and uses a single residual unit to predict noise, that is, input noisy seismic data, output predicted noise after M-DnCNN learning, and make a difference between input and output noise to obtain denoised seismic data. In the experimental part, firstly, the denoising effect of this method is verified by synthetic seismic data. At the same time, M-DnCNN is compared with mean filtering and f-x domain prediction filtering methods. The results show that M-DnCNN is better than the original DnCNN in removing random noise from seismic data and can suppress random noise more effectively than the other two denoising methods. M-DnCNN is used in the denoising experiment of actual seismic data. The experiment shows that M-DnCNN also applies to denoising processing of actual seismic data. It can achieve a good denoising effect while retaining and highlighting effective signals.

Keywords: random noise; seismic data denoising; mish activation function; M-DnCNN