

基于 HS-DnCNN 网络的地震数据随机噪声去除

姜懿珈^{1,3}, 周怀来^{1,2,3}, 陈姝颖^{1,3}, 吕芬^{1,3}

(1. 成都理工大学地球物理学院, 成都 610059;

2. 成都理工大学油气藏地质及开发工程国家重点实验室, 成都 610059;

3. 成都理工大学地球探测与信息技术教育部重点实验室, 成都 610059)

摘要: 地震数据作为油气勘探与开发的重要支撑, 在实际应用中往往受到各种噪声的干扰, 影响了数据的质量和解释的准确性。本研究旨在改进现有噪声抑制网络 (Denoising Convolutional Neural Network, DnCNN), 提升其在地震数据随机噪声去除中的能力。在去噪的实验中, 我们深入研究了 DnCNN 的设计和性能影响。通过对比常用的激活函数, 包括传统的 ReLU 和 Hard-swish, 系统地评估了它们在地震数据去噪中的表现。实验结果表明, Hard-swish 构建的 HS-DnCNN 网络在去除地震数据随机噪声方面优于原始 DnCNN, 并且相较于其他的去噪方法, 更有效地抑制了随机噪声。随后, 我们将 HS-DnCNN 应用于实际地震数据的去噪实验, 验证了其在实际场景中同样具有良好的适用性。HS-DnCNN 在保留并突出有效信号的同时, 展现出较好的去噪效果。

关键词: 地震数据去噪; 随机噪声; Hard-swish 激活函数; DnCNN

中图分类号: P631.443 文献标志码: A DOI: 10.12474/wthtjs.20240108-0001

Removal of random noise in seismic data based on HS-DnCNN network

JIANG Yijia^{1,3}, ZHOU Huailai^{1,2,3}, CHEN Shuying^{1,3}, LV Fen^{1,3}

(1. College of Geophysical, Chengdu University of Technology, Chengdu 610059, China;

2. State Key Laboratory of Oil and Gas Reservoir Geology and Exploitation,
Chengdu University of Technology, Chengdu 610059, China;

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

Abstract: Seismic data, a crucial tool for exploration and monitoring, often faces interference from various noises, impacting the quality and accuracy of data interpretation. This study aims to improve the existing noise suppression network, Denoising Convolutional Neural Network (DnCNN), and enhance its ability to remove random noise from seismic data. In the denoising experiments, we extensively explore the design and performance influences of DnCNN. We systematically evaluate their performance in seismic data denoising by contrasting common activation functions, including traditional ReLU and Hard-swish. Results indicate that the HS-DnCNN network, constructed with Hard-swish, outperforms the original DnCNN in suppressing random noise. Moreover, compared to other denoising methods, it more effectively mitigates random noise. Subsequently, we apply HS-DnCNN to practical

收稿日期: 2024-01-08

第一作者: 姜懿珈(1998—), 女, 硕士, 主要从事地球物理信息处理研究, E-mail: 354716115@qq.com。

引用格式: 姜懿珈, 周怀来, 陈姝颖, 等, 2025. 基于 HS-DnCNN 网络的地震数据随机噪声去除[J]. 物探化探计算技术, 47(2): 169-178.

Jiang Y J, Zhou H L, Chen S Y, et al., 2025. Removal of random noise in seismic data based on HS-DnCNN network[J]. Computing Techniques For Geophysical and Geochemical Exploration, 47(2): 169-178.

seismic data denoising experiments, validating its excellent applicability in real-world scenarios. HS-DnCNN demonstrates superior denoising effects while preserving and emphasizing essential signals. This summarizes the essence of our study.

Keywords: seismic data denoising; random noise; Hard-swish activation function; DnCNN

0 引言

目前地震数据在勘探领域中扮演着不可或缺的角色,然而在实际应用中往往会受到多种噪声的干扰,从而影响数据的质量和解释的准确性,数据的清晰度直接关系到对地下结构的准确识别。因此,去除噪声成为提升地震数据质量中至关重要的步骤之一。随机噪声作为地震数据中常见的一种噪声类型,其复杂性和随机性给数据处理带来了挑战。

地震数据处理领域的学者们提出各种多样而有效的去噪方法,主要包括空间域、变换域、混合域和深度学习去噪方法。空间域去噪方法(Stumpf et al., 2014)主要关注于结构相似性,以确保去噪过程中相似结构的保留。其中,非局部均值算法(Buades et al., 2008)被应用于地震数据的去噪,其核心思想是通过确定相似结构的块来进行分组去噪。这种方法在断层处能够有效保持地震能量,以达到保持边缘信号的良好效果,但该方法计算耗时长且代价大。变换域去噪方法(Chen and Fomel, 2015)采用了多种策略,其中包括小波变换(Mousavi and Langston, 2016)、Shearlet 变换(Tang et al., 2018)和曲波变换(彭才等, 2008)等。小波变换采用分层的方法进行多尺度分解,变换后的尺度系数不同并且计算的复杂度高。Shearlet 变换在小波变换的基础上进行了计算方面的改进,但在弱信号和噪声的区分上并不是很有效。曲波变换与一些全局表示方法不同,更关注信号的局部特征,具有一定的适应性,在捕捉信号不同特征上更加灵活,但引入自适应性后计算也会变得复杂,需要进行优化。混合域去噪方法(Starck et al., 2003)将多个域的优点结合起来,以提升去噪效果。通常结合时域和频域,或者其他变换域的信息,以更全面地理解和处理信号。混合域去噪方法通常需要人为调整有一些参数来获得最佳的去噪效果,如权重、阈值等(Li et al., 2017)。

传统去噪方法通常更需要领域的专业知识,较难适应复杂多变的噪声情况。并且传统方法可能不具备普适性,对于不同类型的噪声和不同的应用场景可能需要不同的调整和参数的设置,对非线性关

系的建模能力较差,而地震数据中通常存在复杂的非线性噪声,深度学习方法的兴起弥补了这些不足,通过大规模数据处理以及复杂的模型结构,更好地适应实际应用中复杂多样的地震噪声。

鉴于深度学习在图像去噪的领域表现优异,和传统的地震数据去噪过程相比,深度学习的引入能够很大程度的地节省运算过程的时间和人力成本。噪声抑制网络成为一种有效的手段,其中卷积神经网络(Convolutional Neural Networks, CNN)被广泛运用于地震数据去噪(Yu and Ma, 2021)、地震数据反演(Li et al., 2020)和地震岩性预测(Zhang et al., 2018)等,其原理是通过卷积操作捕捉地震信号和噪声之间的空间特征,从而实现地震数据的去噪,具有局部感知和参数共享的优点,能够有效地捕捉数据中的局部特征和减少参数数量,这能提高模型的泛化能力,适应不同的地质结构和噪声分布的地震数据。基于 CNN 压制地震数据随机噪声的去噪卷积神经网络(Denoising Convolutional Neural Network, DnCNN)方法取得了很好的去噪效果(Zhang et al., 2017)。它无需手动设置特征提取器,可以直接从输入的地震数据中学习信号和噪声的表示,提高对复杂数据模式的建模能力。现已有许多学者将深度学习引入到地震数据去噪中,彭清等(2022)构建基于残差学习的 DnCNN 模型进行去噪;王钰清等(2019)提出基于数据增广的 CNN 训练框架进行地震随机噪声压制,增强网络的推广性,是一种直接从无标签有噪数据生成标签数据集的方法;王丹荔等(2023)通过修改 DnCNN 网络中的激活层来提升网络模型的去噪性能。

DnCNN 为地震数据处理提供了新的思路和解决方案,该算法特别设计用于图像去噪,通过学习地震数据中的特征,在去噪方面也有较好的表现。笔者基于 DnCNN 对地震随机噪声去除进行了研究,在 DnCNN 的网络模型上进行了修改及优化。Howard et al.(2019)在 MobileNet V3 中提出了 Hard-swish 激活函数,与普通的 ReLU(Glorot et al., 2011)、Sigmoid(Elfwing et al., 2018)等激活函数相比,Hard-swish 激活函数在计算速度上都更快且计算代价很小,在各种分类和回归任务中表现出更低的训练误

差和更优秀的测试准确度。为了提高收敛速度,并且能够更好地处理梯度信息,笔者将 Hard-swish 激活函数应用到 DnCNN 网络中,使得神经网络更容易训练。通过对比信噪比(Signal to Noise Ratio, SNR)、峰值信噪比(Peak Signal to Noise Ratio, PSNR)这两个图像质量评价指标,以及均方误差(Mean Square Error, MSE)、结构相似度(Structural Similarity, SSIM)来反映模型输出与真实标签之间的差异来对优化的 HS-DnCNN 网络进行去噪能力的验证。笔者建立了去噪网络模型,并通过使用合成地震数据,在数据中添加高斯随机噪声作为模型的标签进行训练。通过这一过程,获得适用于地震数据的优化去噪网络。在训练好的网络中输入含有噪声的地震数据,网络能够有效地分离出随机噪声与有效信号,从而达到了去噪的目的。

1 基本原理

笔者使用 DnCNN 网络,并在该网络的基础上进行激活层优化,优化后命名为 HS-DnCNN,该网络构建包括卷积(Convolution, Conv)、批量归一化(Batch Normalization, BN)、激活函数 Hard-swish 三个主要组成部分。深度学习的步骤首先设计数据集的准备和划分,笔者将数据集划分为训练集和测试集;构建 HS-DnCNN 网络,通过损失函数对网络参数进行不断迭代更新,输入训练集进行深度学习模型的训练;训练完成后,将含有噪声的地震数据即测试集输入到网络中,得到去噪后的地震数据。笔者采用 PSNR 作为评价的主要指标,再根据 SNR、MSE、SSIM 指标对去噪效果进行深入评估。

1.1 DnCNN 地震数据去噪原理

含噪地震数据由无噪地震数据与噪声组成,表达式为:

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

式中: x 表示无噪地震数据, N 表示随机噪声, y 表示含噪地震数据。假设 N 服从高斯分布,表示为:

$$N \sim N(\mu, \sigma^2) \quad (2)$$

式中: μ 代表均值; σ 代表方差。DnCNN 通过残差学习构建更深的网络,利用残差学习将含噪地震数据映射到残差数据之中。 $R(y) \approx \hat{N}$ 为映射函数,为了得到无噪地震数据 x ,将含噪地震数据 y 减去网络中预测得到的噪声 \hat{N} ,即:

$$x = y - \hat{N} \quad (3)$$

1.2 批量归一化

在训练神经网络的过程中,通常出现数据的变化使神经网络难以收敛,而归一化处理有助于维持每层输入的分布稳定,减少训练过程中的梯度消失或梯度爆炸问题,从而提高训练的稳定性和速度。归一化在深度学习中有多种形式,包括批量归一化(Batch Normalization, BN)、层归一化(Layer Normalization, LN)、组归一化(Group Normalization, GN)等。其中 BN 是一种深度学习网络中常用的技术,其基本思想是对神经网络的输入进行归一化,通过线性变换缩放和平移来规范神经网络的每一层的输入分布。其步骤为:①计算每个维度上的均值 $mean(x_i)$ 和方差 $var(x_i)$;②进行归一化,使均值为 0,方差为 1;③通过加入缩放因子 γ 和平移因子 β 进行缩放和平移,将归一化后的值映射到所需的尺度和位置;④学习参数, γ 和 β 通过反向传播进行学习。其中计算表达式为:

$$\begin{cases} mean(x_i) = \frac{1}{m} \sum_{i=1}^m x_i \\ var(x_i) = \frac{1}{m} \sum_{i=1}^m (x_i - mean(x_i))^2 \\ \hat{x}_i = \frac{x_i - mean(x_i)}{\sqrt{var(x_i) + \varepsilon}} \\ y_i = \gamma \hat{x}_i + \beta \equiv BN_{\gamma, \beta}(x_i) \end{cases} \quad (4)$$

式中: m 表示批处理大小, x_i 表示上一网络层的输出, \hat{x}_i 表示归一化后的值, ε 表示为了稳定计算而加的小常数, y_i 表示归一化层处理后的最终输出。

1.3 Hard-swish 激活函数

激活函数是神经网络中的一个关键组件,其通过非线性转换为神经网络引入了强大的表达能力,如果没有激活函数,多个线性层的组合仍然是线性变换,通过引入线性激活函数,可以将每一层的输出变为非线性函数。这使得神经网络能够学到更加复杂的特征。其中,最常见的激活函数之一是 ReLU (Rectified Linear Unit),原始的 DnCNN 网络就是采用的该激活函数,其具有收敛速度快和稀疏表达性好的优点。ReLU 函数如图 1 中红色线条所示,其数学表达式为:

$$ReLU(x) = \max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \in [0, +\infty) \quad (5)$$

在 $x < 0$ 时,ReLU 是完全不活动的,即不参与计算,这表示在反向传播过程中,如果输入一个负数,梯度将完全为零,相应参数在之后都不会被更新,这会在学习地震数据中导致部分信息消失。除了

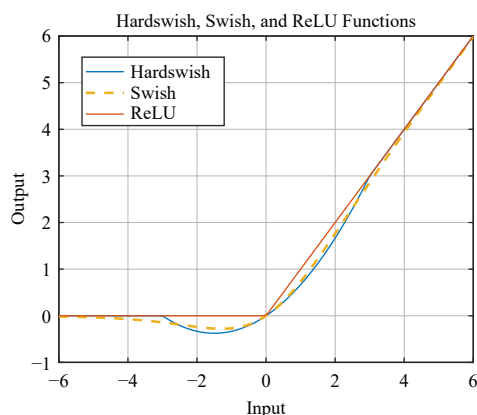


图1 激活函数 (ReLU、Swish、Hard-swish)

Fig. 1 Activation function

ReLU 还有一种常用的非线性激活函数 Sigmoid, 其数学表达式为:

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

它能够把输入的连续值变换为 0~1 之间的输出, 在 $[-2, 2]$ 区间内, 梯度变化明显, 相应的这会容易出现梯度弥散, 反向传播时, 容易出现梯度消失和梯度爆炸的情况, 从而无法完成深层网络的训练。

Swish(Scaled Exponential Linear Unit with Squashing Hyperbolic Tangent) 激活函数 (Ramachandran, 2018) 是 ReLU 和 Sigmoid 函数的结合体, 具备无上下界、平滑、非单调的特性, Swish 函数如图 1 中黄色线条所示, 其数学表达式为:

$$\text{Swish}(x) = \frac{x}{1 + e^{-x}} = x \cdot \text{Sigmoid}(\beta x) \quad (7)$$

式中: β 代表可训练的参数或一个常数。通过将 Sigmoid 函数与输入值相乘的方式, 实现了线性和非线性的融合。在输入的绝对值较小时, 即接近零时逼近线性函数 x , 达到线性的表现, 这个阶段有助于保留输入的相关信息 (He et al., 2016)。随着输入值的变大, Swish 的表现趋向于 Sigmoid, 输出值以一种先增长快, 随着输入值进一步增加, 增长速度减慢的形式进行训练, 这个阶段有助于提供更强的拟合能力。其具有在整个输入域上都是平滑函数的特点, 没有像 ReLU 那样的不连续点, 它在整个域上都连续可导, 这可以帮助神经网络训练更加稳定, 加速训练的收敛过程, 缩短训练时间。

经过以往部分实验表示, Swish 函数在更深的网络层使用才能体现其优势, 它在嵌入式环境中带来了非零成本, 因此计算代价会更大, 于是将其中的 Sigmoid 函数替换为它的分段线性硬界限函数 (Avenash and Viswanath, 2019): $\frac{\text{ReLU}(6(x+3))}{6}$, 提

出一种与 Swish 的近似函数 Hard-swish 激活函数, Hard-swish 函数如图 1 中蓝色线条所示, 其数学表达式为:

$$h\text{-swish}(x) = x \cdot \frac{\text{ReLU}(6(x+3))}{6} \quad (8)$$

它只涉及到简单的乘法计算和 ReLU 计算, 没有涉及到复杂的 Sigmoid 函数, 这个近似减少了计算的复杂性, 同时在实际应用中的性能表现接近 Swish 激活函数。

1.4 残差学习

随着网络层数的增加, 优化变得更加困难, 即中间层的表示能力受限, 同时, 网络的参数数量也会增加, 容易导致过拟合。残差学习解决了神经网络训练中的退化问题, 它引入了跨层的直接连接, 使得网络可以学习残差, 即噪声的分布特征。这个残差函数通过添加跨层连接, 即“残差块”(Residual Block)来表示。

1.5 网络模型

DnCNN 网络是一种设计用于图像去噪的深度神经网络, 具有 17 层的深度结构, 并移除了所有的池化层 (Simonyan and Zisserman, 2014)。这些层分为三种类型: ①第 1 层为 Conv 层与 ReLU 激活函数, 使用 64 个卷积核生成的 $3 \times 3 \times c$ 大小的特征映射, 其中 c 表示图像的通道数, $c=1$ 时表示灰度图像, $c=3$ 时表示彩色图像; ②第 2 层到第 16 层具有相同的网络结构, 由 Conv 层、BN 层、ReLU 激活函数构成, 使用 64 个大小为 $3 \times 3 \times 64$ 的卷积核对比第 1 层的结构, 在 Conv 层与 ReLU 激活函数之间添加了批量归一化层来加快训练速度, 提高去噪性能; ③第 17 层只设置 Conv 层, 使用 c 个大小为 $3 \times 3 \times 64$ 个卷积核重构输出。由于地震噪声数据更接近灰度图像, 将通道数 c 设置为“1”, 即第 17 层使用 1 个 $3 \times 3 \times 64$ 的卷积核对地震数据进行处理。为了更好地权衡性能和效率, 将架构设计中的 ReLU 激活函数替换为表现效果更优秀的 Hard-swish 激活函数, 在此基础上对初始 DnCNN 的网络进行优化, 与原 DnCNN 进行区分, 将优化后的网络命名为 HS-DnCNN, 具体的网络结构如图 2 所示。

1.6 评价指标

为了度量网络的输出与真实目标之间的差异, 通常将损失函数用于网络的最后部分, 其输出是网络对输入数据的估计。常见的损失函数包括均方误

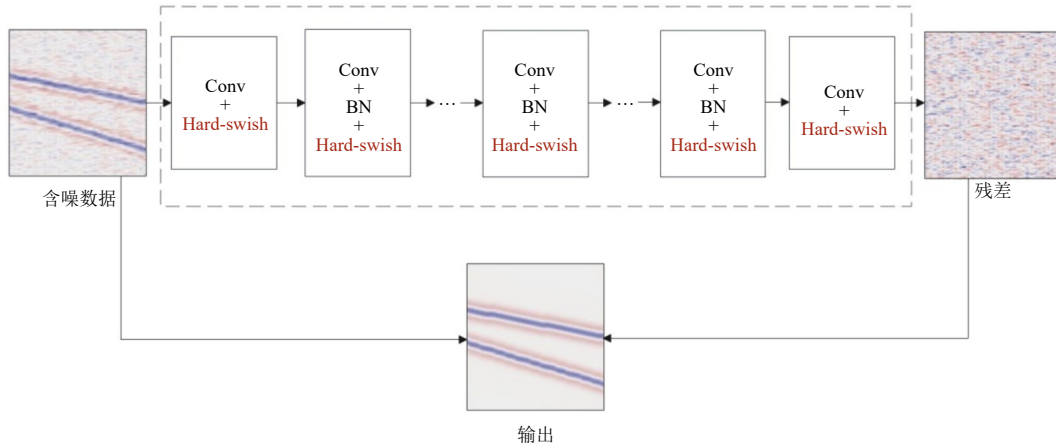


图2 HS-DnCNN 网络结构

Fig. 2 The architecture of the HS-DnCNN

差,其数学表达式为:

$$Loss = \frac{1}{N} \sum_{i=1}^N (Output_i - Target_i)^2 \quad (9)$$

式中: $Output_i$ 是网络的预测输出, $Target_i$ 是实际目标(去噪后的地震数据), N 是数据点的总数。在训练期间,这个过程被迭代多次,知道网络收敛到最小化损失的状态,因此,损失函数直接与网络的训练过程相关。

优化器是深度学习中用于调整模型参数以最小化损失函数的算法,它根据模型的梯度更新权重来减少损失。选择使用一种学习速率自适应的深度学习神经网络方法 Adam(Adaptive Moment Estimation)(Kingma and J, 2015)在处理大规模数据集和参数空间中 Adam 表现良好。在图像处理领域,PSNR 常用来作为测量图像质量的指标,笔者用来评价深度学习的去噪性能,其计算公式为:

$$PSNR(dB) = 10 \cdot \lg\left(\frac{MAX^2}{MSE}\right) \quad (10)$$

式中: MAX 代表数据像素的最大可能值, MSE 代表干净地震数据和去噪的地震数据之间对应差值的平方的平均值。去噪的目标是减小 MSE, 更小的 MSE 意味着去噪后的数据更接近于干净地震数据, 即 PSNR 值越大, 去噪效果越好。此外, 还加入了 SNR、SSIM 进一步对去噪效果进行评价。SNR 表示信号于噪声的相对强度, 数值越大表示信号相对于噪声更强, 去噪效果越好。SSIM 用于测量前后数据的相似度, 数值区间为 [0,1], 数值越接近 1 表示数据越相似。

2 合成数据去噪

本文的实验环境为: AMD Ryzen 5 5600X, 具有 6 个核心, 主频为 3.70 GHz, 32 GB 内存, 在 24 GB 内存的 3070 GPU 平台上运行, 深度学习框架为 PyTorch 1.11.0。

2.1 模型训练

本文实验将深度学习数据集划分为训练集和测试集, 训练集用于训练 DnCNN 模型, 测试集用于判断网络模型的效果, 评估最终模型的去噪能力。选取 SEG 网站上公开的二维合成数据(https://wiki.seg.org/wiki/Hess_VTI_migration_benchmark)作为数据集。该数据集由 Amerada Hess 提供, 共 178 502 道, 每道的采样点为 1332, 时间采样率为 6 ms, 数据格式为 SEG-Y, 取其前 1300 道数据作为展示, 如图 3 所示。

经过对数据的观察, 数据的下段采样时间数据稀疏, 可以选择有效的区域进行数据的训练, 能有效地节约时间成本。将该数据按 2:8 的比例划分为测试集和训练集, 即前 35 600 道为测试集, 其余部分为训练集。在进行网络训练之前, 对该数据添加 25% 的高斯随机噪声为噪声标签。将 DnCNN 和 HS-DnCNN 的迭代次数(epoch)设置为 85, 初始学习率(learning rate)设置为 0.001, 在每经过 20 次迭代时, 学习率降为之前的 0.2 倍。将地震数据切分成 35×35 的数据块(patch size), 批处理大小(batch size)设置为 128。为了更好地适应输入数据的变化, 将数据通过随机旋转, 使模型更全面地学习到数据的不




图3 训练数据
Fig. 3 Training data

同方面,提高模型的鲁棒性和泛化性能,防止过拟合。模型训练过程如图4所示,两种网络模型均收敛,从图中可以看出 HS-DnCNN 的损失函数下降得更快,说明在损失函数的比较上 HS-DnCNN 比 DnCNN 更优秀。对去噪能力进行进一步的数据分析的记录和比较,如图5所示,对比橙色方框内的数据,两种去噪方法的去噪结果和原始地震数据的重叠部分,可以看出 HS-DnCNN 去噪方法的重叠吻合程度更高,说明该方法的信号恢复能力更优于 DnCNN。

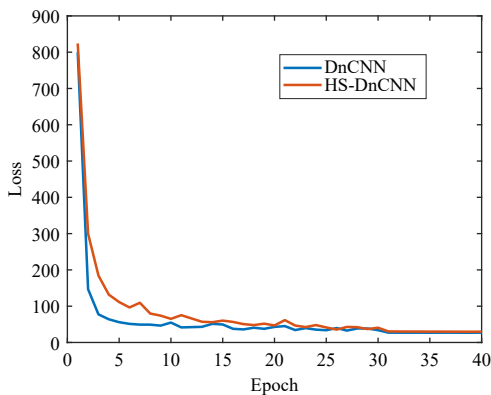


图4 损失函数曲线
Fig. 4 Curve of loss function

2.2 合成模型测试

使用合成地震数据的测试集对训练网络模型进行预测,取具有明显变化的200道数据进行展示,如图6所示。图6(a)为原始合成地震数据,图6(b)




图5 单道时域比较
Fig. 5 Single channel time domain comparison

为对图6(a)添加25%高斯随机噪声后的地震数据,图6(c)为DnCNN网络下训练的去噪结果,图6(d)为HS-DnCNN的去噪结果。图6(e)和图6(f)分别为DnCNN和HS-DnCNN去除的噪声。对比图6(e)和图6(f),DnCNN在去除随机噪声的同时,会丢失部分有效的原始数据,如图6(e)中红色方框中的反射波同相轴,由此可以看出HS-DnCNN损失的有效信号更少,并且在信号较强的位置有更好的去噪效果。这些对比效果都说明HS-DnCNN的去噪能力优于DnCNN。

通过PSNR等的4种图像质量评价的指标进一步对比两种去噪方法的差距,如表1所示。SNR

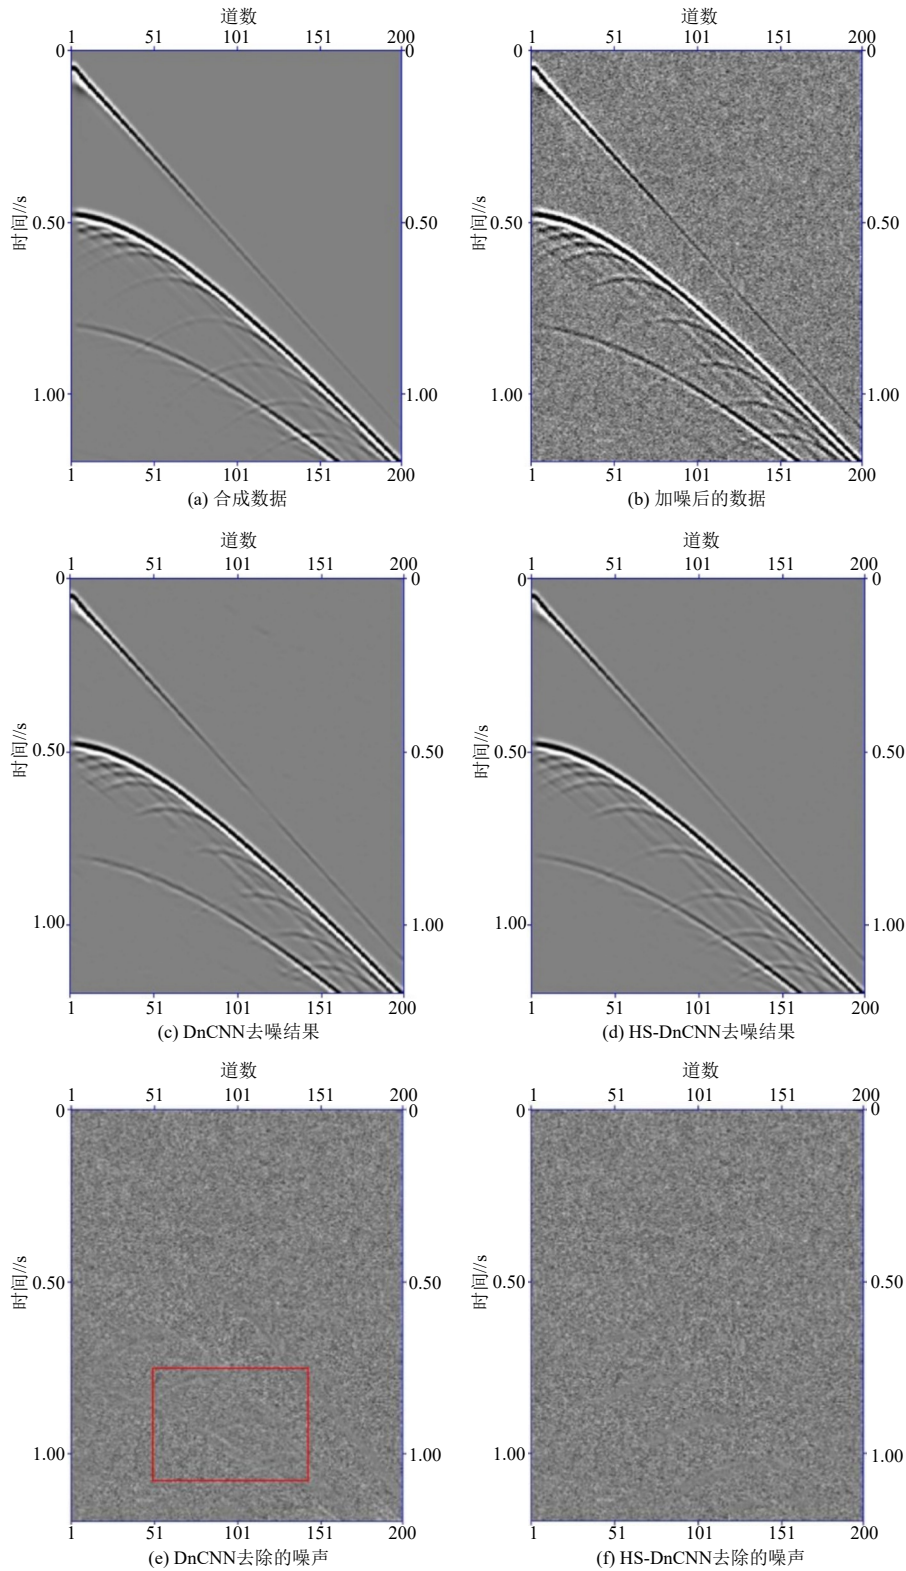


图 6 合成数据去噪

Fig. 6 Synthetic data denoising

表示信号与噪声之间的比率, HS-DnCNN 较 DnCNN 的 SNR 高 2.68 dB, PSNR 高 2.67 dB, 说明在去噪后, 数据的有效信号相对于噪声更为明显了。HS-DnCNN 的 MSE 更低, 这表示去噪后的地震信号与

原始信号更为接近。同时, HS-DnCNN 的 SSIM 稍高, 这意味着通过 HS-DnCNN 的模型去噪后的数据在结构上与原始数据更相似。总体而言, 各项评价指标均表明 HS-DnCNN 的去噪效果更优秀。

表 1 合成数据去噪性能对比

Tab. 1 Comparison of synthetic data denoising performance

去噪方法	评价指标			
	PSNR	SNR	MSE	SSIM
DnCNN	40.32	21.65	0.0013	0.9456
HS-DnCNN	42.99	24.33	0.0001	0.9657

3 实际数据去噪

为了更好地展示 HS-DnCNN 在实际应用中的效果,在原始训练集的基础上,添加真实的地震噪声数据用来训练模型。

3.1 模型训练

选取某 A 地区的叠前偏移距道集实际数据来进行 HS-DnCNN 方法去噪验证。该数据为三维数据,随机抽取其 Inline700、Xline327 的数据构建二维数据样本。该数据共 1 876 道,每道包含了 301 个采样点,时间采样间隔为 2 ms。由于合成地震数据的高斯噪声是由指定数值的标签来进行训练的,该标签为已知,但实际地震数据中的随机噪声为未知,所以

需要经过预处理去掉除随机噪声外的其他噪声。将进行过预处理的数据作为训练标签,按照合成数据中的数据划分比例 8:2 将该数据分别划分为训练集和测试集,取前 1 500 道作为训练集,后 376 道为测试集。与合成数据去噪中的训练方式相同,学习率、批处理大小等超参数不做改变,在已有合成数据训练出的网络模型基础上再进行 20 次迭代。

3.2 实际数据测试

选取测试结果中变化比较大的图像进行展示。图 7(a) 展示了预处理去噪之后添加 25% 高斯随机噪声的含噪数据,图 7(b) 和图 7(c) 分别展示了 DnCNN 的去噪方法和 HS-DnCNN 去噪处理后的结果。图 7(b) 与图 7(c) 相比,DnCNN 去噪虽然去除了很大一部分的噪声,但依旧存在许多明显的随机噪点。图 7(d) 和图 7(e) 分别展示了基于 DnCNN 和 HS-DnCNN 去除的噪声,能明显看出图 7(d) 中去除了很多有效的不属于随机噪声的数据部分,波形特征损失较多。图 7(e) 则呈现出更好的去噪效果,没有损失过多的有效数据,局部细节保留得更完整。

表 2 对两种去噪方法的去噪性能进行了对比,对应的 SNR 和 SSIM 分别为 18.57 dB、0.943 1;




图 7 实际数据去噪

Fig. 7 Actual data denoising

19.63 dB、0.9728, 该表的指标中, SNR 和 PSNR 更大且 MSE 更小, 这都意味着 HS-DnCNN 的去噪效果更优于 DnCNN。并且在实际数据的模型测试中, HS-DnCNN 所需时间成本都很大程度上低于 DnCNN, 完成设定迭代次数所需时间为 DnCNN 的 78%, 提高了去噪的效率。

表 2 实际数据去噪性能对比

Tab. 2 Comparison of actual data denoising performance

去噪方法	评价指标			
	PSNR	SNR	MSE	SSIM
DnCNN	27.69	18.57	0.0028	0.9431
HS-DnCNN	28.78	19.63	0.0016	0.9728

4 结论

笔者研究使用 Hard-Swish 激活函数改进了地震数据去噪的 DnCNN 方法, 有效提高了随机噪声的抑制能力, 在原基础上加快了网络训练, 使用 BN 来提高训练的收敛速度, 更好的拟合数据。基于对合成地震数据的分析, 结果表明 HS-DnCNN 在去噪效果方面优于 DnCNN。Hard-swish 激活函数的引入不仅提高了地震数据去噪的处理准确性, 还在一定程度上加强了处理效率。这意味着在实际应用中, HS-DnCNN 能够更精确地去除噪声, 使得解释地震数据的过程更为可靠。通过对比实验结果, 我们观察到 HS-DnCNN 相对于传统 DnCNN 在随机噪声压制方面的明显优势, 这为深度学习在地震数据处理中的应用提供了更为可行和高效的选择。然而, 研究也存在局限性, 如对特定类型噪声的处理效果需要进一步验证。未来研究也可以探索将本方法对其他特定类型噪声的处理, 以进一步提高去噪效果和适用性。

参考文献:

彭才, 常智, 朱仕军, 2008. 基于曲波变换的地震数据去噪方法 [J]. *石油物探*, 47(5): 461—464, 18.

Peng C, Chang Z, Zhu S J, 2008. Noise elimination method based on curvelet transform [J]. *Geophysical Prospecting for Petroleum*, 47(5): 461—464, 18. (In Chinese)

彭清, 张华, 梁爽, 2022. 基于 DnCNN 的地震数据去噪 [C]//2022 年中国地球科学联合学术年会论文集——专题二十九: 油藏地球物理、专题三十: 油气地球物理, 线

上会议: 27—30.

Peng Q, Zhang H, Liang S. Denoising of seismic data based on DnCNN [C]//China Joint Annual Conference of Earth Sciences: 27—30. (In Chinese)

王丹荔, 周怀来, 王元君, 等, 2023. 基于前馈去噪卷积神经网络的地震数据去噪方法 [J]. *物探化探计算技术*, 45(1): 17—27.

Wang D L, Zhou H L, Wang Y J, et al., 2023. Seismic data denoising method based on feedforward denoising convolution neural network [J]. *Computing Techniques for Geophysical and Geochemical Exploration*, 45(1): 17—27. (In Chinese)

王钰清, 陆文凯, 刘金林, 等, 2019. 基于数据增广和 CNN 的地震随机噪声压制 [J]. *地球物理学报*, 62(1): 421—433.

Wang Y Q, Lu W K, Liu J L, et al., 2019. Random seismic noise attenuation based on data augmentation and CNN [J]. *Chinese Journal of Geophysics*, 62(1): 421—433. (In Chinese)

Avenash R, Viswanath P, 2019. Semantic segmentation of satellite images using a modified CNN with hard-swish activation function [C]//Proceedings of the 14th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications.

Buades A, Coll B, Morel J M, 2008. Nonlocal image and movie denoising [J]. *International Journal of Computer Vision*, 76(2): 123—139.

Chen Y K, Fomel S, 2015. EMD-seislet transform [C]//SEG Technical Program Expanded Abstracts 2015. New Orleans, Louisiana. Society of Exploration Geophysicists, 4775—4778.

Elfwing S, Uchibe E, Doya K, 2018. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning [J]. *Neural Networks*, 107: 3—11.

Glorot X, Bordes A, Bengio Y, 2011. Deep sparse rectifier neural networks [C]//Proceedings of the 14th International Conference on Artificial Intelligence and Statistics. Fort Lauderdale: JMLR. org: 315—323.

He K M, Zhang X Y, Ren S Q, et al., 2016. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016. Las Vegas, NV, USA. IEEE, 770—778.

Howard A, Sandler M, Chen B, et al., 2019. Searching for MobileNetV3 [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). October 27-November 2, 2019. Seoul, Korea. IEEE, 1314—1324.

Kingma, J Ba, 2015. Adam: A method for stochastic optimization [C]//International Conference for Learning Representations.

Li J H, Zhang Y J, Qi R, et al., 2017. Wavelet-based higher or-

- der correlative stacking for seismic data denoising in the curvelet domain[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(8): 3810—3820.
- Li S C, Liu B, Ren Y X, et al., 2020. Deep-learning inversion of seismic data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 58(3): 2135—2149.
- Mousavi S M, Langston C A, 2016. Hybrid seismic denoising using higher-order statistics and improved wavelet block thresholding[J]. *Bulletin of the Seismological Society of America*, 106(4): 1380—1393.
- Ramachandran P, Zoph B, Le Qv, 2018. Searching for activation functions[C]//Proceedings of the 6th International Conference on Learning Representations. Vancouver: OpenReview. Net.
- Simonyan K, Zisserman A, 2014. Very deep convolutional networks for large-scale image recognition[EB/OL]. 2014: arXiv: 1409.1556.
- Starck J L, Nguyen M K, Murtagh F, 2003. Wavelets and curvelets for image deconvolution: a combined approach [J]. *Signal Processing*, 83(10): 2279—2283.
- Stumpf A, Lachiche N, Malet J P, et al., 2014. Active learning in the spatial domain for remote sensing image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 52(5): 2492—2507.
- Tang N, Zhao X, Li Y, et al., 2018. Adaptive threshold shearlet transform for surface microseismic data denoising[J]. *Journal of Applied Geophysics*, 153: 64—74.
- Yu S W, Ma J W, 2021. Deep learning for geophysics: current and future trends[J]. *Reviews of Geophysics*, 59(3): e2021RG000742.
- Zhang G Y, Wang Z Z, Chen Y K, 2018. Deep learning for seismic lithology prediction[J]. *Geophysical Journal International*, 215(2): 1368—1387.
- Zhang K, Zuo W M, Chen Y J, et al., 2017. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[J]. *IEEE Transactions on Image Processing*, 26(7): 3142—3155.