

# 改进的卷积神经网络对地震数据进行去噪的方法

崔少华\*, 李素文, 汪徐德

淮北师范大学物理与电子信息学院, 安徽 淮北 235000

**摘要** 针对采用全卷积神经网络去除地震数据随机噪声方法中遇到的计算量大、容易出现过拟合等问题,提出了一种基于 LeNet-5 改进的卷积神经网络对地震数据进行去噪的方法。除去输入层,该方法包含 2 个卷积层、2 个池化层和 1 个全输出层。采用误差最小的实验试选法,首先在单层卷积网络中确定第 1 个卷积层和池化层的参数,基于第 1 层参数确定第 2 个卷积层和池化层的参数,最后采用 12000 个大小为  $32 \times 32$  的地震数据训练 LeNet-5,采用 1000 个相同大小、相同信噪比的地震数据测试系统。Marousi2 叠前和叠后地震数据去噪实验均表明,本文方法对水平和倾斜同相轴地震数据的去噪效果较好。与奇异值分解算法、BP(Back Propagation)算法以及文献[9]中算法相比,本文方法能更好地去除噪声。

**关键词** 机器视觉; 卷积神经网络; LeNet-5; 地震数据; 去噪

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP57.061501

## De-Noising Method for Seismic Data via Improved Convolution Neural Network

Cui Shaohua\*, Li Suwen, Wang Xude

College of Physics and Electronic Information, Huaibei Normal University, Huaibei, Anhui 235000, China

**Abstract** We propose an improved convolution neural network based on LeNet-5 to address the problems of large computation and over-fitting in the full convolution neural network based method for eliminating noise of seismic data. The network of the proposed method consists of two convolution layers, two pooling layers, and one full output layer, in addition to the input layer. By using the experimental selection method of minimum error, the parameters of the first convolution layer and the pooling layer in the single-layer convolution network are determined. Then the parameters of the second convolution layer and the pooling layer are determined based on the parameters of the first layer. Finally, 12000 seismic data with size of  $32 \times 32$  are used as inputs to train LeNet-5, and 1000 seismic data with the same size and signal-to-noise ratio are used for testing the system. Experiments on pre-stack and post-stack seismic data from Marousi2 model demonstrate that the proposed method has good denoising effect for horizontal and inclined in-phase axis seismic data. Compared with the singular value decomposition algorithm, BP (back propagation) algorithm, and algorithm in Ref. [9], the proposed method has better denoising effect.

**Key words** machine vision; convolution neural network; LeNet-5; seismic data; denoising

**OCIS codes** 150.1135; 100.3190; 100.4996

## 1 引言

当代的石油探测、地震勘探技术中大量利用反演地震波进行勘测。勘测地形的多样性和环境的恶劣性使得地震波极易受到噪声的干扰,因此对采集

的地震波进行去噪具有重要意义。早期的地震波去噪主要采取传统方法,如刘法启等<sup>[1]</sup>采用 F-K 滤波法进行去噪,该方法将信号变换到频率-波数域内,利用一个扇形的滤波器对信号和噪声进行分离,从而达到去噪的目的。之后康冶等<sup>[2]</sup>提出 F-X 域拟

收稿日期: 2019-06-12; 修回日期: 2019-07-14; 录用日期: 2019-08-28

基金项目: 国家自然科学基金面上项目(41875040)、国家自然科学基金青年基金(11504121)、安徽省教育厅项目(2018jyxm0530,2017kfk044,KJ2017B008,201910373104)

\* E-mail: flower0804@126.com

线性预测去噪法,该方法首先将地震数据进行拟线性变换,通过 F-X 域预测滤波后再进行反拟线性变换,从而抑制噪声。然而,上述两种方法主要适用于信号和噪声的特性差异明显的情况,在二者差异不明显时则无法进行去噪。因此,陆文凯等<sup>[3]</sup>提出了基于信号子空间分解的三维地震资料高分辨率处理方法,该方法利用奇异值分解算法(SVD)对 3D 地震信号子空间进行分解,根据不同分解的奇异值将信号和噪声进行分离,但该方法对非水平同相轴噪声的去噪效果不佳。程浩等<sup>[4]</sup>提出了基于小波变换的自适应阈值微震信号去噪方法,该方法采用小波变换对矿山地震信号进行分解与重构,但是小波阈值的选取依靠人工,对去噪效果影响较大。

由于上述的传统去噪方法对地震数据的采集条件过于敏感,整体去噪效果不佳,改进的去噪方法随之产生。赵迎等<sup>[5]</sup>提出了互补集合经验模态分解(CEEMD)与小波变换联合去噪的方法。张银雪等<sup>[6]</sup>提出了基于改进的粒子群优化的独立分量分析(PSO-ICA)的地震信号去噪方法。卜一波等<sup>[7]</sup>提出基于复合稀疏去噪的沙漠地震噪声消减方法。这些改进的算法以传统去噪法为基础,依赖地震数据的先验信息,去噪效果仍然有待进一步提高。

随着 2012 年神经网络在计算机科学技术方面的应用,其高效的网络结构和识别能力得到广泛认可。学者们尝试将神经网络应用于去噪领域,其中,章云港等<sup>[8]</sup>提出基于卷积神经网络(CNN)的电子计算机断层扫描(CT)图像去噪方法,该方法取得了良好的去噪结果。之后,文献[9]提出了基于深度学习卷积神经网络的地震数据去噪方法,实验证明该方法对地震数据具有较好的去噪能力。然而文献[9]采用全卷积网络,除去输入层,共有 17 个卷积层,且每个卷积层使用单一大小的  $3 \times 3$  卷积核,经过卷积后每层得到相同的 64 个特征映射,这使得文献[9]的去噪效果仍然受到限制。

为了进一步提高卷积神经网络对地震数据的去

噪效果,本文提出了一种基于改进的卷积神经网络进行地震数据去噪的方法。该方法采用经典 LeNet-5 网络,除去输入层,网络共包含 2 个卷积层、2 个池化层和 1 个输出层,每个卷积层所用卷积核大小和特征图个数并不单一固定,而是采用均方误差最小的实验试选法,通过分析实验数据确定卷积核大小和特征图个数。将 12000 个大小为  $32 \times 32$  的地震数据输入 LeNet-5 系统,这些数据包含 10000 个含噪数据和 2000 个不含噪数据,测试样本采用 1000 个相同大小、相同信噪比的地震数据。最后,通过 Marousi2 叠前和叠后地震数据进行去噪实验,并将本文方法与传统 SVD 算法、BP (Back Propagation)算法以及文献[9]中算法进行对比,实验结果表明本文方法的去噪效果较好。

## 2 CNN 网络简介

### 2.1 CNN 网络结构

传统的人工神经网络结构中隐含层的神经元与前一层是全连通的,这意味着每一个神经元都与前一层的所有神经元存在参数关联,从而使得传统神经网络计算量大、速度慢,容易出现过拟合。而 CNN 是一个由单层卷积神经网络组成的多层可训练监督学习网络,每个单层卷积神经网络包含卷积、非线性变换和下采样(池化)三个阶段,如图 1 所示<sup>[10]</sup>。图 1 中卷积阶段的输入记为  $x_i$ ,为  $n_1$  个  $n_2 \times n_3$  的特征图(特征映射)数组,卷积阶段的输出记为  $y_i$ ,为  $m_1$  个  $m_2 \times m_3$  的特征图数组。 $y_i$  中的每个神经元和  $x_i$  之间并非全连接,而是通过一定大小的区域相连接,同时  $y_i$  中的神经元通过一定大小的卷积核对这个区域进行特征提取,从而使得输入数据的权值数量大大降低(降维),提高了网络的训练速度,避免了过拟合现象<sup>[11]</sup>。 $y_i$  和  $x_i$  之间的监督学习过程可表示为

$$y_j = \sum_i \omega_{ij} x_i + b_j, \quad (1)$$




图 1 单层卷积神经网络的三个阶段

Fig. 1 Three stages of single-layer convolution neural network

式中:  $\omega_{ij}$  为可训练的卷积核;  $b_j$  为可训练的偏置参数。

## 2.2 LeNet-5 系统简介

CNN 最为经典的应用是 LeCun 等<sup>[12]</sup> 提出的 LeNet-5 系统。除去输入层, 该系统包含 2 个卷积

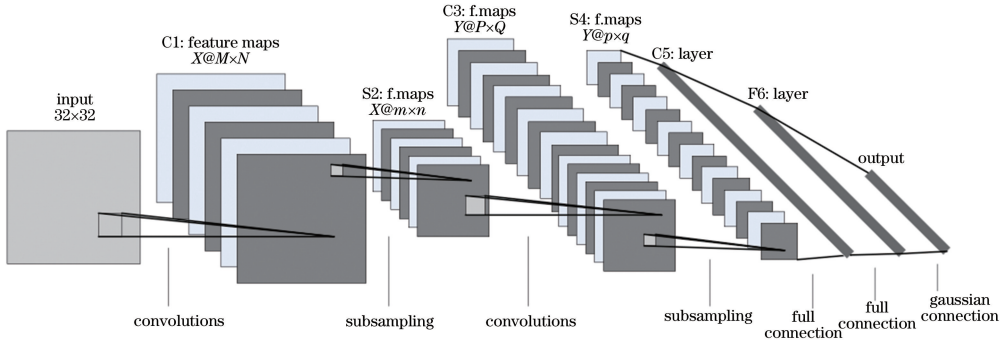


图 2 LeNet-5 系统

Fig. 2 LeNet-5 system

图 2 中  $X$ 、 $Y$  分别是 2 个卷积层与池化层中特征图的个数,  $M$ 、 $P$  和  $N$ 、 $Q$  分别是每个卷积层中特征图的宽和高,  $m$ 、 $p$  和  $n$ 、 $q$  分别是每个池化层中特征图的宽和高,  $S4$  (池化层) 直接连接到输出层。由图 2 可知, LeNet-5 系统的参数主要包括网络层数(深度)、卷积核大小、特征图个数, 三者相互联系、相互影响。目前对于这三个参数的选择没有标准化, 大多依靠设计者的经验。本文采用均方误差最小的试选法, 通过分析实验数据, 对系统的卷积核大小、特征图个数进行选取, 使系统达到最佳去噪效果。

## 2.3 CNN 去噪原理

若设原始地震数据为  $S$ , 噪声为  $N$ , 则含噪地震数据  $Y$  的具体公式为

$$Y = S + N. \quad (2)$$

地震数据去噪的本质就是从含噪数据  $Y$  中去除噪声  $N$ , 从而恢复原始不含噪声的地震数据  $S$ 。因此本文的实验方法是: 将含噪数据  $Y$  作为 CNN 网络的输入数据, 经过残差单元学习输入数据与输出数据的残差, 在达到目标时网络输出误差  $N$  (去除的噪声), 再用含噪数据  $Y$  减去除去的噪声  $N$ , 即可得去噪后的地震数据  $\hat{S}$ , 它是原始地震数据的逼近, 即  $S \approx \hat{S} = Y - N$ 。

CNN 残差单元的学习目标公式为

$$g = \operatorname{argmin}_g \sum_{i=1}^n \|g(y_i) - x_i\|_2^2, \quad (3)$$

式中:  $g$  为卷积神经网络输出;  $g(y_i)$  为去噪后的单道地震数据;  $x_i$  为原始单道地震数据。CNN 去噪的过程就是不断调整各层网络参数, 使去噪后的地

震数据与原始地震数据之间的误差最小。层、2 个池化层和 1 个输出层(输出层的各层看作一个整体), 具体结构如图 2 所示。该系统设计之初主要应用于手写数字识别, 经由数字数据库(MINIST)测试, 识别错误率达到 0.9%<sup>[13]</sup>。

震数据与原始地震数据之间的误差最小。

## 3 LeNet-5 系统去噪设计

### 3.1 网络深度的确定

文献[9]借助 Matlab 中 MatConvNet 工具箱, 采用全卷积的 CNN 网络, 除去输入层, 该网络包含 17 个全卷积层, 每层均采用 64 个大小为  $3 \times 3$  的卷积核(最后一个卷积层包含 1 个特征图), 文献[9]通过实验证明该网络能有效地对地震数据进行去噪。一般地, CNN 网络的深度越大, 网络的残差越小, 去噪的效果越好。但是网络的深度越大, 包含的参数越多, 过大的网络极容易出现过拟合、计算时间过长的问题, 使得去噪效果不佳。在处理地形复杂区域采集的信号时, 面对数以百万计的大规模地震数据, 文献[9]采用的全卷积网络负担过重, 容易出现过拟合, 使网络精度下降, 输出去噪效果不佳。因此本文采用 5 层深度的 LeNet-5 系统(其中卷积层只有 2 个)对地震数据进行去噪处理。

### 3.2 卷积核和特征图的选取思路

对于卷积核大小、特征图个数的选择, 文献[9]将每层的卷积核均设置为  $3 \times 3$  大小, 对应每层的特征图个数(除去最后一层, 均为 64 个)也相同, 然而地震属性中包含地质结构和反演岩层变化信息, 各道数据的构成复杂, 采用单一的卷积核和特征图个数, 在提取信息时容易造成细节的损失。因此, 本文以网络输出结果与期望值之间的均方误差( $M_{SE}$ )衡量该系统的特征提取能力, 其数学公式为

$$M_{SE} = \frac{1}{2n} \sum_i^n |y_i - y_{io}|^2, \quad (4)$$

式中： $y_i$  是第  $i$  个不含噪数据； $y_{io}$  是对应的第  $i$  个去噪后数据； $n$  是输入数据的数量（采样点）<sup>[14]</sup>。 $M_{SE}$  越小，代表系统提取特征的能力越强，去噪后数据和原始数据之间差异越小，去噪效果越好。通过实验试选法，将  $M_{SE}$  最小时对应的组合作为每层卷积核大小、特征图个数，具体思路为：

1) 在单层卷积网络中（图 2 中的 C1 层和 S2 层）估计卷积核大小的范围，固定某一个卷积核尺寸，依次改变特征图个数，选取实验数据中  $M_{SE}$  最小时对应的组合，将其作为该层最佳的卷积核尺寸和特征图个数；

2) 将上一层网络确定的参数作为下一层卷积网络（图 2 中的 C3 和 S4 层）的输入，在两层卷积网络中，选取系统  $M_{SE}$  最小时对应的组合，确定 C3 层的最佳卷积核尺寸和特征图个数。

### 3.3 卷积核和特征图的确

#### 3.3.1 C1 层参数的确定

本文采用广泛的 Marousi2 模型产生地震数据，LeNet-5 系统的训练样本为 12000 个  $32 \times 32$  大小（时域为 32 道，每道 32 个采样点）的地震数据，其中包含 10000 个含噪数据（加入 15% 随机噪声）和 2000 个不含噪数据，测试样本采用 1000 个相同信噪比、相同大小的含噪数据，补零步长为 1，历经 50 个 epoch（训练次数）。图 2 中 C1 层的特征图个数  $X$  和卷积核的选取思路为：

1) 经典 LeNet-5 系统在最后一个卷积层采用 16 个特征图进行十分类（识别数字 0~9）<sup>[12]</sup>。对地震数据进行去噪相当于对噪声和信号进行二分类，因此本文实验的特征图个数不应大于 16，其范围为 1~16。

2) 卷积核的大小一般选取奇数尺寸<sup>[13]</sup>。相对 LeNet-5 系统实现十分类，对地震数据进行去噪（二分类）所提取的特征相对简单，卷积核大小一般选取  $1 \times 1, 3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9$ ，又因为后一层的卷积核不应大于上一层的卷积核，因此本文实验中 C1 层卷积核选取  $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9$ 。

试选实验的结果如表 1 所示，其中  $M_{SE}$  值为 0.5000 时表示系统无法收敛。由表 1 可知，单层网络去噪能力与卷积核大小和特征图个数存在联系，除个别情况外，大部分不收敛（ $M_{SE}$  值过大）情况出现在左下角且呈阶梯状分布，大部分收敛（ $M_{SE}$  值较小）情况出现在右上角。由此可知，在卷积核过小

时，通过增大特征图个数可使系统输出  $M_{SE}$  过大，无法收敛；卷积核过大时，特征图个数过大，也会使系统无法收敛。恰当的卷积核大小和特征图个数才能使系统输出  $M_{SE}$  最小，达到去噪要求。由表 1 可知，卷积核大小为  $5 \times 5$  时 9 个特征图对应的  $M_{SE}$  最小（0.0235），因此 C1 层卷积核选取  $5 \times 5$ ，特征图个数为 9。C1 层  $M \times N = 28 \times 28$ ，池化层 S2 层  $m \times n = 14 \times 14$ <sup>[15]</sup>。经过池化后系统的广度（特征图的尺寸）减小到原有的 1/4，而数据的深度不变，系统的参数个数减小到了 75%，计算量大大降低，S4 层亦是如此。

表 1 C1 层不同的卷积核大小和特征图个数对应的  $M_{SE}$

Table 1  $M_{SE}$  values corresponding to different sizes of convolution kernels and numbers of feature maps in C1 layer

Number of feature maps	$3 \times 3$	$5 \times 5$	$7 \times 7$	$9 \times 9$
1	0.0475	0.0520	0.0585	0.0680
2	0.0360	0.0245	0.0555	0.0445
3	0.0340	0.0275	0.0365	0.0355
4	0.0370	0.0250	0.0315	0.0300
5	0.0312	0.0265	0.0345	0.0330
6	0.0420	0.0520	0.0315	0.5000
7	0.5000	0.0335	0.5000	0.0285
8	0.5000	0.5000	0.0305	0.0285
9	0.5000	0.0235	0.0385	0.5000
10	0.5000	0.5000	0.0327	0.0290
11	0.5000	0.5000	0.5000	0.0312
12	0.5000	0.5000	0.5000	0.0441
13	0.5000	0.5000	0.5000	0.5000
14	0.5000	0.5000	0.5000	0.5000
15	0.5000	0.5000	0.5000	0.5000
16	0.5000	0.5000	0.5000	0.5000

#### 3.3.2 C3 层参数的确定

由表 1 可知，C1 层的卷积核选取  $5 \times 5$ 。一般地，下一层的卷积核不应大于上一层的卷积核，因此本次实验中 C3 层的卷积核选取  $1 \times 1, 3 \times 3, 5 \times 5$ 。由表 1 可知，卷积核过小时，通过增大特征图个数无法使得系统收敛，因此本次实验中 C3 层的特征图个数选取 1~9。实验结果如表 2 所示。由表 2 可知，固定 C1 层卷积核大小和特征图个数后并将其与 C3 层级联，系统的  $M_{SE}$  值分布无显著规律，这是

由于此时已经不是单层卷积网络,C3层的输入取决于C1层和S2层的输出,卷积层之间互相关联。由表2可知,C3层的卷积核大小为 $3 \times 3$ ,特征图个数为6时系统的 $M_{SE}$ 值最小(0.0190)。C3层 $P \times Q = 12 \times 12$ ,池化层S4层 $m \times n = 6 \times 6$ ,计算量大大降低。因此,最终网络的拓扑结构确定为:C1层卷积核大小为 $5 \times 5$ ,9个特征图;C3层卷积核大小为 $3 \times 3$ ,6个特征图。

表2 C1层卷积核大小为 $5 \times 5$ ,9个特征图时,C3层不同的卷积核大小和特征图个数对应的 $M_{SE}$

Table 2  $M_{SE}$  values corresponding to different sizes of convolution kernels and feature map numbers of C3 layer when the convolution kernel size is  $5 \times 5$  and the number of feature maps is 9 for C1 layer

Number of feature maps	$1 \times 1$	$3 \times 3$	$5 \times 5$
1	0.0620	0.0460	0.0510
2	0.0565	0.0425	0.0435
3	0.0570	0.0545	0.0435
4	0.0405	0.0410	0.0430
5	0.0415	0.0340	0.0345
6	0.0535	0.0190	0.0330
7	0.0495	0.0370	0.0295
8	0.0395	0.0325	0.0340
9	0.0480	0.0395	0.0260

## 4 实际去噪结果

### 4.1 叠前地震数据去噪结果

采用 Marousi2 地震数据进行实验,将大小为 $500 \times 500$ (时域总共 500 道,每道含有 500 个采样点)的叠前地震数据加入幅度为 15% 的随机噪声(与训练系统时噪声幅度一致),采用本文建立的 LeNet-5 系统进行去噪,并分别与传统 SVD 算法、BP 算法以及文献[9]所述全卷积网络进行对比,结果如图 3 所示。采用峰值信噪比(Peak Signal-to-Noise Ratio,  $P_{SNR}$ )、去噪后的信噪比(Signal-to-Noise Ratio,  $S_{NR}$ )、 $M_{SE}$ 共同作为去噪效果的衡量指标<sup>[16]</sup>,其计算式为

$$P_{SNR} = 10 \log_{10} \left( \frac{\| \max(y) - \min(y) \|_2}{M_{SE}} \right), \quad (5)$$

$$S_{NR} = 10 \log_{10} \left( \frac{\| y \|_2}{\| y - y_0 \|_2} \right), \quad (6)$$

式中: $y$ 为不含噪的原始地震数据; $y_0$ 是去噪后数据; $\| \cdot \|_2$ 表示 L2 范数。 $M_{SE}$ 值越小,则  $P_{SNR}$  值越大, $S_{NR}$  值越大,代表网络去除的噪声越干净,算法恢复的地震数据失真越小,去噪效果越好<sup>[17]</sup>,实验结果如表 3 所示。




图3 叠前地震数据不同算法的去噪结果。(a)原始地震数据;(b)含噪地震数据;(c) SVD算法去噪效果;(d) BP算法去噪效果;(e)文献[9]中算法去噪效果;(f)所提算法去噪效果

Fig. 3 Denoising results of different algorithms for pre-stack seismic data. (a) Original seismic data; (b) noisy seismic data; (c) denoising results of SVD algorithm; (d) denoising results of BP algorithm; (e) denoising results of algorithm proposed in Ref. [9]; (f) denoising results of proposed algorithm

由图 3(c)可知,传统 SVD 算法对倾斜同相轴数据的去噪效果不佳(图中圆圈部分),对水平轴或倾角较小的同相轴数据去噪效果较好,这是由于 SVD 算法的去噪效果与各通道数据的相关性有关,相关性越弱,去噪效果越差<sup>[18]</sup>,倾角越大的同相轴数据之间的相关性越弱。由图 3(d)可知,浅层神经网络 BP 算法对水平同相轴或倾角较小的同相轴数据的去噪效果不佳,对倾斜同相轴数据的去噪效果较好,这是由于 BP 网络更擅长处理非线性问题,水平同相轴各通道数据之间相关性很大,可看作线性问题;倾斜同相轴反之。由图 3(e)和(f)可知,文献

[9]全卷积算法和本文算法对水平和倾斜同相轴数据的去噪效果均较好。由表 3 可知,本文算法的  $P_{\text{SNR}}$ 、 $S_{\text{NR}}$  较其他算法的数值高,但是仅比文献[9]中算法的  $P_{\text{SNR}}$  值高 0.0107 dB,同时仅比文献[9]的  $S_{\text{NR}}$  值高约 0.7 dB,这是由于叠前地震数据未经叠加降噪处理,所含地震地质细节更多,文献[9]中算法网络深度更深,特征图保留个数更多,去噪存在一定优势。然而相比文献[9]中算法的 17 层卷积深度、计算量过大的问题,本文算法的计算量大减小,不容易因出现过拟合而退出,有利于处理大规模地震资料。

表 3 不同算法针对叠前和叠后地震数据的结果

Table 3 Results of different algorithms for pre-stack and post-stack seismic data

Seismic data	Algorithm	$P_{\text{SNR}}/\text{dB}$	$S_{\text{NR}}/\text{dB}$	$M_{\text{SE}}$
Pre-stack data	SVD	62.9160	25.7189	0.0095
	BP	61.0352	24.4899	0.0156
	Algorithm in Ref. [9]	64.6129	27.3903	0.0080
	Proposed algorithm	64.6236	28.1604	0.0067
Post-stack data	SVD	61.2323	27.4449	0.0079
	BP	60.3104	24.6603	0.0150
	Algorithm in Ref. [9]	64.9023	29.6088	0.0048
	Proposed algorithm	66.6712	31.9728	0.0022

#### 4.2 叠后地震数据去噪结果

采用 Marousi2 地震数据进行实验,在大小为  $300 \times 600$  的叠后地震数据中加入幅度为 15% 的随

机噪声(与训练系统时噪声幅度一致),分别采用本文建立的 LeNet-5 系统、SVD 算法、BP 算法,以及文献[9]所述全卷积网络进行去噪,结果对比如图 4 所示。




图 4 叠后地震数据不同算法的去噪结果。(a)原始地震数据;(b)含噪地震数据;(c) SVD 算法去噪效果;

(d) BP 算法去噪效果;(e)文献[9]中算法去噪效果;(f)所提算法去噪效果

Fig. 4 Denoising results of different algorithms for post-stack seismic data. (a) Original seismic data; (b) noisy seismic data; (c) denoising results of SVD; (d) denoising results of BP; (e) denoising results of algorithm proposed in Ref. [9]; (f) denoising results of proposed algorithm

由图 4(c)可知,传统 SVD 算法对倾斜同相轴叠后地震数据的去噪效果欠佳(圆圈部分),选取较少的信号维数不能重构倾斜同相轴的数据,选取较大的信号维数则容易引入过多的噪声,去噪效果较差,这正是传统 SVD 去噪算法的弊端<sup>[18]</sup>。由图 4(d)可知,BP 算法对水平同相轴叠后地震数据的去噪效果欠佳(圆圈部分),对倾斜同相轴数据的去噪效果相对较好,但是对比 CNN 网络的去噪效果,BP 网络对地震数据的细节还原效果差,这是浅层神经网络的弊端。由图 4(e)和(f)可知,相比前两种算法,文献[9]中全卷积算法和本文算法对水平和倾斜同相轴数据的去噪效果均较好。由表 3 可知,对于叠后地震数据,本文算法的  $P_{\text{SNR}}$  值最高,比文献[9]算法的  $P_{\text{SNR}}$  值约高 1.8 dB,同时,比文献[9]的  $S_{\text{NR}}$  值约高 2.4 dB。这是由于地震数据经过叠加后可以抵消一部分随机噪声,相比叠前数据,叠后数据经过预处理后无需过大的网络深度和过多的特征图个数,本文算法即可取得较好的去噪效果。此时,叠后地震数据量的增大使得文献[9]中网络计算量庞大,更容易出现过拟合现象,限制了文献[9]的去噪效果。

需要指出的是,本文去噪方法是在固定噪声幅度(15%)时进行的,如果待去噪地震数据的噪声幅度发生变化,需要重新训练 LeNet-5 系统,这对实际地震数据去噪时所用样本集的丰富性提出了更高的要求。为了解决实际数据中训练样本少的问题,本文采用与实际噪声概率分布相似的估计水平,即 5%、10%、15%、25%、30%,分别进行实验,对实际工程中采用的叠后地震数据进行去噪,结果如表 4 所示。由表 4 可知,随着噪声水平的增加,网络输出的  $M_{\text{SE}}$  越来越大,使得  $P_{\text{SNR}}$  和  $S_{\text{NR}}$  值越来越小。对比表 4 可知,在 30%的噪声水平下,本文算法仍然能达到 63.7596 dB 的  $P_{\text{SNR}}$  值,22.1031 的  $S_{\text{NR}}$  值,并不低于其他算法在 15%噪声水平时的去噪能力,该结果表明本文算法在实际工程中确实有效可行。

表 4 不同噪声水平时本文算法的去噪结果

Table 4 Denoising results of proposed algorithm at different noise levels

Noise level / %	$P_{\text{SNR}}/\text{dB}$	$S_{\text{NR}}/\text{dB}$	$M_{\text{SE}}$
5	80.9861	38.3296	0.0005
10	71.0896	34.3800	0.0016
15	66.6712	31.9728	0.0022
20	65.5404	26.8308	0.0091
25	64.3720	23.7155	0.0150
30	63.7596	22.1031	0.0217

## 5 结 论

提出了一种基于 LeNet-5 系统的地震数据去噪方法。采用误差最小的实验试选法确定系统参数,首先在单层网络中确定第 1 个卷积层和池化层的卷积核大小、特征图个数,根据第 1 层的参数确定第 2 个卷积层和池化层的卷积核大小、特征图个数。将 12000 个  $32 \times 32$  大小的地震数据输入系统,包含 10000 个含噪数据和 2000 个不含噪数据,测试样本采用 1000 个同样大小、相同信噪比的地震数据。Marousi2 叠前和叠后地震数据去噪实验均表明,本文方法对水平和倾斜同相轴数据的去噪效果较好。与 SVD 算法、BP 算法以及文献[9]中算法相比,本文方法的去噪效果更好。同时,本文算法加入了 2 个池化层后,只采用 2 个卷积层,便使得系统处理参数的数目约减少到了 75%,大大降低了计算成本,有效避免了过拟合现象,本文算法在处理大规模地震数据时具有实际意义。

## 参 考 文 献

- [1] 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, 906.  
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, 906.
- [2] Kang Y, Yu C Y, Jia W, et al. A study on noise-suppression method in f-x domain [J]. Oil Geophysical Prospecting, 2003, 38(2): 136-138.  
康冶, 于承业, 贾卧, 等. f-x 域去噪方法研究[J]. 石油地球物理勘探, 2003, 38(2): 136-138.
- [3] Lu W K, Ding W L, Zhang S W, et al. A high-resolution processing technique for 3-D seismic data based on signal sub-space decomposition[J]. Chinese Journal of Geophysics, 2005, 48(4): 896-901.  
陆文凯, 丁文龙, 张善文, 等. 基于信号子空间分解的三维地震资料高分辨率处理方法[J]. 地球物理学报, 2005, 48(4): 896-901.
- [4] Cheng H, Yuan Y, Wang E D, et al. Study of hierarchical adaptive threshold micro-seismic signal denoising based on wavelet transform[J]. Journal of Northeastern University (Natural Science), 2018, 39(9): 1332-1336.  
程浩, 袁月, 王恩德, 等. 基于小波变换的自适应阈值微震信号去噪研究[J]. 东北大学学报(自然科学

- 版), 2018, 39(9): 1332-1336.
- [5] Zhao Y, Yue Y X, Huang J L, et al. CEEMD and wavelet transform jointed de-noising method [J]. Progress in Geophysics, 2015, 30(6): 2870-2877.  
赵迎, 乐友喜, 黄健良, 等. CEEMD与小波变换联合去噪方法研究[J]. 地球物理学进展, 2015, 30(6): 2870-2877.
- [6] Zhang Y X, Tian X M. Seismic denoising based on the modified particle swarm optimization-independent component analysis[J]. Oil Geophysical Prospecting, 2012, 47(1): 56-62, 188, 194.  
张银雪, 田学民. 基于改进 PSO-ICA 的地震信号去噪方法[J]. 石油地球物理勘探, 2012, 47(1): 56-62, 188, 194.
- [7] Bu Y B, Liang N S, Shao D, et al. Desert seismic noise attenuation via compound sparse denoising [J]. Journal of Jilin University (Information Science Edition), 2018, 36(3): 240-245.  
卜一波, 梁乃升, 邵丹, 等. 基于复合稀疏去噪的沙漠地震噪声消减[J]. 吉林大学学报(信息科学版), 2018, 36(3): 240-245.
- [8] Zhang Y G, Yi B S, Wu C Y, et al. Low-dose CT image denoising method based on convolutional neural network [J]. Acta Optica Sinica, 2018, 38(4): 0410003.  
章云港, 易本顺, 吴晨玥, 等. 基于卷积神经网络的低剂量 CT 图像去噪方法[J]. 光学学报, 2018, 38(4): 0410003.
- [9] 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, 877.  
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, 877.
- [10] Zhang Y S, Yang G W, Wang Q Q, et al. Weld feature extraction based on fully convolutional networks [J]. Chinese Journal of Lasers, 2019, 46(3): 0302002.  
张永帅, 杨国威, 王琦琦, 等. 基于全卷积神经网络的焊缝特征提取[J]. 中国激光, 2019, 46(3): 0302002.
- [11] Peng Y F, Song X N, Zi L L, et al. Remote sensing image retrieval based on convolutional neural network and modified fuzzy C-means [J]. Laser & Optoelectronics Progress, 2018, 55(9): 091008.  
彭晏飞, 宋晓男, 訾玲玲, 等. 基于卷积神经网络和改进模糊 C 均值的遥感图像检索[J]. 激光与光电子学进展, 2018, 55(9): 091008.
- [12] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [13] Qiao J F, Wang G M, Li W J, et al. An adaptive deep Q-learning strategy for handwritten digit recognition [J]. Neural Networks, 2018, 107: 61-71.
- [14] Zhang H, Lu S F, Li W H, et al. Application of  $\Delta$ LogR technology and BP neural network in organic evaluation in the complex lithology tight stratum [J]. Progress in Geophysics, 2017, 32(3): 1308-1313.  
张晗, 卢双舫, 李文浩, 等.  $\Delta$ LogR 技术与 BP 神经网络在复杂岩性致密层有机质评价中的应用[J]. 地球物理学进展, 2017, 32(3): 1308-1313.
- [15] Li Y, Lin X Z, Jiang M Y. Facial expression recognition with cross-connect LeNet-5 network [J]. Acta Automatica Sinica, 2018, 44(1): 176-182.  
李勇, 林小竹, 蒋梦莹. 基于跨连接 LeNet-5 网络的面部表情识别[J]. 自动化学报, 2018, 44(1): 176-182.
- [16] Li C P, Qin P L, Zhang J J. Research on image denoising based on deep convolutional neural network [J]. Computer Engineering, 2017, 43(3): 253-260.  
李传朋, 秦品乐, 张晋京. 基于深度卷积神经网络的图像去噪研究[J]. 计算机工程, 2017, 43(3): 253-260.
- [17] Shi Z T, Wang Z R, Wang R, et al. Single image super-resolution based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2018, 55(12): 121001.  
史紫腾, 王知人, 王瑞, 等. 基于卷积神经网络的单幅图像超分辨[J]. 激光与光电子学进展, 2018, 55(12): 121001.
- [18] Cui S H, Shan W, Fang Z G. Research on denoising of SVD algorithm based on Hankel matrix [J]. Research and Exploration in Laboratory, 2018, 37(2): 32-34.  
崔少华, 单巍, 方振国. 基于 Hankel 矩阵 SVD 算法的去噪研究[J]. 实验室研究与探索, 2018, 37(2): 32-34.