

基于深度卷积和自注意力机制的端到端地震波降噪方法

赵博涛¹, 亢祖衡¹, 贺亚运¹, 彭俊清¹, 张旭龙¹, 瞿晓阳¹, 谭毅培², 陈雨乐³, 肖春光⁴, 王健宗¹

1. 平安科技(深圳)有限公司, 广东 深圳 518063;
2. 天津市地震局, 天津 300201;
3. 湖南大学工商管理学院, 湖南 长沙 410082;
4. 深圳市宝安区教育信息中心, 广东 深圳 518101

摘要

地震波信号的降噪对于地震监测和地震学研究至关重要。提出了一种基于深度学习的端到端地震波降噪方法。该方法融合了卷积神经网络与多头自注意力机制, 采用残差连接的编码器-解码器架构, 一方面能够处理复杂背景和细节丰富的信号, 另一方面多头自注意力机制能捕捉长距离依赖关系。通过一致性相关性损失与频域均方误差损失的联合约束, 在时域和频域上均实现了优异的降噪效果。在公开数据集STEAD上的测试表明, 该方法在峰值信噪比(PSNR)和信号相关性(CC)两个关键指标上均优于传统及现有的深度学习方法, 皮尔逊相关性为0.918, 峰值信噪比为36.79, 达到先进水平。此外, 在京津冀地震预警台网所记录地震波形数据上进一步验证, 结果表明该方法在抑制噪声的同时, 能够较好地保留地震信号(CC达0.70, PSNR为35.26)。

关键词

地震波降噪; 深度学习; 卷积网络; 自注意力机制; 残差编解码器

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.2096-0271.2025070

End-to-end seismic signals denoising via deep residual convolution and self-attention mechanisms

Zhao Botao¹, Kang Zuheng¹, He Yayun¹, Peng Junqing¹, Zhang Xulong¹, Qu Xiaoyang¹, Tan Yipei², Chen Yule³, Xiao Chunguang⁴, Wang Jianzong¹

1. Ping An Technology (Shenzhen) Co., Ltd., Shenzhen 518063, China
2. Tianjin Earthquake Administration, Tianjin 300201, China
3. Business School of Hunan University, Changsha 410082, China
4. Shenzhen Baoan District Education Information Center, Shenzhen 518101, China

Abstract

Denoising of seismic waveform signals is crucial for seismic monitoring and seismological research. To this end, we propose an end-to-end deep learning method for denoising seismic waveforms. The method combines the deep convolutional network with the multi-head self-attention mechanism. We employ a residual encoder-decoder structure, which is particularly well-suited for processing signals with complex backgrounds and rich details. At the same time,

the multi-head self-attention mechanism can capture long-range dependencies. By jointly constraining the model with a consistent correlation loss and a frequency-domain mean squared error loss, outstanding denoising performance is achieved in both the time and frequency domains. Evaluation of the publicly available dataset STEAD shows that our method outperforms traditional and existing deep learning methods in two key metrics: peak signal-to-noise ratio (PSNR) and signal correlation coefficient (CC), achieving a Pearson correlation of 0.918 and a PSNR of 36.79, reaching the state-of-the-art performance. Furthermore, we have further validated our method using the seismic waveform data recorded by the Beijing-Tianjin-Hebei earthquake early warning network, which started operating in 2021, and the results indicate that our approach can effectively suppress noise while better preserving seismic signals (achieving a CC of 0.70 and a PSNR of 35.26).

Key words

seismic signal denoising, deep learning, convolutional network, self-attention mechanism, residual encoder-decoder

0 引言

地震波降噪是地球物理勘探及相关研究领域的一项关键技术。作为研究地下介质结构及性质的主要信息载体，地震波数据的信号质量对勘探精度及可靠性影响重大。然而，在实际数据采集过程中，除了所需的介质响应信号，还不可避免地混杂了人为噪声源（如交通、工业等）、自然环境噪声源以及测量系统本身的干扰噪声等多种噪声信号。因此，高效的地震波降噪算法对于地震数据处理而言具有重要意义，是许多地震学研究的基础，如震相识别、震源反演、地震勘探等。近年来，研究者们致力于开发各种先进的地震波降噪方法^[1-3]，旨在显著提升信噪比，增强地震数据的清晰度和可靠性。这些算法利用地震波和噪声在时空频率领域的不同特征实现分离，为地下介质结构解释提供更可靠的基础。发展高精度、高效率地震波降噪算法将持续是该领域的重点研究方向。

传统的地震波降噪方法主要基于机器学习组合技术，这些方法具有较好的可解释性和可控性，因此广受青睐。然而，与基于深度学习的方法相比，它们在降噪效

果上表现较为逊色。最常见的非深度学习方法是基于频域滤波的方式，如带通滤波。随后，基于时频信息的降噪方法应运而生，如小波变换^[2]、短时傅里叶变换（short time Fourier transform, STFT）^[4]、Curvelet变换^[5]、Shearlet变换^[6]。然而，当噪声频率与地震频率相近时，时频法的作用受到限制。一些传统的机器学习方法也可用于获得更优的去噪效果，如独立成分分析^[7]、字典学习^[8]等。尽管如此，上述方法仍然存在超参数选择和计算速度问题。

近10年来，基于深度学习的地震波降噪方法逐渐成为研究热点并成为主流^[9-12]。与传统机器学习方法相比，深度学习方法通常可以带来显著的降噪效果提升，且计算效率较高。然而，这些方法也存在一些不足，如泛化性差（即在未知数据集上表现一般）、可解释性低等问题。Zhu等^[13]提出了DeepDenoiser，这是一种基于编码器-解码器架构的地震波降噪方法。该方法首先将时域信号转换为时频域表示，在频域进行降噪处理后，再重建回时域信号。Van等^[14]提出了一种自监督的波形数据降噪方法，在光纤分布式地震波信号降噪任务中取得了较好的降噪效果。Novoselov等^[15]设计了一种基于双通路循环神经网络的地震波降噪算法。在2024年的一些研究

中^[16-18]，研究者试图基于Transformer架构来解决传统基于卷积神经网络中感受野不足的问题，还有Wang等^[19]通过添加自监督学习增强了特征提取的质量。但这些方法在本质上较为相似，大多是添加注意力机制，侧重于架构的改变，且多基于一维或二维的单一数据或约束进行建模，对噪声的抑制不够充分，缺乏对统计规律的有效抑制，导致泛化性不足，未能从根本上解决问题。鉴于此，笔者以DeepDenoiser为基线进行实验。虽然上述方法都取得了一定的进展，但目前在地震波降噪领域，现有方法尚缺乏在统一数据集上的公平比较评估。因此，该领域仍有进一步改进的空间，有待后续研究深入探索。

基于上述讨论，本文提出一种新颖的端到端地震波信号降噪方法。该方法采用多尺度卷积与自注意力机制，同时引入适用于1D信号、具有统计学意义的降噪损失函数，并结合2D频谱损失的方法，提升地震波信号的降噪效果。为了公平评估现有方法，笔者分别在公开数据集和本地数据集上构建了基准测试，并对所提出算法进行了全面评估。实验结果表明，本文提出的方法达到了先进水平，并且在有效降噪的同时能够很好地保留地震信号，特别是P波到达信号。此外，相较于其他传统降噪方法，本文算法也有较快的推理速度，更有利于在实际场景中应用。

1 地震波降噪方法

1.1 地震波降噪问题

采集的地震波信号通常受到多种噪声的影响，这些噪声源主要包括自然噪声^[20]，如海浪、滑坡等，以及人为噪

声^[20-21]，如火车、工厂等。此外，采集过程中也可能引入系统噪声^[22]。上述噪声源通常被认为与地壳运动（即有效地震信号）是相互独立的事件，因此在处理地震数据时，可以将噪声视为在有效信号上叠加的一个加性噪声成分。本文用 $X_{\text{noisy}} \in \mathbb{R}^T$ 表示采集到的观测数据，则有：

$$X_{\text{noisy}} = X + N \quad (1)$$

其中， X 表示真实的地震信号， T 为信号长度， N 表示噪声。本文的目标是已知观测 X_{noisy} ，得到一个降噪函数 f ，有 $f(X_{\text{noisy}}) = X$ 约等于 $X_{\text{noisy}} - N$ 。因而降噪函数 f 可视为对噪声的估计函数。

1.2 降噪网络架构

本文从数据驱动的角度，使用深度学习拟合降噪函数 f 。具体而言，笔者提出了带多头自注意力机制的深度残差卷积网络，该网络可看作U-Net^[23]和Transformer^[24]的结合。整体架构如图1所示，其架构为编码器-解码器结构。

首先，对于输入的地震波数据，模型会经过一个以一维卷积神经网络为主的编码器进行深度特征提取。由于卷积神经网络具有有限感受野的局限性，单纯通过堆叠多层卷积和池化操作难以提取输入数据的全局信息（只包含其前后有限范围的信息）。为此，笔者将提取到的特征输入一个由多头自注意力机制和全链接层组成的变换器层（Transformer）。经此模块，即便是单帧的特征也包含了整个输入数据的信息。但如果要实现端到端的地震波降噪，还需要将提取的特征解码成降噪后的真实信号。为此，笔者使用一个由反卷积和卷积层组成的解码器。经过此模块，即可还原出降噪后的干净地震波信号。考虑到地

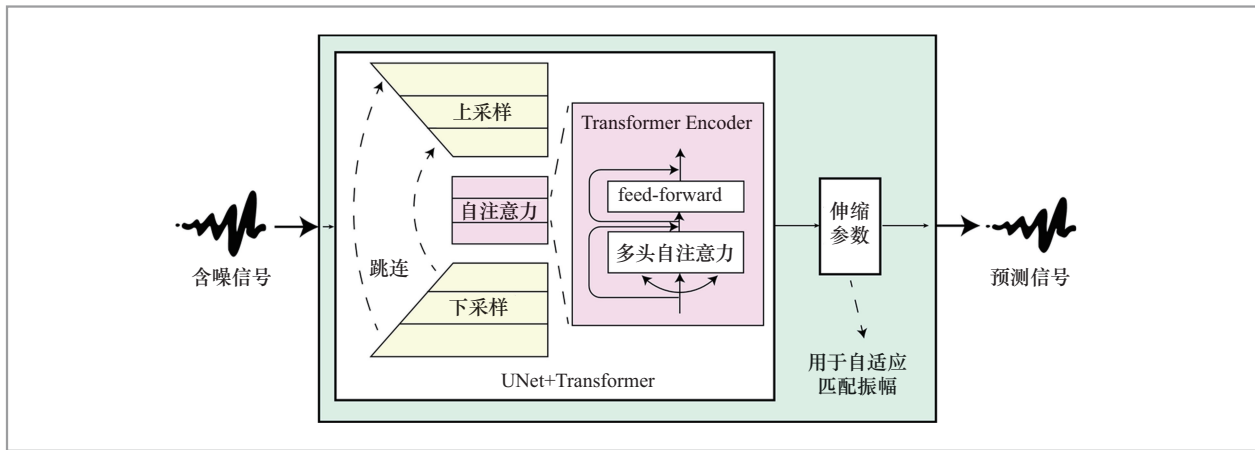


图1 整体架构

震波的噪声源主要是加性噪声，为了更好地实现对噪声的建模，极大地保留原有信号的信息，笔者在编码器和解码器之间使用了残差连接。以网络最初和最后一层之间的残差连接为例，可表达为：

$$X = f(X_{\text{noisy}}) + X_{\text{noisy}} \quad (2)$$

如式(2)所示，通过残差连接，笔者将对干净信号的建模转换成对噪声的估计，即式(2)中的 $f(X_{\text{noisy}})$ 变为了对噪声的直接估计。

具体而言，模型的编码器由8个卷积子模块构成，一个子模块由一个步长为2的一维卷积、线性修正激活函数(ReLU)、步长为1的一维卷积和门控线性单元(gated linear unit, GLU)激活函数构成。卷积的通道数分别为64和128，卷积核尺寸分别为4和1。为了将自注意力模块和编码器模块之间的维度对齐，采用卷积核尺寸为1、通道数为512的一维卷积层。对于自注意力模块，笔者使用2层的变换器编码器模块，其注意力头数为6，输入向量维度为512，隐向量维度为2048。此外，笔者通过通道数为64的一维卷积将

向量维度转为64维，输入解码器。解码器也由8个子卷积模块构成，每个子卷积模块由一个一维卷积、一个GLU激活函数、一个步长为2的一维反卷积和一个PReLU激活函数构成。卷积的通道数分别为128和64，卷积核尺寸分别为1和4。此外，对于上述模型的输出，笔者乘以一个可训练的伸缩参数，用于自适应调整振幅的大小。

1.3 损失函数

损失函数的设计对于模型的优化目标及最终表现至关重要。针对地震波降噪任务，笔者专门设计了损失函数。首先，笔者认为模型降噪后的地震波在时域上要与真实标签之间保持高度一致性。因而本文引入了一致性相关系数(concordance correlation coefficient, CCC) ρ_{CCC} ^[25]作为损失函数，如图2下方框内CCC Loss模块所示。该损失函数结合了均方误差对绝对差值的度量和皮尔逊相关系数对相关性的度量，是一种综合性更强的损失函数，其具体计算方式如下：

$$\rho_{\text{CCC}} = \frac{2\sigma_{XY}^2}{\sigma_X^2 + \sigma_Y^2 + (\mu_X - \mu_Y)^2} \quad (3)$$

其中, X 、 Y 分别为预测数据和标签数据, $\sigma_{XY}^2 = \text{cov}(X, Y)$, $\mu_X = \mathbb{E}(X)$, $\mu_Y = \mathbb{E}(Y)$, $\sigma_X^2 = \text{var}(X)$, $\sigma_Y^2 = \text{var}(Y)$, $\text{cov}(\cdot)$ 表示协方差, $\text{var}(\cdot)$ 表示方差, $\mathbb{E}(\cdot)$ 表示数学期望。

神经网络优化需要最小化损失函数, 则通过 CCC 导出的信号重构损失函数 L_{signal} 为:

$$L_{\text{signal}} = 1 - \rho_{\text{CCC}} \quad (4)$$

由于时域信号的复杂性, 纯粹基于时域信号的模型可能难以准确捕捉地震波数据中包含的丰富信息。因此, 除了考虑时域上的一致性外, 还需要关注频域信息的保持。由于频域信号天然具有信息简单性的特点, 通过引入频域约束可以提高模型对复杂信号的建模能力。为此, 本文采用短时傅里叶变换, 如图 2 下方框内频谱 Loss 所示, 将降噪后的预测语音 X 和真实标签语音 Y 通过 STFT 转换到时频域后, 分别形成振幅谱 $\hat{X} = \text{STFT}(X)$ 和 $\hat{Y} = \text{STFT}(Y)$ 。随后, 对这两个振幅谱使用均方误差 (mean square error, MSE) 作

为损失函数 L_{spec} , 其具体计算式如下:

$$L_{\text{spec}} = \text{MSE}(\hat{X}, \hat{Y}) = \frac{1}{n} \sum_{i=1}^n (\hat{X}_i - \hat{Y}_i)^2 \quad (5)$$

其中, n 表示样本数量, \hat{X}_i 为预测值, \hat{Y}_i 为真实值, i 表示第 i 个样本。

最后, 引入一个超参数 α 来调和这两个损失函数, 形成最终损失函数 L :

$$L = L_{\text{signal}} + \alpha \cdot L_{\text{spec}} \quad (6)$$

2 设计与评估方法

2.1 实验数据

为了进一步验证本文提出方法的有效性, 笔者使用基于斯坦福地震数据库 (Stanford earthquake dataset, STEAD) 构建的 STEAD 数据集^[26-27]进行实验验证。该数据集包含了 2 613 个站点中的 1 786 个站点的的海震数据, 以及 306 个专门用于噪声记录的站点数据。该数据集中选取了震级大于 2、震源一站点距离小于 100 km、纵波在 7 s 后到达的 30 s 长地震道数据进行采样。该数据记录包含东西分量 (X)、

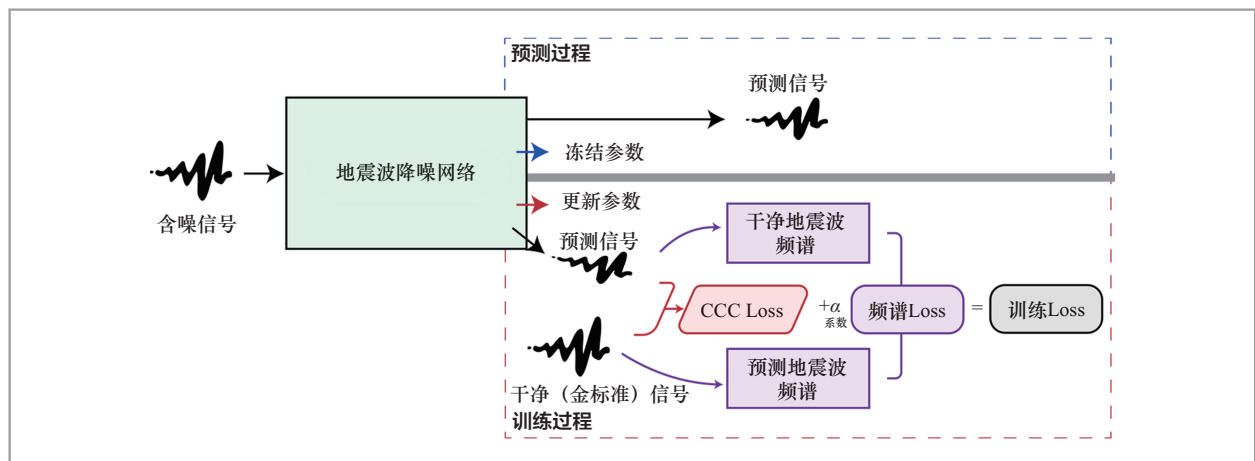


图2 训练和预测流程

南北分量 (Y)、纵向分量 (Z) 3 个方向的地震信号数据。该数据集共有 30 491 条地震道数据用于模型训练, 有 3 441 条数据用于模型验证, 另外有 5 994 条数据用于模型测试。在这一大规模、多样化的数据集上进行实验, 可以全面考察本文所提方法在不同地震情况下的泛化能力。

此外, 笔者在本地数据集上进行了进一步的测试。数据集为自 2021 年开始运行的京津冀地震预警台网记录的地震波形数据集。其包含同站采集的 1 856 条测震数据和强震数据。其中强震数据是为了观测强地震发生而采集的信号, 其采集设备灵敏度更低, 采集数据包含相对多的噪声。测震数据是为了测量地震而采集的信号, 具有更高的灵敏度, 采集信号包含的信噪比相对更高。本文将强震数据视为含噪数据, 将测震数据视为降噪后的金标准。具体地, 对每个数据段截取 4 min 的片段, 从发震时刻向前 1 min, 向后 3 min, 发震时刻向前为噪声数据。强震数据是经过去均值计算、加速度转换为速度、0.1~40 Hz 四阶带通滤波后截取的片段数据; 测震数据是经过去均值计算、0.1~40 Hz 四阶带通滤波后截取的片段数据。两组数据的物理量都是速度, 采样频率为 100 Hz, 每个数据片段有 24 000 个采样点。

2.2 评估指标

为了全面评价本文所提方法的性能, 笔者采用峰值信噪比 (peak signal to noise, PSNR)、相关系数 (cross-correlation, CC) 两个指标评估模型的降噪水平。

峰值信噪比: 衡量目标信号相对于背景噪声强度的指标。PSNR 值越高, 表明目标地震信号相对于背景噪声越显著, 这

对后续的地震数据分析和理解更有帮助。PSNR 在不同场景下的计算方式会存在差异, 对于本文场景, 其计算式如下:

$$\text{PSNR} = 20 \cdot \log_{10} \left(\frac{\text{MAX}}{\sqrt{\text{MSE}}} \right) \quad (7)$$

考虑到信号的值域为 $[-1, 1]$, 则 MAX 设为定值 2, MSE 表示均方误差。

相关系数: 描述两个信号之间相似性的指标。CC 值越大, 表明两组信号之间的相关性越强。笔者通过计算降噪后的数据与不含噪声的原始数据之间的相关系数来度量模型降噪后对原始信号的保留程度, 其计算式如下:

$$\text{CC} = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sqrt{(X - \bar{X})^2} \cdot \sqrt{(Y - \bar{Y})^2}} \quad (8)$$

其中, X 、 Y 表示两组信号, \bar{X} 和 \bar{Y} 分别表示其对应的均值。

2.3 实验设置细节

2.3.1 模型训练

模型训练分为两个阶段: 预训练阶段和微调阶段。

预训练阶段的目标在于利用大规模标注数据, 学习基础的地震波信号去噪能力, 为微调阶段奠定基础。此阶段采用 1×10^{-4} 的初始学习率, 仅利用信号重构损失 L_{signal} 作为优化目标, 这种策略有助于模型在初始阶段获得稳健的去噪能力。同时, 设置 1×10^{-4} 的权重衰减系数, 结合 AdamW 优化器, 实现参数的合理更新。

在完成预训练后, 进入微调阶段对模型进行进一步训练, 使之更加适应目标任务。此阶段引入了逐阶段学习率衰减的调度机制。初始学习率保持不变, 但每隔 10 000 步将学习率降低至原学习率的

30%，循环往复。该调度方案使模型在后期以较小的步长精修参数，避免参数值过度震荡。同时，将频谱损失 L_{spec} 作为辅助目标引入，与重构损失联合优化，进一步增强模型生成样本的稳定性和准确性。

2.3.2 数据增强

在模型训练过程中，采用数据增强的方式来提升模型的鲁棒性。数据增强是一种有效的技术手段^[3]，可以在保留原始数据的基本特征和属性的同时，通过一定的变换操作产生新的数据样本，从而扩充训练集的数据量，增强模型的泛化能力。本文采用了3种数据增强方法，分别为翻转增强（flipping augmentation）、振幅增强（amplitude augmentation）和截断增强（truncation augmentation），具体如下。

- 翻转增强：地震波信号具有相位不敏感的特点，即将信号翻转 180° 不会改变其本质特性。因此，在50%的概率下同时对输入地震波信号 x 和标签信号 y 进行翻转操作，即乘以 -1 。该操作可以增加数据样本的多样性，提高模型对不同相位信号的鲁棒性。

- 振幅增强：地震波对于地震强弱在特定强度上，输入信号和预测信号的振幅关系可近似看作线性关系。基于此，在50%的概率下同时将输入地震波信号 x 和标签信号 y 乘以一个在 $0.9\sim 1.1$ 区间内均匀采样的系数 β 。这种操作可以模拟不同振幅下的地震波信号，增强模型对振幅变化的适应能力。

- 截断增强：尽管地震波理论上在长时间内都具有相互因果的关联，但瞬时的关系更重要。因此，在50%的概率下随机截取输入地震波信号 x 和标签信号 y 的一部分，作为新的训练样本。该操作可以强化模型对局部信号的建模能力，提高其在任

意时刻预测地震波的精度。

上述3种数据增强方法可以有效扩充训练集的数据量和多样性，从而提高模型的泛化性能，使其能够更准确地预测任意时刻的地震波信号。

2.3.3 基线方法对比

为了客观评估本文所提方法的有效性，本文将其与以下几种基线方法进行对比：添加噪声后的波形、DeepDenoiser^[13]以及小波变换降噪。其中，小波变换降噪是经典的地震波信号去噪手段，目前已在多个降噪场景中得到应用。DeepDenoiser是由Zhu等^[13]提出的一种基于深度学习的降噪方法。该方法首先将时域信号转换至时频域，然后在频域上训练一个U-Net用于去噪，最后重建回时域信号。

3 定量定性分析结果

本节对模型的降噪效果进行定量和定性分析。

3.1 定量分析结果

3.1.1 信噪比评估

首先对不同噪声水平的地震波样本使用多种降噪方法进行降噪处理，并统计其峰值信噪比（PSNR）。结果见表1，可以发现，无论是在公开数据集还是在本地数据集上，传统的小波变换降噪方法在PSNR提升方面远小于两种基于深度学习的方法，这体现了深度学习方法的优越性。

此外，从表1发现，无论是东西分量、南北分量、纵向分量，还是整体水平，本

表1 不同方法降噪后的峰值信噪比

数据集	方法	东西分量	南北分量	纵向分量	总值
STEAD	带噪声	30.13 ± 14.12	29.63 ± 13.26	30.25 ± 6.94	28.37 ± 4.25
	小波变换	30.44 ± 4.95	29.36 ± 4.83	30.96 ± 4.77	29.57 ± 3.84
	DeepDenoiser	32.95 ± 6.02	32.83 ± 5.76	34.94 ± 5.37	33.64 ± 4.99
	本文方法	36.03 ± 5.66	35.95 ± 5.67	37.90 ± 5.50	36.79 ± 5.08
本地数据集	带噪声	23.87 ± 6.96	23.64 ± 6.97	22.07 ± 6.03	25.09 ± 7.01
	小波变换	23.94 ± 6.97	23.69 ± 6.99	22.18 ± 6.06	25.28 ± 7.02
	DeepDenoiser	29.75 ± 5.77	29.31 ± 5.57	27.65 ± 4.89	30.99 ± 5.64
	本文方法	36.41 ± 8.71	35.85 ± 8.95	33.32 ± 8.20	35.26 ± 7.16

文提出的方法均明显优于对比的基线方法。即使对比同类的基于深度学习的方法，本文提出的模型仍然表现出一定的优势，特别是在本地数据集上。

3.1.2 相关性评估

笔者进一步统计了使用不同降噪方法处理后的地震波信号与金标准信号之间的相关系数。结果见表2，可以发现，基于深度学习的方法相较于传统的小波变换降噪，可以带来更大幅度的相关系数提升。并且，与当

前比较领先的基于深度学习的DeepDenoiser方法相比，本文提出的方法仍表现出显著的优势。另外，本文提出的方法相较于对比的基线方法具有更小的标准差，这表明其稳定性更高。在本地数据集上，本文方法在相关系数上远高于其他方法。这是因为，相较于STEAD数据集人为添加的噪声，强震数据和测震数据之间本身的相关性比较低，并且测震数据中本身就包含一些噪声数据，因此直接使用传统的降噪的方法无法估计出更符合测震数据的信号。

表2 不同方法降噪后的相关系数(CC)对比

数据集	方法	东西分量	南北分量	纵向分量	总值
STEAD	带噪声	0.72 ± 0.19	0.71 ± 0.19	0.64 ± 0.22	0.69 ± 0.18
	小波变换	0.74 ± 0.19	0.74 ± 0.18	0.66 ± 0.23	0.71 ± 0.18
	DeepDenoiser	0.87 ± 0.13	0.86 ± 0.13	0.79 ± 0.20	0.85 ± 0.12
	本文方法	0.92 ± 0.10	0.92 ± 0.10	0.88 ± 0.13	0.92 ± 0.07
本地数据集	带噪声	0.16 ± 0.32	0.16 ± 0.31	0.14 ± 0.25	0.15 ± 0.29
	小波变换	0.16 ± 0.31	0.17 ± 0.31	0.15 ± 0.26	0.15 ± 0.29
	DeepDenoiser	0.21 ± 0.42	0.20 ± 0.40	0.15 ± 0.36	0.19 ± 0.38
	本文方法	0.72 ± 0.32	0.71 ± 0.31	0.66 ± 0.31	0.70 ± 0.29

3.1.3 推理速度评估

笔者对这3种方法的速度进行了全面评估。基于传统统计的方法，在配备Intel i7 CPU的设备上进行测试；基于深度学习的DeepDenoiser，分别在上述CPU以及GPU为NVIDIA 4060Ti的设备上测试，其中STFT和iSTFT两个部分仍使用CPU计算；本文方法同样分别在上述CPU以及上述GPU的设备上测试。

本文使用时长为15 360 s（对应1 536 000个采样点）的数据进行测试，模型推理速度结果见表3。从表3可以看出，与DeepDenoiser相比，本文方法的推理速度具有相当的竞争力。此外，相较于传统的基于CPU计算的小波变换方法以及部分基于GPU的DeepDenoiser，本文方法在速度上也有显著的优势。尤其是，即便同样在CPU上进行测试，本文方法也依然具备一定的优势。这表明，本文方法能够充分发挥GPU强大的并行计算能力，从而显著提升计算速度。

3.2 针对不同噪声水平样本的降噪效果

笔者进一步分析了本文方法在不同噪声水平下的降噪效果。如图3所示，笔者分别统计了带噪声信号和降噪后信号的峰值信噪比及相关系数散点图分布，图中每一个点的横坐标为降噪前的指标，纵坐标为降噪后的指标。由图3可见，随着噪声水平的上升，降噪后信号的PSNR呈现比较明显的上升趋势，但CC随噪声水平的变化相对不明显。这可能是由于本文方法在幅值复原能力上相对较弱，从而导致PSNR提升受到噪声影响。相较之下，无论噪声水平如何，本文方法均能获得与金标准信号具有较高相似性的降噪结果，各个指标表现出良好的稳健性。

表3 各种方法的速度对比/s(↓)

对比项	小波变换	DeepDenoiser	本文方法
CPU	18.60	11.97	12.31
GPU	--	2.42	1.75

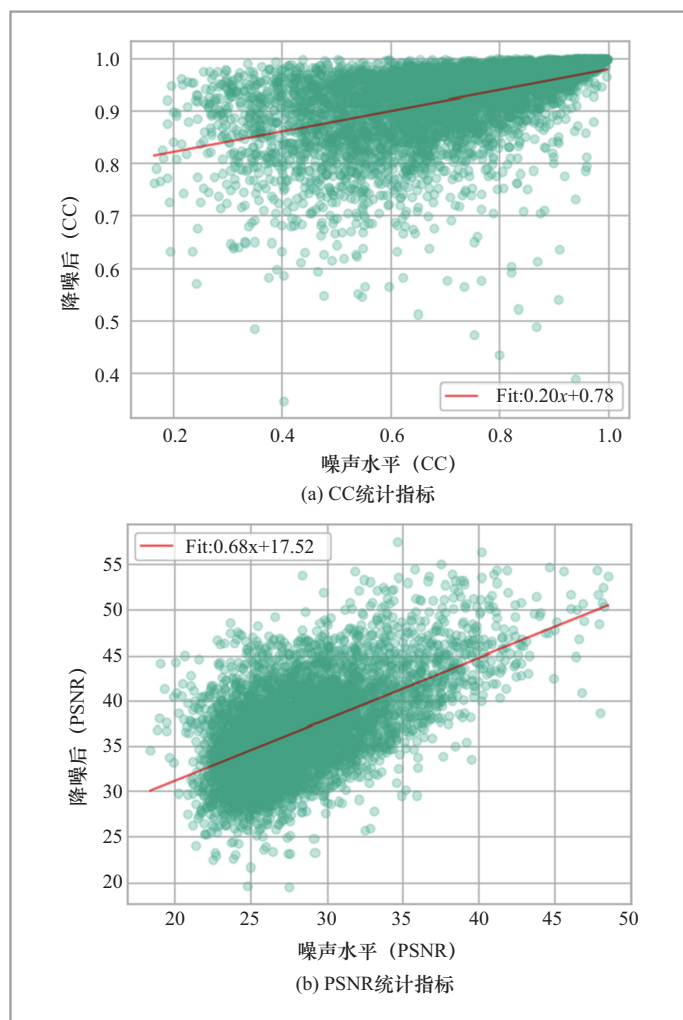


图3 带噪声信号和降噪后信号的散点图

3.3 可视化定性结果

为了更直观地评估本文方法的降噪效果，笔者选取STEAD数据集中测试集的第399条地震波数据进行可视化分析。如图4、图5、图6所示，可以明显观察到本




图4 测试集第354个样本东西分量的降噪结果

文方法在东西分量、南北分量和纵向分量3个方向上均取得了显著的降噪效果，降噪后的波形与金标准波形能够较好地匹配。除此之外，本文方法对于地震发生前的噪声信号也具有明显的降噪能力，即P波到达之前的波形。若将P波到达前的波形视作纯噪声，则本文方法在金标准的基础上实现了进一步降噪。另外，本文方法可以

更容易判断出P波和S波的到达时间，这对后续的地震分析具有十分重要的意义。

此外，笔者对比了不同降噪方法的可视化降噪效果。考虑到选取样本的震级较低，对此类地震通常会采用0.8~8 Hz的带通滤波进行处理，笔者在进行可视化时添加了带通滤波处理的结果。如图7和图8所示，相较于其他对比方法，本文方法展




图5 测试集第354个样本南北分量的降噪结果

现出更优秀的降噪能力, 这与前文的定量分析结果一致。另外, 可以发现, DeepDenoiser 表现出来过度降噪的现象, 在其降噪过程中, 存在将P波到达的信号直接去除的情况, 这对于地震预警来说是十分致命的问题。此外, DeepDenoiser 对非信号区的噪声抑制效果十分明显。对比之下, 本文方法可以在抑制噪声的同时,

充分保留地震信号, 特别是相较于 DeepDenoiser, 本文方法能够保留P波到达的地震信号。

4 结束语

本文提出了一种基于深度学习的端到




图6 测试集第354个样本纵向分量的降噪结果

端地震波降噪方法，旨在提高地震监测和地震学研究的数据质量。该方法采用融合卷积神经网络和多头自注意力机制的编码器-解码器架构，能同时处理复杂背景噪声和细节丰富的地震波信号，通过联合时域一致性相关性损失和频域均方误差损失函数的约束优化，在时域和频域上均实现了优异的降噪效果。该方法的优势在于：

无须人工参数调整，能一步完成三分量地震波信号的联合降噪；捕捉了不同分量间的内在联系，简化了处理流程；在公开数据集STEAD和本地数据集上的测试显示，其峰值信噪比和信号相关性两个关键指标均优于传统和其他深度学习方法；可视化分析发现，相较于DeepDenoiser方法，其能够在降噪的同时较好地保留地震信号。

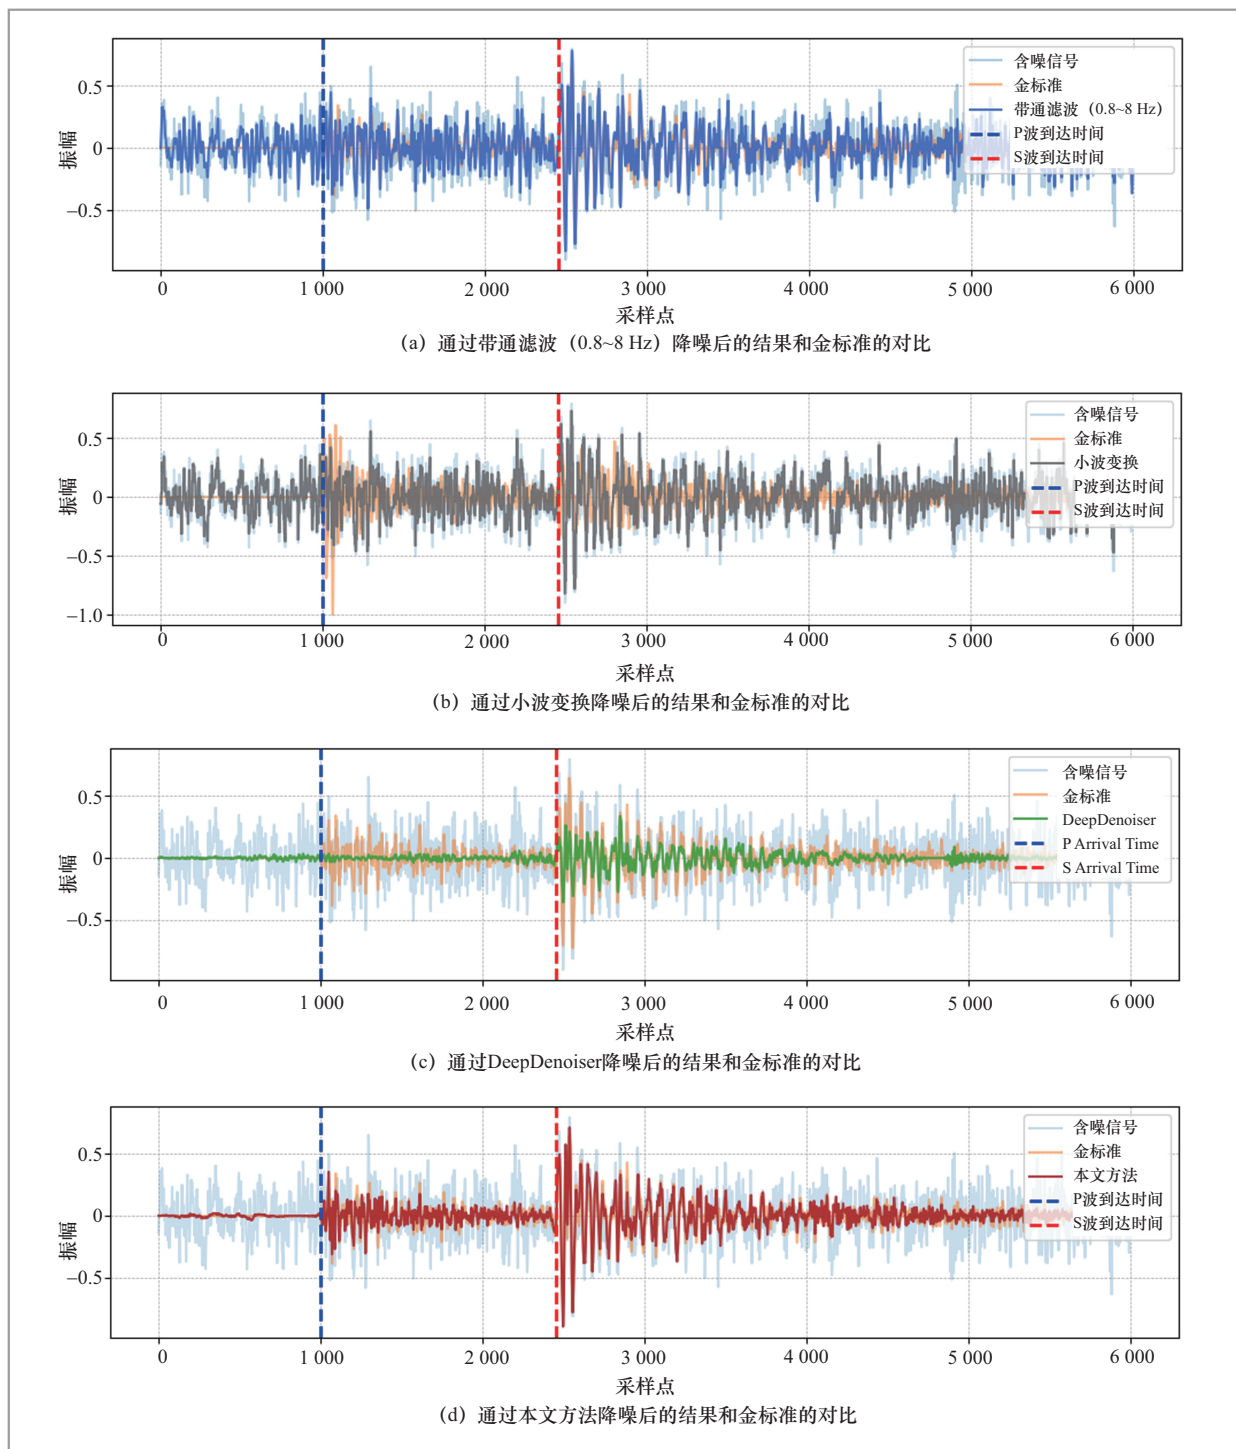


图7 不同方法对测试集第354样本的纵向信号的降噪能力对比

在未来工作中，笔者将在更多真实数据上对模型进行进一步训练，推动该方法在我国地震监测、勘探等领域的实际应用。

同时，还需对方法的泛化能力和鲁棒性进行深入测试和改进，以提升其在实际应用场景中的适应性和稳健性。

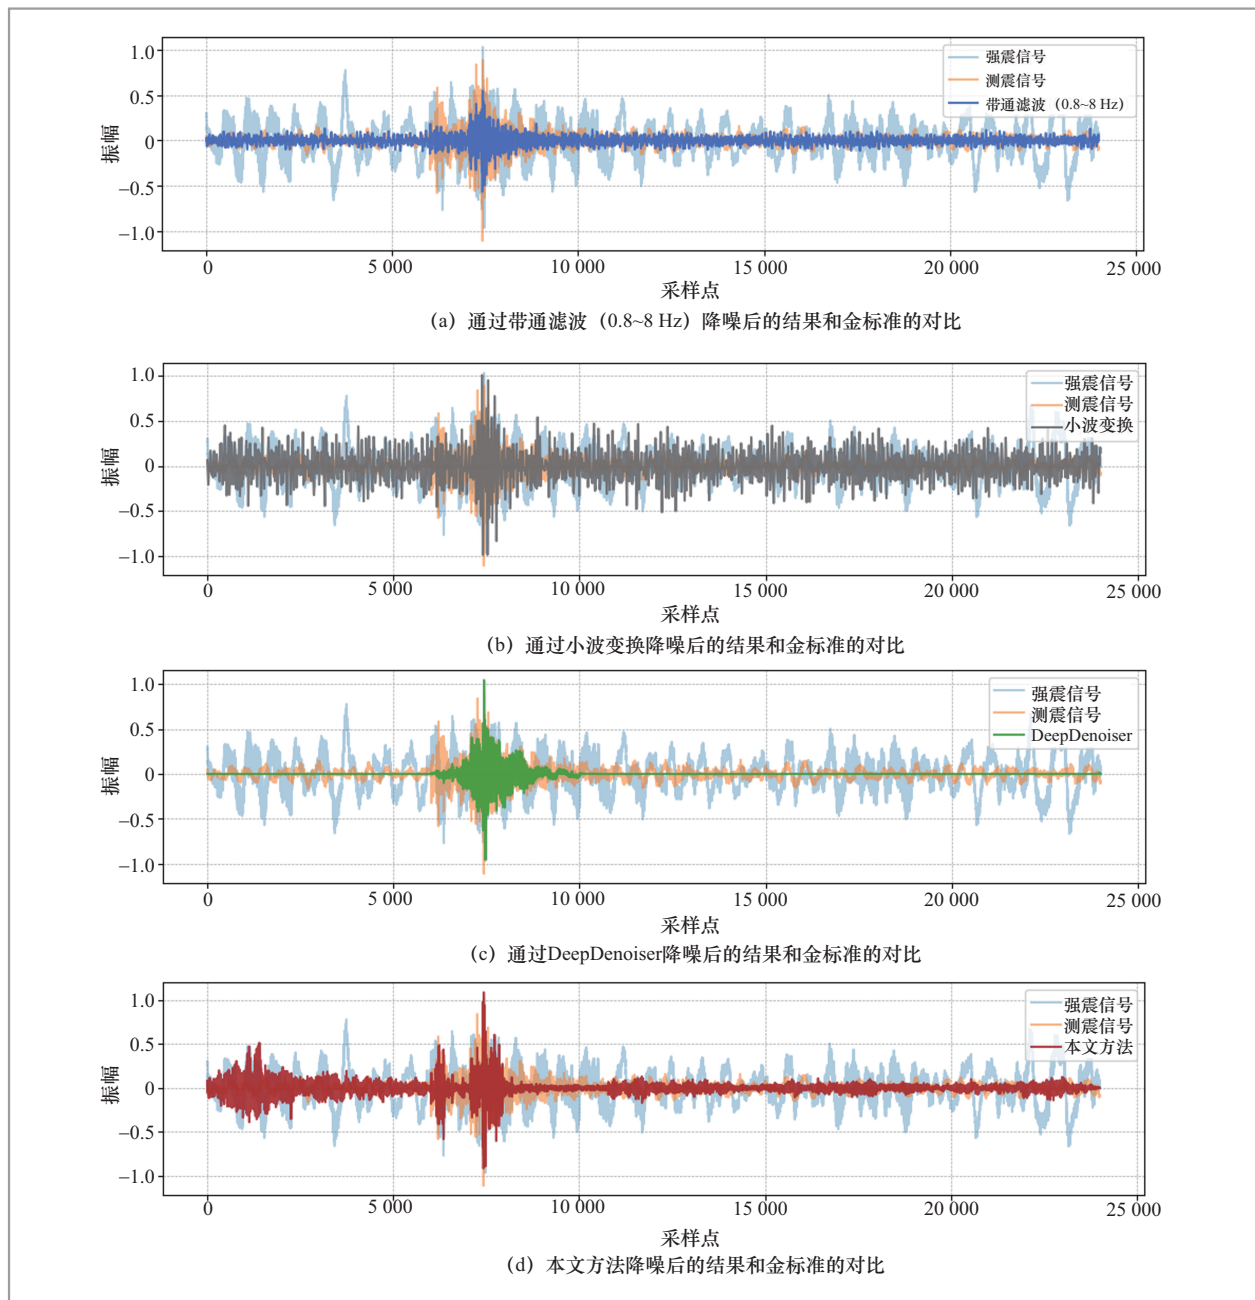


图8 不同方法对本地数据集2022.04.25.T.12.52.05.BJ.MIY号样本纵向信号的降噪能力对比

参考文献:

- [1] 董非非, 曾庆平, 罗桂生. 小波阈值降噪法在地震波信号处理中的应用[J]. 科技创新与应用, 2012, 2(15): 15-16.
- Dong F F, Zeng Q P, Luo G S. Applica-

tion of wavelet threshold denoising method in seismic wave signal processing[J]. Technology Innovation and Application, 2012, 2(15): 15-16.

- [2] 富一博. 一种海底地震波小波阈值降噪方法[J]. 中国科技信息, 2017(17): 88-89, 14.

- Fu Y B. A wavelet threshold denoising method for submarine seismic wave[J]. *China Science and Technology Information*, 2017(17): 88-89, 14.
- [3] 孙苗, 吴立, 周玉纯, 等. 水下钻孔爆破地震波信号的最优降噪光滑模型[J]. *华南理工大学学报(自然科学版)*, 2019, 47(8): 31-37.
- Sun M, Wu L, Zhou Y C, et al. Optimal denoising smooth model of underwater drilling blasting seismic wave signal[J]. *Journal of South China University of Technology (Natural Science Edition)*, 2019, 47(8): 31-37.
- [4] Mousavi S M, Langston C A. Adaptive noise estimation and suppression for improving microseismic event detection[J]. *Journal of Applied Geophysics*, 2016, 132: 116-124.
- [5] Tang G, Ma J W. Application of total-variation-based curvelet shrinkage for three-dimensional seismic data denoising [J]. *IEEE Geoscience and Remote Sensing Letters*, 2011, 8(1): 103-107.
- [6] Zhang C, Van Der Baan M. Multicomponent microseismic data denoising by 3D shearlet transform[J]. *Geophysics*, 2018, 83(3): 45-51.
- [7] Moni A, Bean C J, Lokmer I, et al. Source separation on seismic data: application in a geophysical setting[J]. *IEEE Signal Processing Magazine*, 2012, 29(3): 16-28.
- [8] Chen Y K, Ma J W, Fomel S. Double-sparsity dictionary for seismic noise attenuation[J]. *Geophysics*, 2016, 81(2): 103-116.
- [9] Tibi R, Hammond P, Brogan R, et al. Deep learning denoising applied to regional distance seismic data in Utah[J]. *Bulletin of the Seismological Society of America*, 2021, 111(2): 775-790.
- [10] Dong X T, Zhong T, Li Y. A deep-learning-based denoising method for multiarea surface seismic data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(5): 925-929.
- [11] 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.
- 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.
- [12] 张岩, 李新月, 王斌, 等. 基于深度学习的鲁棒地震数据去噪[J]. *石油地球物理勘探*, 2022, 57(1): 12-25, 4.
- Zhang Y, Li X Y, Wang B, et al. Robust seismic data denoising based on deep learning[J]. *Oil Geophysical Prospecting*, 2022, 57(1): 12-25, 4.
- [13] Zhu W Q, Mousavi S M, Beroza G C. Seismic signal denoising and decomposition using deep neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(11): 9476-9488.
- [14] Van Den Ende M, Lior I, Ampuero J P, et al. A self-supervised deep learning approach for blind denoising and waveform coherence enhancement in distributed acoustic sensing data[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(7): 3371-3384.
- [15] Novoselov A, Balazs P, Bokelm-Ann G. SEDENOSS: SEparating and DENOising seismic signals with dual-path recurrent neural network architecture[J]. *Journal of Geophysical Research (Solid Earth)*, 2022, 127(3): e2021JB023183.
- [16] Li F, Liu H L, Wang W, et al. Swin transformer for seismic denoising[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 7501905.
- [17] Ding M, Zhou Y T, Chi Y. Seismic signal

- denoising using swin-conv-UNet[J]. Journal of Applied Geophysics, 2024, 223: 105355.
- [18] Chen J X, Chen G X, Li J, et al. Efficient seismic data denoising via deep learning with improved MCA-SCUNet [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5903614.
- [19] Wang H, Lin J, Li Y, et al. Self-supervised pre-training transformer for seismic data denoising[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1-25.
- [20] 徐义贤, 罗银河. 噪声地震学方法及其应用[J]. 地球物理学报, 2015, 58(8): 2618-2636.
Xu Y X, Luo Y H. Methods of ambient noise-based seismology and their applications[J]. Chinese Journal of Geophysics, 2015, 58(8): 2618-2636.
- [21] 谢江涛, 林丽萍, 赵敏, 等. 四川地区地震背景噪声特征分析[J]. 地震学报, 2021, 43(5): 533-50.
Xie J T, Lin L P, Zhao M, et al. Analysis of seismic background noise characteristics in Sichuan region[J]. Acta Seismologica Sinica, 2021, 43(5): 533-50.
- [22] 国陇予, 刘财, 刘洋. 滤波类方法衰减地震数据噪声[J]. 地球物理学进展, 2018, 33(5): 1890-1896.
Guo L Y, Liu C, Liu Y. Filtering methods attenuate seismic data noise[J]. Progress in Geophysics, 2018, 33(5): 1890-1896.
- [23] Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention [M]. Cham: Springer International Publishing, 2015.
- [24] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 6000-6010.
- [25] Lin L I. A concordance correlation coefficient to evaluate reproducibility[J]. Biometrics, 1989, 45(1): 255-268.
- [26] Mousavi S M, Zhu W, Sheng Y, Beroza G C. A global data set of seismic signals for AI[C]//Proceedings of the AGU Fall Meeting Abstracts. [S.l.:s.n.], 2019.
- [27] Trappolini D, Laurenti L, Poggiali G, et al. Cold diffusion model for seismic denoising[R]. AGU23, 2023.

作者简介



赵博涛 (1997-), 男, 平安科技(深圳)有限公司高级算法工程师, 主要研究方向为深度学习、语音算法以及具身智能等, 发表过多篇国际论文, 获得多项专利授权。



亢祖衡 (1989-), 男, 平安科技(深圳)有限公司高级算法工程师, 主要研究方向为人工智能、声纹识别、信号处理、音乐生成、大模型等, 发表过多篇国际论文, 获得多项专利授权。



贺亚运（1990-），男，平安科技（深圳）有限公司资深算法工程师，主要研究方向为人工智能、声纹识别、大模型、Agent等，发表过多篇国际论文，获得多项专利授权。



彭俊清（1973-），男，平安科技（深圳）有限公司资深经理，高级人工智能算法研究员，在IT行业耕耘多年，精通架构设计、云平台和AI系统建设，发表多篇论文，获得多项专利授权。



张旭龙（1988-），男，博士，平安科技（深圳）有限公司，高级算法研究员，复旦大学计算机理学博士，2023年入选上海市东方英才计划青年项目。兼任深圳清华大学研究院及中国科学技术大学先进技术研究院校外导师，中国自动化学会联邦数据与联邦智能专业委员会委员。目前是IEEE、中国自动化学会以及中国计算机学会会员。主要研究方向为大模型、具身智能、跨模态智能计算以及模型上下文协议（MCP）等。发表学术论文80余篇，申请国家发明专利授权20余项。



瞿晓阳（1988-），男，博士，平安科技（深圳）有限公司前沿机器学习算法分组负责人，清华大学深圳国际研究生院校外导师，中国科技大学先进技术研究院校外导师，中佛罗里达大学访问学者，从事机器学习、大数据、体系结构方面的研究工作，在语音语义分析、自动化机器学习、零样本和小样本学习、高性能计算与存储等方面经验丰富。在体系结构方向（如INFOCOM、DAC、IPDPS、TPDS）和人工智能方向（如NeurIPS、IJCAI、ICASSP、Interspeech）等国际会议和期刊发表过近50篇文章，其中1篇论文荣获会议最佳学生论文奖提名；担任多个国际期刊的评委，已授权专利70篇，已出版专著2本。



谭毅培（1982-），男，博士，天津市地震局高级工程师。2016年入选中国地震局防震减灾优秀人才，2019年入选中国地震局青年人才计划。主持多项国家自然科学基金青年项目、地震星火计划青年项目、安全天津与城市可持续发展科技重大专项子课题。主要研究方向为数字地震学和地震预测预报，主要包括历史地震震源参数研究、地震序列事件和震相检测研究、前震序列识别和余震序列统计特征研究。



陈雨乐（2006-），女，湖南大学大数据管理与应用专业在读，主要研究方向为大数据、人工智能、生物医学大数据等。



肖春光（1976-），男，深圳市宝安区教育事业发展中心高级教师，主要研究方向为教育数字化、网络安全、信息化教学创新。



王健宗（1983-），男，博士，平安科技（深圳）有限公司副总工程师，资深人工智能总监，联邦学习技术部总经理，智能金融前沿技术研究院院长。美国佛罗里达大学人工智能博士后，美国莱斯大学和华中科技大学联合培养博士，中国计算机学会资深会员，中国计算机学会大数据专家委员会委员，中国自动化学会联邦数据和联邦智能专业委员会副主任。主要研究方向为大模型、联邦学习和深度学习等。

收稿日期: 2025-03-31

通信作者: 王健宗, jzwang@188.com

基金项目: 广东省重点领域研发计划“新一代人工智能”重大专项(No.2021B0101400003)

Foundation Item: The Key Research and Development Program of Guangdong Province (No.2021B0101400003)