



吉林大学

本科生毕业论文（设计）

中文题目 基于多尺度网络的 DAS-VSP 噪声抑制流程设计

英文题目 Design of DAS-VSP noise suppression process based

学生姓名 欧阳天成 班级 01 学号 65200126

学 院 仪器科学与电气工程学院

专 业 测控技术与仪器

指导教师 董新桐 职称 副教授

2023 年 6 月

摘要

分布式声学传感（DAS）被认为是一种新型的地震数据采集技术。与传统的电子检波器相比，DAS 具有成本低、空间分辨率高、覆盖范围好、抗恶劣环境能力强等一系列明显优势。噪声衰减是地震数据处理中必不可少的步骤。然而，DAS 地震数据的去噪任务面临两个主要困难。一方面，DAS 地震资料中的一些背景噪声，如光学低频噪声、水平噪声、衰落噪声等，是常规地震资料所不具备的；另一方面，DAS 地震资料的信噪比（SNR）相对较低。最近，与传统方法相比，卷积神经网络（CNN）显示出更优越的去噪性能。为了顺应这一趋势，我们提出了一种多尺度交互式卷积神经网络（MSI-Net），并将其应用于具有挑战性的 DAS 地震数据的降噪。与现有的大多数用于地震数据去噪的 CNN 架构不同，MSI-Net 通过将固有的串行卷积改进为多尺度并行卷积，同时考虑了粗尺度和细尺度的特征，有利于恢复详细信息。此外，利用一些连接实现不同尺度之间的信息交互，促进了信息的流动，使网络能够从 DAS 地震资料中提取出信息量更大的多尺度特征。此外，仿真算例和实测算例均表明，所提出的 MSI-Net 可以有效衰减多种独特的 DAS 背景噪声，并完全恢复微弱信号。与传统的 CNN 架构相比，MSI-Net 在全局信噪比和局部细节方面表现出更好的性能。

关键词：分布式声学传感；CNN；MSI-Net；降噪；多尺度；

Abstract

Distributed Acoustic Sensing (DAS) is considered a novel seismic data acquisition technology. Compared to traditional electronic geophones, DAS offers a series of significant advantages such as lower cost, higher spatial resolution, better coverage, and stronger resistance to harsh environments. Noise attenuation is an essential step in seismic data processing. However, denoising DAS seismic data faces two main challenges. On the one hand, some background noises in DAS seismic data, such as optical low-frequency noise, horizontal noise, and decay noise, are not present in conventional seismic data. On the other hand, the signal-to-noise ratio (SNR) of DAS seismic data is relatively low. Recently, convolutional neural networks (CNNs) have demonstrated superior denoising performance compared to traditional methods. To adapt to this trend, we propose a Multi-Scale Interactive Convolutional Neural Network (MSI-Net) and apply it to the challenging task of denoising DAS seismic data. Unlike most existing CNN architectures used for seismic data denoising, MSI-Net improves upon inherent serial convolutions by implementing multi-scale parallel convolutions, considering both coarse and fine-scale features, which facilitates the recovery of detailed information. Additionally, utilizing connections to enable information interaction between different scales promotes the flow of information, allowing the network to extract multi-scale features with higher information content from DAS seismic data. Furthermore, both simulation and real-case studies demonstrate that the proposed MSI-Net can effectively attenuate various unique DAS background noises and fully recover weak signals. Compared to traditional CNN architectures, MSI-Net exhibits better performance in terms of overall SNR and local detail preservation.

Keywords: DAS; CNN ; MSI-Net ; Denoising; Multi-Scale.

目录

摘要	I
Abstract	II
目录	III
第 1 章 绪论公式章 1 节 1	1
1.1 课题研究的目的和意义	1
1.2 国内外研究现状	3
1.3 主要研究内容	4
1.4 本文的组织结构	5
1.5 本章小结	6
第 2 章 相关原理及理论研究	7
2.1 DAS-VSP 中的波场和噪声分析	7
2.2 卷积神经网络识别原理	8
2.3 降噪原理	9
2.5 本章小结	12
第 3 章 训练集的构建	14
第 4 章 实验结果	18
4.1 横纵向综合比较结果	19
第 5 章 结论和展望	28
参考文献	30
致谢	32

第 1 章绪论

1.1 课题研究的目的是和意义

随着油气勘探的发展，对地震资料的质量要求逐渐提高，寻找一种精度更高、分辨率更高的地震资料处理技术也是我们必须面对的难题。分布式声学传感（DAS）被认为是地震勘探中新兴的采集技术。DAS 使用散射光信号的相位信息的变化来记录波场。与传统的电子检波器相比，DAS 在采集几何形状方面具有优势，例如低成本和高密度的观测。近年来，DAS 已应用于垂直地震剖面（VSP）数据采集^[1]。

然而，能量较弱的散射光信号极易受到背景噪声的影响，从而对采集的地震数据的质量产生负面影响。此外，井内采集环境也给数据处理带来了新的挑战，一些干扰在常规地震勘测中不存在，如时变光学噪声和耦合噪声。由于地下地质条件、采集条件和环境因素，现场采集的地震数据与各种噪声混合在一起。受混合噪声影响，真实地震记录质量下降，数据信噪比（SNR）和分辨率相对较低，给后续反演、成像和解释带来困难。提高数据信噪比和分辨率，对地下结构研究和油气矿产资源勘探具有重要意义^[2]。

与传统的电子检波器相比，DAS 具有成本低、空间分辨率高、覆盖范围好、抗恶劣环境能力强等一系列明显优势^{[3][4]}。噪声衰减是地震数据处理中必不可少的步骤。然而，DAS 地震数据的去噪任务面临两个主要困难。一方面，DAS 地震资料中的一些背景噪声，如光学低频噪声、水平噪声、衰落噪声等，是常规地震资料所不具备的。最近，与传统方法相比，卷积神经网络（CNN）显示出更优越的去噪性能^[5]。

为了顺应这一趋势，我们提出了一种多尺度交互式卷积神经网络（MSI-Net），并将其应用于具有挑战性的 DAS 地震数据的降噪^[6]。与现有的大多数用于地震数据去噪的 CNN 架构不同，多尺度交互式卷积神经网络通过将固有的串行卷积改进为多尺度并行卷积，同时考虑了粗尺度和细尺度的特征，有利于恢复详细信息^{[7][8]}。此外，利用一些连接实现不同尺度之间的信息交互，促进了信息的流动，使网络能够从 DAS 地震资料中提取出信息量更大的多尺度特征。例如地震数据去噪（Chen et al., 2019; Saad 和 Chen, 2020 年）、到达采摘（Tsai 等人, 2018 年; Yuan et al., 2019; Zhang et al., 2020）、断层识别（Wu et al., 2019）、岩性预测（Zhang et al., 2018）和地质构造分类（Li, 2018）^[9]。深度学习算法可以自动学习高度复杂的非线性特征，并应用于叠前地震数据中背景噪声

的抑制，通过自动学习随机噪声特征，实现自动高效的背景噪声分离。Yu et al. (2019) 提出了一种基于 CNN 的智能去噪方法，该方法不需要对信号和噪声进行精确建模，也不需要参数调谐进行优化。Wang 和 Chen (2019) 使用具有残差学习的深度 CNN 框架进行 2-D 叠后地震随机噪声衰减。Saad 和 Chen (2020) 将地震信号视为时间序列，提出了一种深度去噪自动编码器 (DDAE) 来衰减地震随机噪声。Li et al. (2022) 提出利用深度卷积神经网络 (CNN) 同时实现地震图像超分辨率和去噪。江等人 (2021) 提出了一种改进的卷积自编码器 (CAE) 方法，以实现地震数据的同步重建和去噪。Yang et al. (2021) 提出了一种改进的 ResNet 来实现地震随机噪声衰减。Wang 等人 (2022) 应用于地震噪声衰减任务 (Creswell et al., 2017; Wang et al., 2021)，并在地面记录处理方面取得了一些成功的应用。此外，迁移学习被引入去噪网络的训练中，以增强模型的泛化以处理真实记录 (Li et al., 2022; Sun 等人, 2022 年)。基于监督学习的去噪方法需要标注大量干净的地震数据来拟合网络，这将增加人力和计算成本。因此，提出了一些基于无监督学习或自监督学习的去噪模型，以解决地震信号处理中缺乏配对数据的问题 (Wang et al., 2022; Yang 等人, 2021 年; Liu 等人, 2021 年; 2022 年; Qiu 等人, 2022 年)。同时，基于深度学习的算法在 DAS 记录去噪方面也取得了良好的效果 (Zhao et al., 2022; Wang 等人, 2021 年)。通常，这些去噪网络旨在噪声记录和所需信号之间建立非线性高维映射关系^[10]。在训练过程中，我们可以使用训练数据来加强学习到的映射，训练后得到最终的去噪模型，并在实际应用中被证明是有效的。值得注意的是，与传统方法不同，去噪网络可以被认为是一种“数据驱动”的方法，可以在没有参数的情况下自适应地完成复杂的地震噪声抑制 *ne-tuning*^[11]。如果训练数据是完整的，基于 CNN 的网络总是可以获得比传统方法更有利的结果。然而，大多数传统网络，如 DnCNN (Zhang et al., 2017) 都是基于单尺度信息来提取潜在特征，这在处理复杂地震数据时的有效性和泛化性较低 (Zhong et al., 2022)。此外，大多数现有方法通过网络传输输入，并在最后一层重建输出。虽然这类网络学习到的特征可以随着层数的增加而聚合局部特征，但它也具有粗尺度的特点，即重构后的分辨率不够精细，忽略了一些细节特征。因此，在地震数据处理任务中，特别是当数据受到强噪声干扰时，很难获得准确的预测结果。较强的噪声会导致最终输出表征空间的灵敏度迅速下降，重建精度降低，甚至出现一些假地震事件。

因此，人们越来越关注设计高效的去噪网络，以提高 DAS-VSP 数据的处理能力。针对上述问题，本文构建了一种多尺度交互式深度卷积神经网络（MSI-Net）。网络通过在主网上逐步融合子网来构建多尺度框架，在平行的多尺度子网络上进行重复的信息交互，完成尺度之间的重复信息融合，增强了网络的泛化能力。该网络可以学习更丰富的多尺度特征，并重建高分辨率地震数据。我们构建了一个包含合成信号和实际 DAS 背景噪声的高质量训练数据集来训练网络。此外，仿真算例和实测算例均表明，所提出的多尺度交互式卷积神经网络可以有效衰减多种独特的 DAS 背景噪声，并完全恢复微弱信号。与传统的 CNN 架构相比，多尺度交互式卷积神经网络在全局信噪比和局部细节方面表现出更好的性能。

1.2 国内外研究现状

在地震信息处理时，降噪从而还原有效的原始信号一直是一个重点方向。噪声会干扰有效地震信息，导致信噪比过低，同时使地震数据有效频带变窄，降低数据分辨率。在考虑分辨率的同时降低地震数据中的噪声是一个具有挑战性的问题。在传统的降噪方法中，带通滤波、维纳滤波（Mendel, 1977）和 F-X 反卷积（Canales, 1984）较早用于地震噪声抑制^[12]。为了提高地震数据的去噪能力，还开发了几种时频衰减算法，包括短时傅里叶变换（Lu and Li, 2013）和时频峰值滤波（TFPF）（Wu et al., 2011）。一般来说，这些方法的去噪原理是基于反射信号与背景噪声在物理特性或频率分量方面的差异，以消除复杂的干扰。但是，上述方法无法处理复杂的 DAS 背景噪声。此外，多尺度去噪方法利用稀疏分解结果的特征来构建合适的滤波器，以抑制噪声以保留有效信号，典型的方法包括小波变换滤波（Mousavi et al., 2016; Anvari 等人, 2017），Curvelet 变换过滤（Neelamani 等人, 2008; Gorszczyk 等人, 2014），Shearlet 变换滤波（Gan 等人, 2015; Chen 和 Fomel 2018）、经验模态分解（EMD）（Bekara 和 van der Baan, 2009 年; Amezcua Sanchez 等人, 2017）和变分模态分解（VMD）（Kesharwani 等人, 2021 年）。不幸的是，在处理包含复杂噪声的 DAS 记录时，研究人员很难获得最佳滤波参数，这会导致噪声残差和有效信号幅度的损失。此外，许多其他方法已广泛用于地震数据处理，包括奇异值分解（SVD）（Oropeza 和 Sacchi, 2011），字典学习方法（Chen 等人, 2016; Yarman 等人, 2018 年; Wang 和马, 2020），稳健主成分分析（RPCA）（Cheng 等人, 2015; Liu et al., 2021），但这些方法在 DAS 数据去噪中的应用很少见报道。当

DAS 数据受到噪声严重干扰时，传统方法很难提供较好的处理效果，同时考虑信噪比和分辨率。同时，对于上述常规方法，它涉及到在数据处理中手动选择各种参数，这大大增加了处理工作的运行时间，并且严重依赖人工经验。为了高精度地震勘探，迫切需要更智能、更快速的数据处理技术。

在当今飞速发展的人工智能技术浪潮中，深度学习备受瞩目，其在各个领域都有着非常成功的实用案例。该技术模拟了人脑的工作原理，利用神经网络结构模拟人脑的神经从而进行学习。许多研究人员提出了一种基于深度神经网络的地震数据去噪方法，成功地消除了各种地震噪声，并保留了有效信号。

通常，去噪网络旨在噪声记录和所需信号之间建立非线性高维映射关系。在训练过程中，我们可以使用训练数据来加强学习到的映射，训练后得到最终的去噪模型，并在实际应用中被证明是有效的。值得注意的是，与传统方法不同，去噪网络可以被认为是一种“数据驱动”的方法，可以在没有参数的情况下自适应地完成复杂的地震噪声抑制 *ne-tuning*。如果训练数据是完整的，基于 CNN 的网络总是可以获得比传统方法更有利的结果。然而，大多数传统网络，如 DnCNN (Zhang et al., 2017) 都是基于单尺度信息来提取潜在特征，这在处理复杂地震数据时的有效性和泛化性较低 (Zhong et al., 2022)。此外，大多数现有方法通过网络传输输入，并在最后一层重建输出。虽然这类网络学习到的特征可以随着层数的增加而聚合局部特征，但它也具有粗尺度的特点，即重构后的分辨率不够精细，忽略了一些细节特征。因此，在地震数据处理任务中，特别是当数据受到强噪声干扰时，很难获得准确的预测结果。较强的噪声会导致最终输出表征空间的灵敏度迅速下降，重建精度降低，甚至出现一些假地震事件^[13]。

本文构建了一种多尺度交互式深度卷积神经网络 (MSI-Net)。该网络可以学习更丰富的多尺度特征，并重建高分辨率地震数据。实验结果表明，该网络不仅能有效抑制噪声，而且能准确预测有效信号，能够实现高信噪比和高分辨率的处理要求，大大减少假地震事件。我们构建了一个包含合成信号和实际 DAS 背景噪声的高质量训练数据集来训练网络。我们还处理合成和现场 DAS 数据，以检查拟议网络的有效性。与传统的去噪方法和最近提出的去噪网络相比，本文提出的方法在 DAS 背景噪声衰减和微弱信号幅度保持方面具有优势。

1.3 主要研究内容

本文的主要研究内容是基于多尺度网络的 DAS-VSP 噪声抑制流程设计，采用了目前去噪效果明显优于传统去噪模型的卷积神经网络模型 MSI-Net。通过构建一个通用的不具备特殊性的 DAS-VSP 数据集来对模型的 DAS-VSP 数据降噪效果进行验证并得出相应结论。

总的来说，本文通过与多种传统降噪方法以及另外两种卷积神经网络降噪方法（DnCNN、U-Net）进行综合对比，定量分析得出 DnCNN、UNet 和 MSI-Net 三种深度学习方法结果的信噪比远高于传统方法，具有更好的去噪效果，噪声抑制更加均匀彻底，去除的噪声结果中没有明显的信号泄漏，同时在深度学习方法中，本文使用的 MSI-Net 结果的信噪比最高，高于 DnCNN 和 U-Net。

1.4 本文的组织结构

第 1 章：绪论。该章节概述了地震勘探中 DAS 技术的重要性及传统方法在处理 DAS 背景噪声时的挑战，介绍了基于深度学习的地震数据去噪方法的发展现状，并提出了一种多尺度交互式卷积神经网络（MSI-Net）用于处理 DAS 地震数据的降噪。该网络有效提高了地震数据的信噪比和分辨率，论文主要研究内容为 MSI-Net 模型在 DAS-VSP 数据降噪方面的优越性。

第 2 章：相关原理及理论研究。该章节介绍了 DAS-VSP 中常见的各种噪声类型及其特征，解释了卷积神经网络的识别原理，以及基于深度学习的降噪原理和实现过程。

第 3 章：训练集的构建。该部分介绍了深度学习模型训练集的构建过程，包括合成有效信号和多样噪声，并调整超参数以提高性能。

第 4 章：实验结果和比较。本章综合比较了原始噪声、带通滤波、小波变换滤波、WNNM、DnCNN、UNet 和本文所使用的 MSI-Net，定量分析的结果表明 MSI-Net 的降噪效果综合最优。

第 5 章：结论。总结论文主要研究内容。

1.5 本章小结

本章主要介绍了基于多尺度卷积神经网络的 DAS-VSP 噪声抑制的意义背景和国内外研究现状，并且横向分析对比了几种传统去噪方法和基于 MSI-Net 的去噪方法对 DAS-VSP 噪声的抑制效果，并得到基于 MSI-Net 的去噪方法综合来讲更优的结论。最后，本章简单介绍了一下主要研究内容以及本文的组织结构，为后续的诸章节描绘出了框架。

第 2 章 相关原理及理论研究

2.1 DAS-VSP 中的波场和噪声分析

随机噪声是 DAS-VSP 数据中常见的背景噪声，频带宽，能量强，主要由数据采集过程中的振动引起。噪声源可能来自环境因素如地震活动、海浪和风声，设备运作产生的噪声如传感器和电缆，人为干扰例如周围环境的活动或施工，电磁干扰由附近设备或电路的电磁辐射引起。

低主频、极强能量的异常干扰可能是井下温度异常引起的。异常干扰在记录中往往具有大面积和高振幅。在存在异常干扰的情况下，有效信号被完全覆盖，严重影响 DAS-VSP 数据质量^[14]。

衰落噪声是由随机间隔的反向散射光的相位抵消干涉引起的。衰落噪声主要表现在周期长、振幅大。一般来说，衰落噪声出现在唱片的最上侧，对第一到达波以下的有效信号影响较小。它很容易与水平噪声混合以产生新型噪声。

水平噪声是由光学测量过程中的振动引起的。水平噪声通常表现为一个短的水平带，在所有迹线上具有基本相同的相位，并且幅度会随着时间的推移而减小。

棋盘噪声通常由水平噪声和衰落噪声混合产生。棋盘噪声具有与水平噪声大致相同的特性。例如，棋盘噪声和水平噪声都具有水平运动，并且振幅会随着时间的推移逐渐衰减。然而，棋盘噪声往往在不同的迹线上具有不同的相位。一般来说，棋盘格噪音在第一次到达之前也比较分散。

耦合噪声主要是由于光纤与测量线耦合不良引起的。它通常伴随着反射信号，并且与局部视图中的信号高度相似。传统方法通常更难区分信号噪声和耦合噪声。目前，在井中部署 DAS 系统有三种方式。第一种是将光纤永久固定在外壳外。它最大限度地提高了光纤和地层之间的耦合，从而减少了采集的 DAS 数据中的耦合噪声（Jiang 等人，2016）。第二种是将光纤固定在管道上，仍然会有少量的耦合噪声。第三种是用砝码将纤维悬浮在套管中。然而，光纤与钻孔没有紧密接触，这可能会产生强烈的耦合噪声（Constantinou 等人，2016）。

2.2 卷积神经网络识别原理

卷积神经网络（CNN）是目前被广泛应用于各种数据处理和分析任务的深度学习模型之一。它在自然语言处理、语音识别和图像识别等领域有着诸多成功案例。

图 2-1 展示了卷积神经网络的架构，包括多个池化层、卷积层、归一化层、激活函数层和全连接层，构成了一个深度神经网络。CNN 的独特之处在于利用卷积层来提取输入数据的特征，以实现分类、识别等任务。卷积层是一种特殊的神经网络层，通过卷积核对输入数据进行操作，从而提取数据的特征。

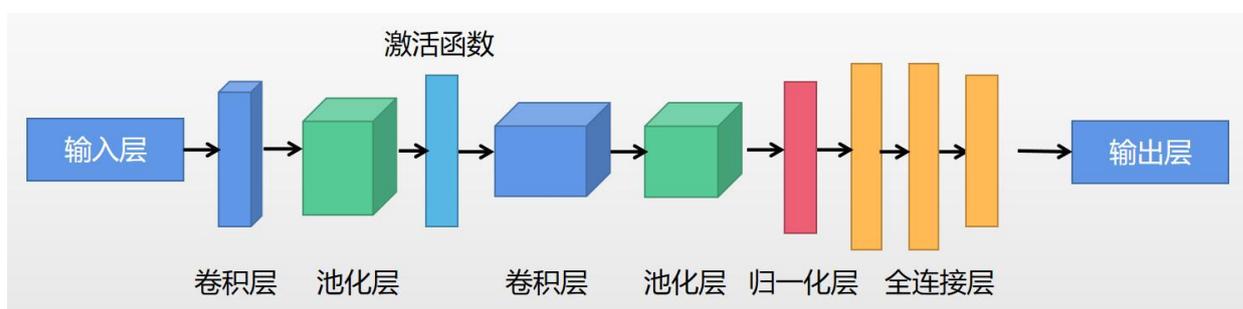


图 2-1. 卷积神经网络的结构

在卷积神经网络中，卷积层和池化层扮演着至关重要的角色。卷积层利用多个卷积核来提取输入数据的各种特征，这些特征在不同尺度上捕获着数据的不同细节。而在池化层中，通过最大池化或平均池化等下采样操作，可以有效地减少特征图的尺寸，从而降低了模型的复杂度和参数数量，防止了过拟合的发生。这种处理方式也有助于增强模型的稳定性，使其能够更好地泛化到未见过的数据上。

[15]

池化操作的重要性不言而喻。最大池化通过提取每个小区域的最大值，精确地保留了图像的主要特征，同时消除了冗余信息。这种操作对抗噪声的能力也是其独特之处，因为即使在存在噪声的情况下，最大池化仍能够准确地捕捉到关键信息。

与之不同的是平均池化，它通过提取每个小区域的平均值来减少特征图的尺寸。这种方式有助于平滑特征图的数据分布，减少图像中的高频噪声，从而有效地保持了局部统计特征。通过这样的操作，模型的稳定性和泛化能力都得到了提高，使得其在面对各种数据时能够更为可靠。激活函数对卷积和池化操作的结果

进行非线性变换，有助于网络学习复杂的模式和特征。最常用的三个分别是 Tanh、Sigmoid 和 ReLU。

在训练过程中，卷积神经网络通过反向传播算法进行模型优化。该算法根据模型预测结果与真实标签的差距计算每个神经元的梯度，然后利用梯度大小来更新权重参数，逐步调整模型以逼近最优解。

归一化层的作用在于对神经元的输出进行标准化，这一步骤有助于加速训练过程，提高模型的泛化能力，并确保各层输出的稳定性和一致性。

全连接层则承担着将卷积操作提取的特征向量输入到神经网络中进行分类的任务，特别适用于地震数据的信号和噪声分类与识别。此外，全连接层通常也采用激活函数进行非线性变换，以提高模型的分类准确度。

在实际应用中，根据噪声种类的不同，需要采用相应的模型来进行识别，在本文中，由于训练集是自主构建，所以只需采用相对合适的模型参数即可。

2.3 降噪原理

本文将受噪声干扰的 DAS-VSP 记录表示为：

$$y = x + n$$

(2.1)

其中， y 包含有效信号和噪声，代表着原始数据， n 是噪声信号， x 表示有效信号，即尽量通过 x 和 n 还原 y 。

在等式 3 中， H 代表多尺度互动重构网络， $\theta = \{W, b\}$ 是具有权重的网络优化参数 W 和偏见 b 。

在训练过程中，我们可以计算出网络输出之间的误差 x^{\sim} 和纯粹的记录 x ，并通过梯度反向传播更新网络参数。经过多次迭代后，误差会收敛到一个足够小的值，可以确定网络参数。在推理过程中，给定地震数据，网络可以预测去噪后的 DAS 数据。在本文中，L2 使用损失函数作为代价函数来指导模型的训练过程，公式 2.2 如下：

$$L = 12N \sum N_i = \frac{1}{H(y_i; \theta)} - \frac{x_i}{2F(4)}$$

(2.2)

在这里 $H(y_i; \theta)$ 表示训练样本的去噪结果 y_i 和 x_i 表示我们称之为标签的纯信号，即我们期望从网络获得的输出。 i 是样本的索引，并且 N 是批大小。梯度下降法用于最小化损失函数。为提高地震信号的重构能力，该网络逐层逆向调整权重参数，并进行频繁的迭代训练。具体来说，我们使用 Adam 优化器来优化网络。更多网络训练参数见表 3。训练结束后，我们使用训练好的网络来处理嘈杂的 DAS 记录。在这种神经网络中，主要通过残差学习来对信号进行预处理。残差学习 (Residual learning, RL) 通过将网络前面层的输出与输入相连接的方式，实现了对信号残差的学习，从而使神经网络更有效地捕捉信号特征信息，并在一定程度上消除噪声信号的干扰。这一方法的优势在于能够训练出更加精确和鲁棒的神经网络，相对于传统的滤波器和降噪算法，具有更高的准确性和更快的处理速度。

残差学习的核心思想是将网络的输出转化为残差图像，即对噪声的 n 阶估计。按照这种方法，可以训练出具有更高精度和鲁棒性的神经网络^[16]。与传统的滤波器和降噪算法相比，残差学习方法在准确性和处理速度上都有显著提升。

根据残差学习理论，深度网络的训练误差往往高于浅层网络，但通过在浅层网络中引入多层身份映射，可以将浅层网络转化为深度网络，并保持与浅层网络相同的训练误差。换言之，身份映射层更易于训练。因此，利用残差学习思想，将网络输出转换为残差图像，即估计噪声的 n 阶，通过训练残差映射并结合批量归一化，可以加速训练并提高去噪性能。如下(公式 2.2)：

$$\hat{x} = y - \hat{n} = y - \text{Net}(y; \theta) \quad (2.3)$$

式中参数和上面一样， $\hat{x}\hat{n}$ 分别代表有效信号和噪声， $\theta = \{\omega, b\}$ 代表网络的参数，整个式子代表着用实际信号通过网络降噪后还原原始信号（有效信号）。

2.4 网络层参数

为了更详细地展示相关参数和网络架构，本文描述了网络的细节并且简要介绍了这些网络层参数的作用。这些参数包括但不限于步长、零填充、卷积滤波器

的数量、层数、不同类型的块数、池化大小和步长等，这些参数的合理设置对于网络的性能和功能至关重要。

在研究中，表格 2-1 作为关键信息呈现的载体，提供了更为详尽的网络架构细节，从而深入了解网络的设计和参数设置。通过表格中的数据可以清晰地了解每个网络层的具体功能和影响，以及不同参数设置对网络整体性能的影响。这种结构化的呈现方式有助于全面把握研究的技术细节，为进一步的研究和实践提供了重要参考。

表 2-1. 每个网络层的参数

参数 层		输入卷积 滤波器的 个数	输出卷积 滤波器的 个数
卷积层	输入层	1	64
	输出层	64	1
	隐藏层	64	64
通道注意力	平均池化	64	64
	最大池化	64	64
	卷积层	64	64
空间注意力	卷积层	2	1
扩张卷积		64	64

卷积神经网络中的步长（Stride）是卷积操作中一个重要的参数，它决定了卷积核在输入矩阵上移动的步幅大小。当步幅为 1 时，卷积核每次移动一个像素；而当步幅大于 1 时，卷积核每次移动的像素数增加，导致输出矩阵的宽度和高度减小。通过调整步长，我们可以控制输出矩阵的形状和大小。

为了保持卷积后输出的大小与输入矩阵相同，可以在输入矩阵的周围添加零像素，这一操作被称为零填充（Zero Padding）或边界填充（Border Padding）。零填充可以有效地保持特征图的尺寸，并有助于减少信息在边界处的丢失。

输入卷积滤波器的数量（Input Convolution Filters, ICF）取决于输入矩阵的通道数，它决定了第一层卷积层的卷积滤波器的数量。每个卷积滤波器用于提取输入矩阵中的一个特征，卷积核的数量不同会导致提取的特征丰富度有所差异。

隐藏层（Hidden Layer, HL）是神经网络中除了输入和输出层之外的所有层。这些隐藏层包含训练参数（权重和偏置），用于处理数据的非线性特征。隐藏层的设计对于神经网络的性能和效果起着至关重要的作用。

输出卷积滤波器的数量（Output Convolution Filters, OCF）取决于卷积核的数量和大小。每个卷积核会生成一个输出特征映射，而输出卷积滤波器的数量则决定了最终的特征提取能力和网络的表达能力。

在卷积神经网络中，池化层有两种常见类型：平均池化（Average Pooling, AV）和最大池化（Max Pooling, MP）。平均池化通过计算图像中不重叠小块的平均值来减少过拟合问题，同时保持特征图尺寸。最大池化则通过选取每个小块中的最大值来减少图像尺寸，并保留主要特征。这些池化操作在卷积神经网络中起着重要的作用，有助于提高网络的鲁棒性和泛化能力。总之，步长、零填充、输入和输出卷积滤波器的数量、池化类型和作用、隐藏层等参数都是影响神经网络性能的关键因素。这些参数的选择需要根据具体任务和数据集进行调整和优化。

本文采用了亚当算法（Adaptive Moment Estimation, Adam）作为优化算法，初始学习率设置为 $1e-4$ 。亚当算法是一种自适应学习率的优化算法，被广泛应用于深度学习中^[17]。

在训练过程中，网络的输入是构建好的包含了有效信号和噪声的数据集，在测试过程中不断调整参数，并将信号数据作为标签。通常情况下，首先随机选择噪声补丁和信号补丁，并对数据进行规范化。随后，将不同信噪比的噪声训练数据输入网络，通过建立非线性映射来获取估计信号。

2.5 本章小结

本章首先介绍了 DAS-VSP 数据中常见的各种噪声类型并对他们的特征和产生原因进行了分析。随后介绍了使用卷积神经网络（CNN）进行识别的原理。最后，从理论上介绍了基于 MSI-Net 对 DAS-VSP 数据噪声进行去噪的详细流程和具

体原理。然后再介绍了在之后的训练过程中需要调整的一些超参数以及其意义，并以表格的形式呈现了出来。本章内容涵盖了从噪声分析到识别、去噪过程的原理和详细流程，给予了整个流程设计一个完整的知识架构。

第3章 训练集的构建

3.1 构建训练集

深度学习的目的是学习特征，可以通过网络自适应地获取分层特征信息，解决了过去手动设计算子进行特征提取的问题。数据集是深度学习算法的重要基础，其完备性决定了该方法可以触及的潜在上限。在地震勘探中，很难获得纯地震信号。为了获得更完整、更真实的训练集，使用正向建模来构建纯信号集，对于 DAS-VSP，为了获得地下信息，我们通常放置人工源来激发地震波场，并沿纵向放置接收器来记录地震波。因此，我们使用雷克子波（Ricker Wavelet, RW）来进行震源的仿真，表达式如下(公式 3.1)：

$$f(t) = A[1 - 2\pi f_0(t - t_0)^2] \quad (3.1)$$

图 3-1 是模拟的模型之一，从下往上上是地层，红色三角是光源，黑线是 DAS 探测器。横、纵坐标分别是剖面长度和测井深度。垂直黑线代表光纤传感器形成的测量线。时间采样间隔为 400 μ 秒，空间采样间隔为 1m。通过求解弹性波方程，我们可以得到合成的干净 DAS -VSP 数据。由于耦合噪声的产生机理尚不明确，在仿真实验中，不考虑在仿真 DAS 记录中增加耦合噪声。重新制作的模拟纯信号和收集在一起的噪声形成合成噪声记录，并用作测试。我们综合了 10 个噪声承载记录作为测试集。在测试数据集上评估了所提方法对信号重构任务的影响。用于测试的数据和用于训练的数据是相互独立的。所提出的方法用于处理合成和现场噪声记录。同时，一些竞争性方法也被用于处理记录，包括传统的方法——带通滤波、小波变换滤波、加权核范数最小化（WNNM）和深度学习通用模型——DnCNN 和 U-Net。为方便描述，本文提出的方法称为 MSI-Net。

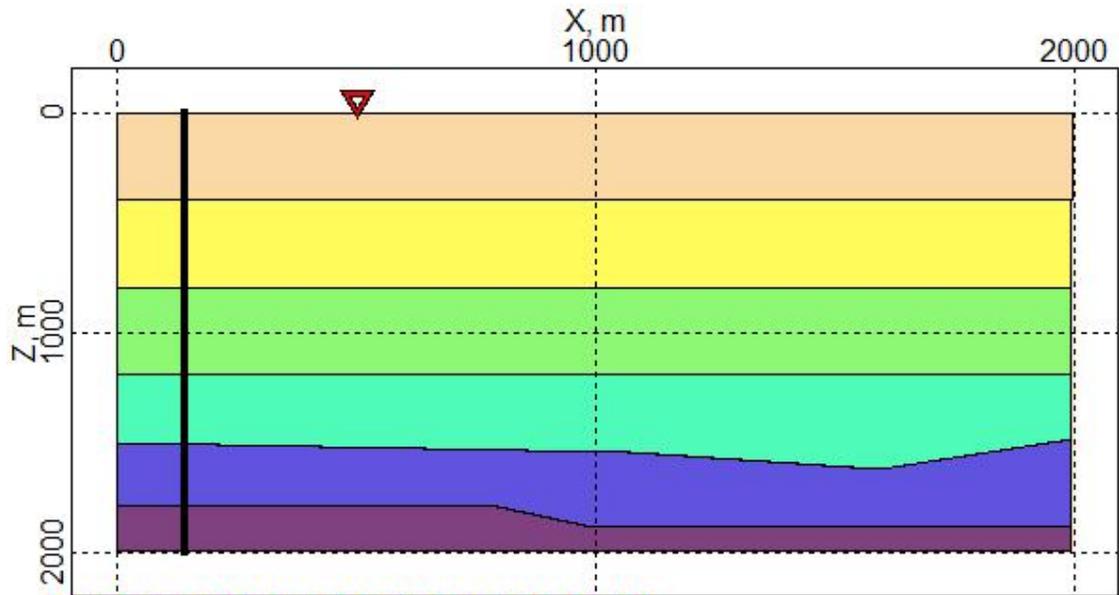


图 3-1. 正演模型

在正演模拟中，对于 DAS-VSP，为了获得地下信息，我们通常放置人工源来激发地震波场，并沿纵向放置接收器来记录地震波。本文基于时域声波方程对合成数据进行建模，如下式所示。(式 3.2)：

$$\frac{\partial^2 u(x, y, t)}{\partial t^2} = v(x, y^2) \left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right) + s(x, y, t) \quad (3.2)$$

v 表示波速和 u 表示声波场。 $s(x, y, t)$ 表示源的功能。 (x, y) 表示空间位置和 t 表示时间。

正演建模相关参数如下(表 3-1)：

表 3-1. 正演建模模型的参数

参数	规格
子波类型	雷克子波
主频率	50-70Hz
跟踪间隔	1 米
采样时间间隔	4×10^{-4} 秒
地层深度	500-2000m
波速	800-3000m/s

我们利用上述模拟方法对有效信号进行综合，共生成了 1120 个大小为 128×128 的信号。训练时将合成信号分成小块，共获得 184800 个大小为 50×50 的数据作为训练集。

根据噪声的形状和特征，我们可以将噪声分为：水平噪声 (a)、棋盘噪声 (b)、随机噪声 (c)、衰落噪声 (d)、光学系统噪声 (e)。

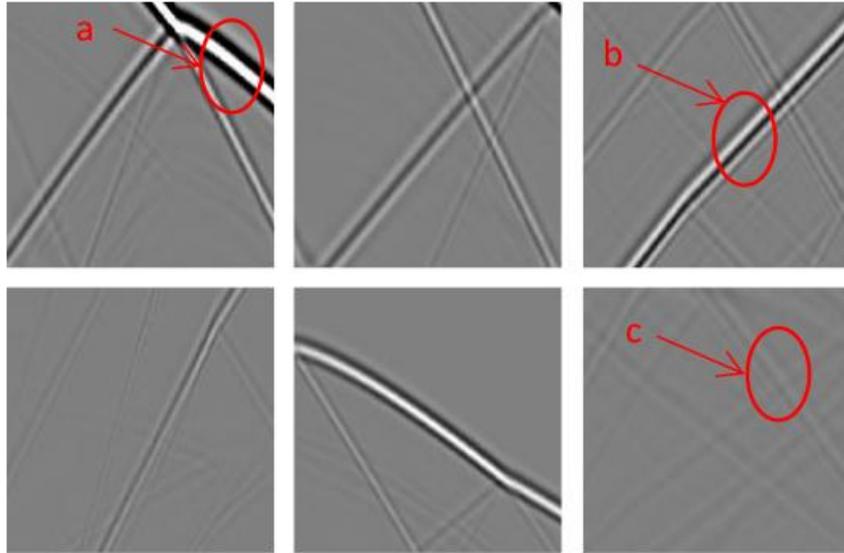


图 3-2. 有效信号训练集

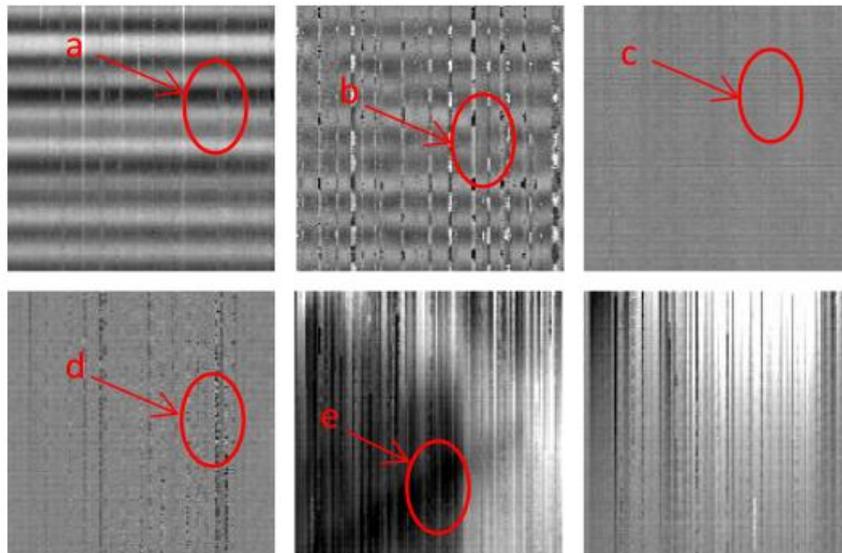


图 3-3. 噪声训练集

在去噪过程中，局部结构的分辨率越高，越有利于噪声的降低，但高分辨率带来的丰富信息也会在处理中产生误判，导致一些假地震事件。因此，掌握数据

的整体结构也很重要，这就要求我们使用不同分辨率的数据。分辨率较低的数据分量更有利于整体信号的恢复。通过分析和处理不同分辨率的信号来提高整体任务的性能具有重要意义。如何设计具有多分辨率表示的网络是我们需要考虑的关键问题。为使网络实现多尺度特征提取，该模型在具有高分辨率特征图的主网络中，逐步并行添加具有低分辨率特征图的子网络，以完成尺度之间的特征融合。拟议网络的设计思想参考了 HRNet。水平传递过程表示随着处理层的增加而变化，垂直过程表示特征图的比例变化。第一级（我们称之为第 1 阶段）显示主网络，其特征图保持在高分辨率标准。信号在 stage1 中通过主网传输，后续阶段并行加入更多低分辨率子网。并行子网在后期的解析由之前的所有解析和新的解析组成，即在 n-th 阶段，特征处理在 n 并行分辨率。每增加一个较低分辨率的子网，分辨率就会降低到一半，对应的信道就会增加一倍。

综上所述，选择合适的超参数可以有效改善神经网络的性能和泛化能力。超参数需要根据具体任务和数据集进行调整，这需要通过不断试验和迭代来优化，以达到最佳效果。该实验中，我们比较了不同层数的训练时间和训练效果（平均信噪比的改进），如表 3-2 所示。由下表可知，采用 20 层的网络可以更全面地学习输入数据的特征，从而提高准确性，同时也能够充分利用时间进行训练，得到更好的性能表现。

表 3-2. 不同层次神经网络去噪效果和训练时间的比较

层数	改进（分贝）	训练时间（H）
14	15.08	7.2
16	17.87	9.1
18	20.64	11.7
20	21.71	13.1
22	21.92	16.8

3.2 本章小结

本章首先介绍了深度学习的目的和一个合适的数据集的重要性，然后说明了如何利用正向建模来构建数据集。接着详细介绍了正演模型的建立和参数设置。

随后分析了不同类型的噪声以及去噪过程中考虑到的分辨率问题。最后，说明了为什么要使用多尺度网络来提高降噪性能，并声明超参数的选择对网络性能和泛化能力的影响，并用表 3-2 加以作证。

第 4 章 实验结果

4.1 横纵向综合比较结果

为了评估神经网络对去噪任务的适应能力，我们构建了一个模拟噪声信号作为网络输入的实验设置，以有效信号与各类噪声相结合。首先，我们展示了通过模拟地震波刺激所得的地震记录中捕获的有效信号，与用于训练的数据集中的信号存在显著差异，突显了深度学习中训练集和测试集之间的异质性。

我们提取了实际记录中的噪声信号，这些信号不包含有效信息，与训练集中的噪声信号也呈现出差异性。这些噪声信号呈现多样性特征，例如水平噪声、衰减噪声以及分布在整个信号中的随机噪声，凸显了噪声的复杂性。该信号波形尺度为 3，即其取值范围介于-3 到 3 之间。在这些信号中，大部分有效信息被各类噪声所掩盖，这些噪声包括水平噪声、衰减噪声以及随机噪声，为网络的去噪任务增加了挑战。这些实验结果再次强调了在深度学习中训练集和测试集之间的差异对于网络泛化性能的关键作用。

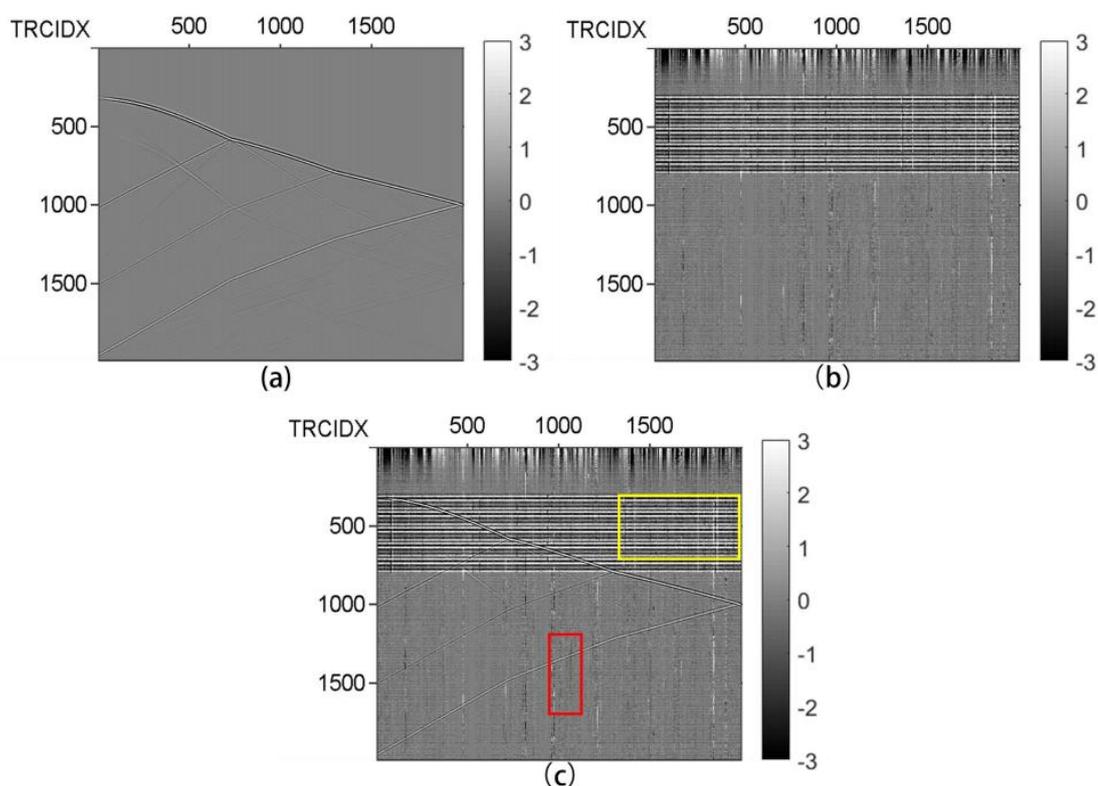


图 4-1. 模拟试验信号

本文以该模拟试验信号为例，显示了不同方法的信号重建结果和图 6 中去除的噪声。合成噪声记录的信噪比 (SNR) 为 -0.5132 dB。我们可以观察到，MSI-Net 可以同时抑制许多常见噪声，并且去噪过程更高效、更快速。结果如图 6K, L 所示，其中图 6K 是去噪结果，图 6L 是噪声输入与预测纯信号之间的差值，也可以认为是该方法预测的噪声。从定量分析来看，总体来看，三种深度学习方法结果的信噪比远高于传统方法，三种深度学习方法的对比结果更侧重于信号结构的高分辨率重建。对 MSI-Net，采用了多尺度分析的思想，对噪声的抑制效果优于 DnCNN（仅在单一尺度上）。同时，我们可以看到 MSI-Net 在去噪恢复方面具有最高的分辨率，对微弱信号的恢复效果优于 DnCNN 和 U-net，这表明 MSI-Net 更适合地震勘探的高分辨率要求。如图 7 所示，我们还分析了频域中各种方法的信号和差异，主要期望观察各种方法是否通过频谱泄漏的信号。从频域可以看出，传统方法不能很好地恢复信号。同时，它们的差异也存在不同程度的信号泄漏。相比之下，三种深度学习方法的结果更接近原始记录。并且很难看出三种方法之间信号的泄漏。这三种深度学习方法在频域上没有显著差异。三种深度学习的比较更多地依赖于定量分析。

在深度学习方法中，MSI-Net (19.0062 dB) 结果的信噪比最高，高于 DnCNN (18.3209 dB) 和 U-Net (18.4935 dB)。从信号恢复的角度来看，可以恢复波场中的各种信号，并观察到原本被噪声污染的直射波、反射的上行波和入射的下行波，这将有利于后续的反演和成像。从噪声抑制的角度来看，所有噪声都被抑制了。相比之下，传统方法对 DAS-VSP 记录的去噪效果不能满足地震勘探的要求。对处理结果的分析表明，带通滤波只能衰减图 6A 中定义的频带内的噪声，这不仅不能抑制噪声，而且会损坏信号。小波变换滤波只能去除一部分随机噪声，大部分噪声仍保留在图 6C 的去噪记录中。WNNM 的滤波效果较差，只能机械去除部分噪声，图 6E 的记录中仍有大量的噪声残留，在图 6F 中去除的噪声结果中也可以观察到明显的信号泄漏，这是重建所不能接受的。与传统三种方法相比，DnCNN、U-Net 和 MSI-Net 具有更好的去噪效果，噪声抑制更加均匀彻底，去除的噪声结果中没有明显的信号泄漏。

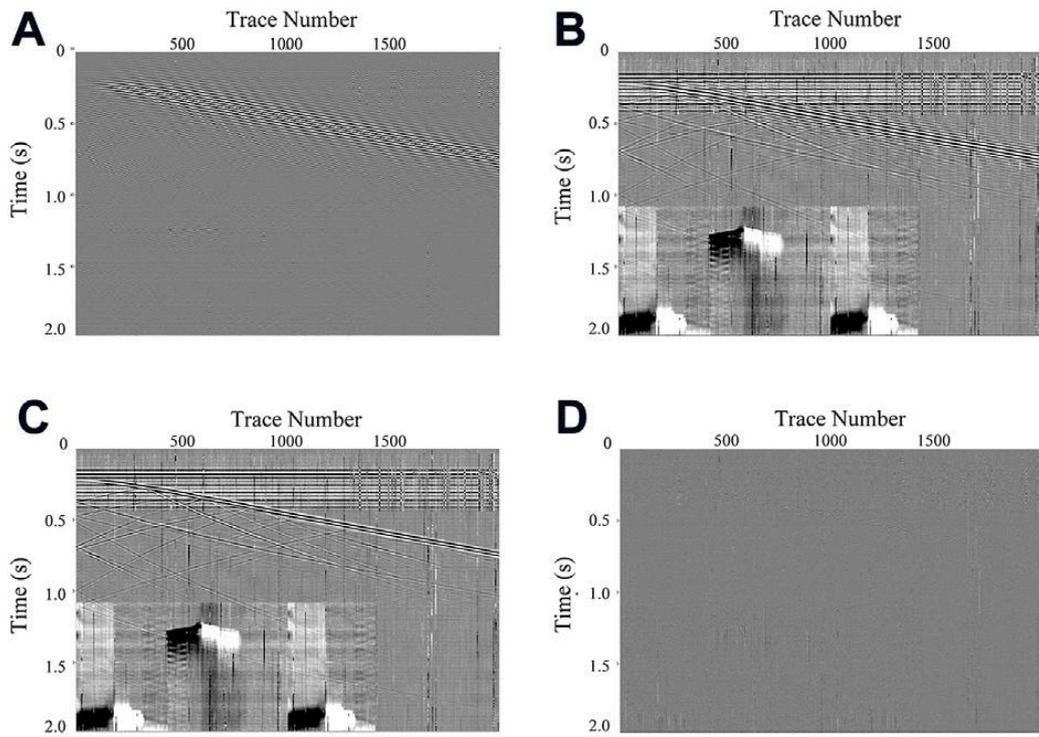


图 4-2. 不同方法的去噪结果比较。(A-B) 信噪比为 1.9371 dB 的去噪结果和带通滤波的预测噪声。(C-D) 信噪比为 1.0421 dB 的去噪结果和小波变换滤波的预测噪声。

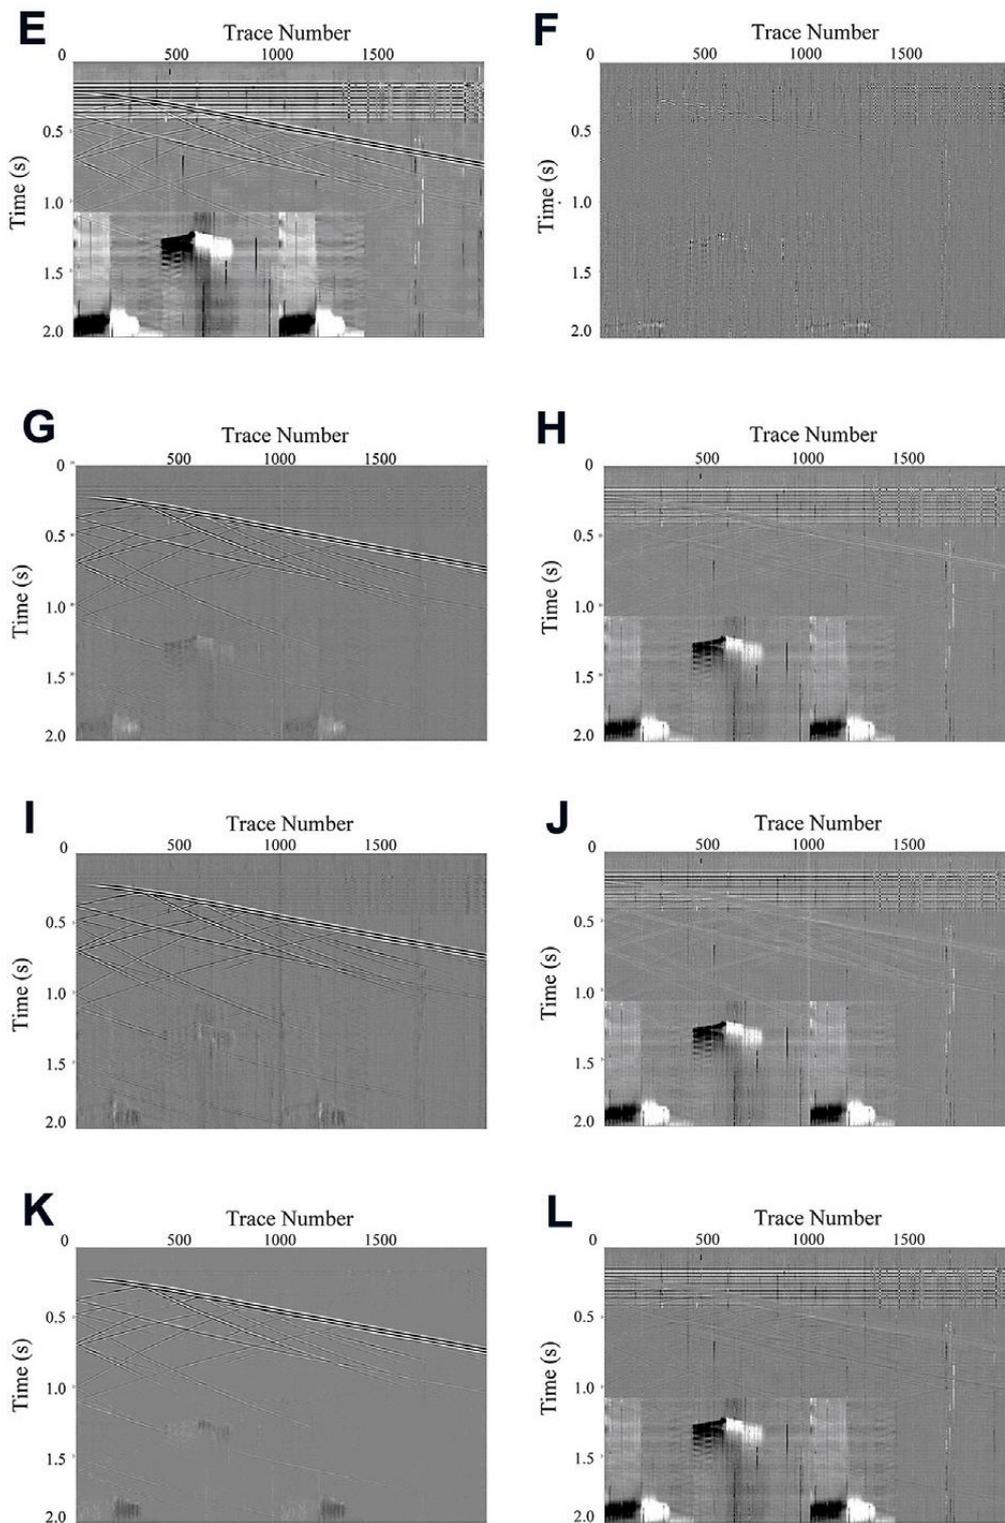


图 4-3. 不同方法的去噪结果比较。(D-G) 信噪比为 0.5712 dB, 预测噪声为 WNNM 时的去噪结果。(G-H) 信噪比为 18.3209 dB, 预测噪声为 DnCNN 的去噪结果。(I-J) 信噪比为 18.4935 dB, 预测噪声为 U-Net 的去噪结果 (K-L) 信噪比为 19.0062 dB, 预测噪声为 MSI-Net 的去噪结果。

三种深度学习方法的对比结果更侧重于信号结构的高分辨率重建。对 MSI-Net，采用了多尺度分析的思想，对噪声的抑制效果优于 DnCNN（仅在单一尺度上）。同时，我们可以看到 MSI-Net 在去噪恢复方面具有最高的分辨率，对微弱信号的恢复效果优于 DnCNN 和 U-net，这表明 MSI-Net 更适合地震勘探的高分辨率要求。如图 7 所示，我们还分析了频域中各种方法的信号和差异，主要期望观察各种方法是否通过频谱泄漏的信号。从频域可以看出，传统方法不能很好地恢复信号。同时，它们的差异也存在不同程度的信号泄漏。相比之下，三种深度学习方法的结果更接近原始记录。并且很难看出三种方法之间信号的泄漏。这三种深度学习方法在频域上没有显著差异。三种深度学习的比较更多地依赖于定量分析。

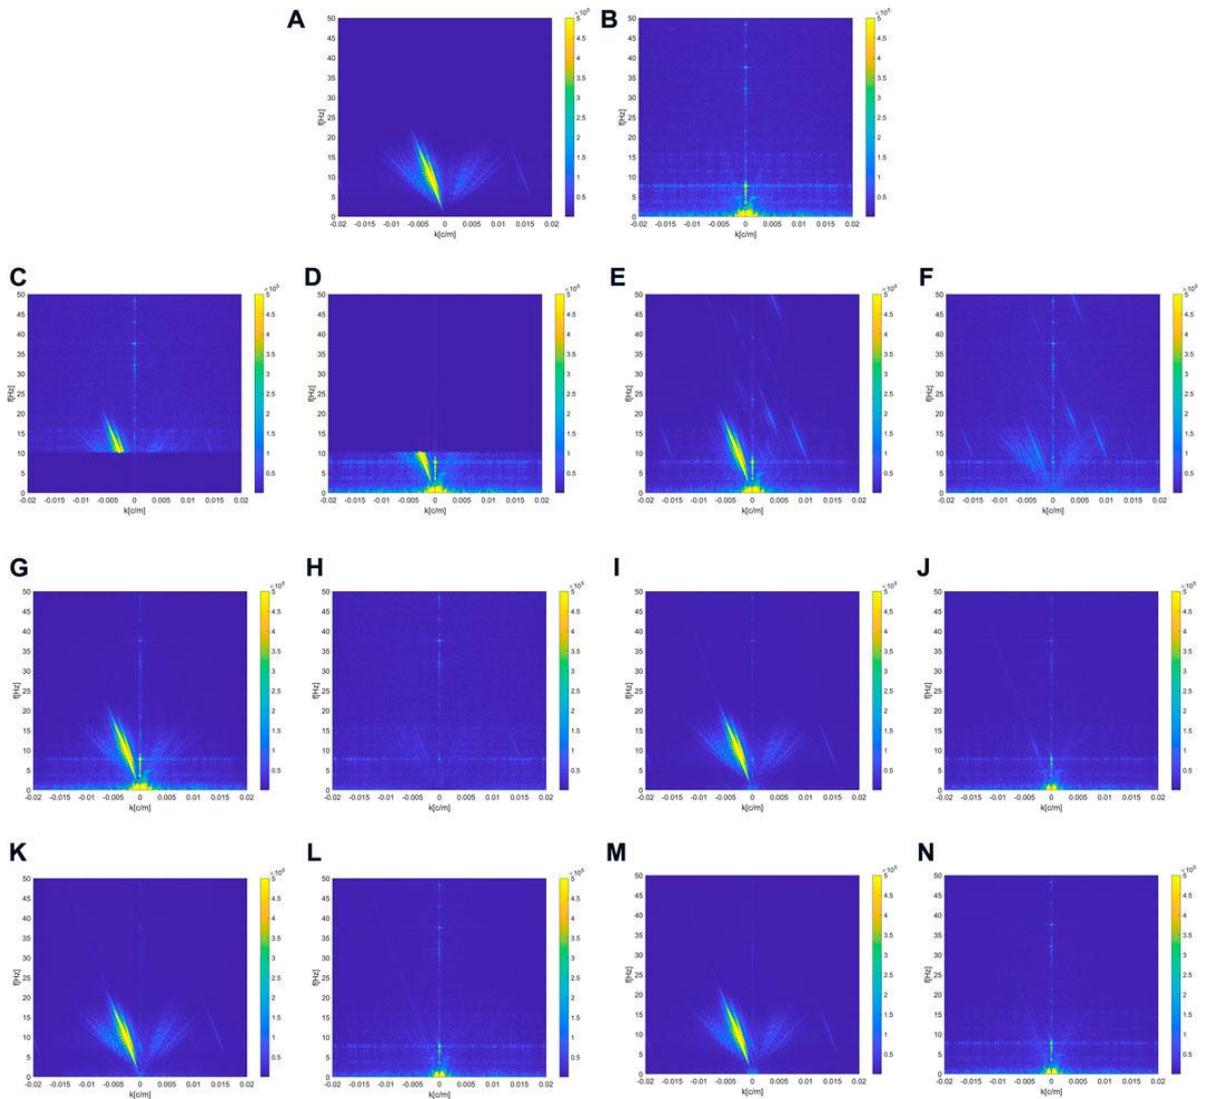


图 4-4. F-K 域分析不同方法的去噪结果。(A, B) 纯记录和噪声数据的 F-K 频谱。(C, D) 去噪结果的 F-K 频谱和带通滤波的预测噪声。(E, F) 小波变换滤波的去噪结果和预测噪声的 F-K 谱。(G, H) WNNM 的去噪结果和预测噪声的 F-K 谱。(I, J) DnCNN (K, L) 去噪结果和预测噪声的 F-K 频谱 去噪结果和预测噪声的 U-Net 的 F-K 频谱 (M, N) MSI-Net 去噪结果和预测噪声的 F-K 频谱。

信噪比 (SNR) 是衡量地震资料质量的重要指标之一, 信噪比的提高是评价去噪方法性能的重要指标。根据计算的大小, 信噪比可分为全局信噪比和局部信噪比。全局信噪比通常用于衡量地震数据的整体质量。此外, 平均绝对误差 (MAE)、均方误差 (MSE) 和结构相似性 (SSIM) (Wang et al., 2004) 是常用的衡量标准。本文采用 SNR、MAE、MSE 和 SSIM 对几种方法进行了定量评估。

在地震学和信号处理领域, 信噪比 (SNR) 被广泛认可为反映数据质量和信息含量的重要度量。信噪比的提高不仅能够有效评估去噪方法的性能, 还能直接影响数据处理和解释结果的准确性。在实际应用中, 全局信噪比和局部信噪比的结合分析能够更全面地揭示地震数据的特征和噪声分布情况, 为后续地质解释和勘探工作提供有力支持。

一般来说, 较高的 SNR、SSIM 和较小的 MAE、MSE 代表更好的降噪效果。不同方法的去噪结果如表 4 所示, 从中可以看出, MSI-Net 在 4 个指标的评估中表现最好。我们还意识到, 全局信噪比可能对本地数据的质量不敏感。在某些情况下, 可能会出现局部数据质量较差, 但整体信噪比较高的情况, 这对于全局差异较大的 DAS 记录来说是不可接受的。局部信噪比可以详细描述局部地震资料的质量, 因此用于定量分析所提方法的去噪性能。使用大小为 5×5 且步长为 1 的移动窗口对 DAS-VSP 数据进行分割, 并在移动窗口中计算本地 SNR。数据的本地信噪比 (t, x)。

可以表示为

$$SNR(t, x) = 10 \log_{10} \frac{\sum_{i=t-(w-1)/2}^{t+(w-1)/2} \sum_{j=x-(w-1)/2}^{x+(w-1)/2} (S(i, j) - \bar{S}(i, j))^2}{\sum_{i=t-(w-1)/2}^{t+(w-1)/2} \sum_{j=x-(w-1)/2}^{x+(w-1)/2} (Dn(i, j) - \bar{Dn}(i, j))^2}$$

(4.1)

在这里 S 是纯信号和 D_n 是去噪后的数据。 w 是窗口长度。MSI-Net 结果的局部信噪比和比较方法如图 8 所示，其中横坐标是地震迹数，纵坐标是采样点，彩条中的数字是信噪比（dB）。图 8A 显示了合成噪声 DAS-VSP 数据的本地 SNR。可以看出，受不同噪声影响的区域的局部信噪比较低，与实际情况相符。图 8G 显示了所提方法处理结果的本地信噪比。可以看出，本文提出的方法在提高局部信噪比方面表现最好。

指标	信噪比	结构相似性指数
原始记录	-0.4005	0.0516
带通滤波	1.8221	0.1495
小波变换	0.8423	0.0518
WNNM	0.4593	0.0881
DnCNN	18.3303	0.3641
U-Net	18.4876	0.4081
本文的方法	19.0006	0.4127

表 4-1. 不同去噪方法在测试集上的性能统计。

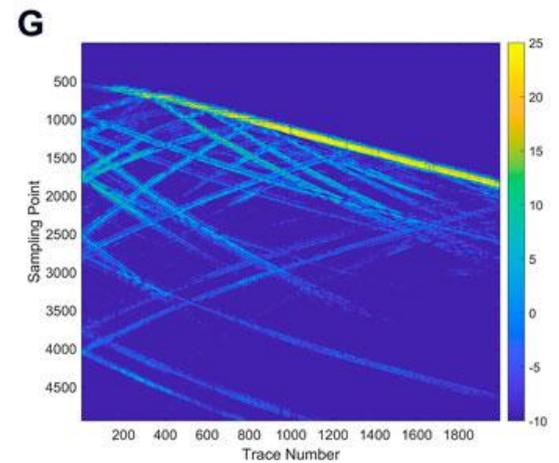
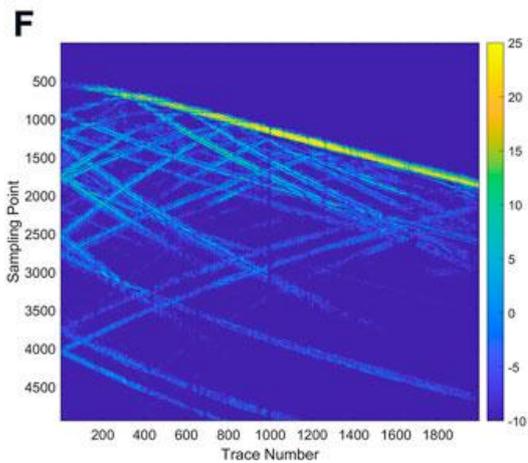
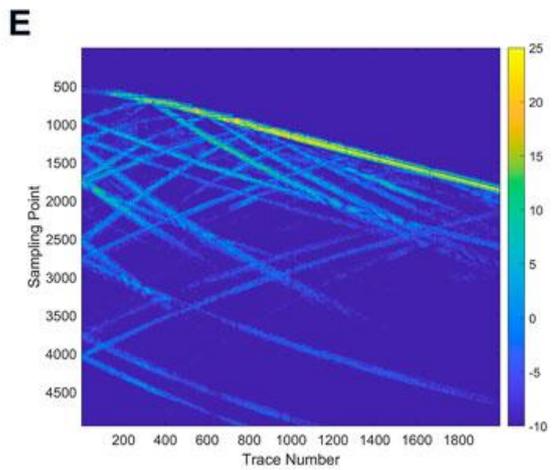
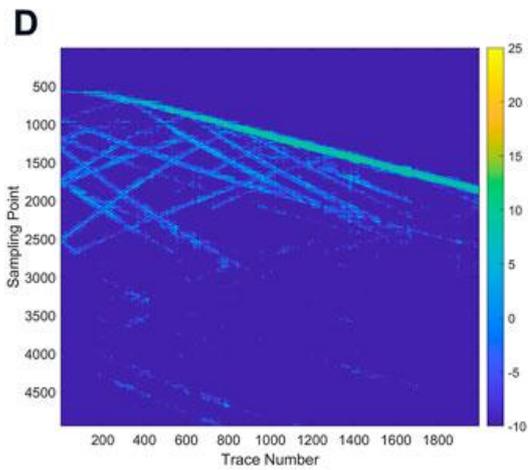
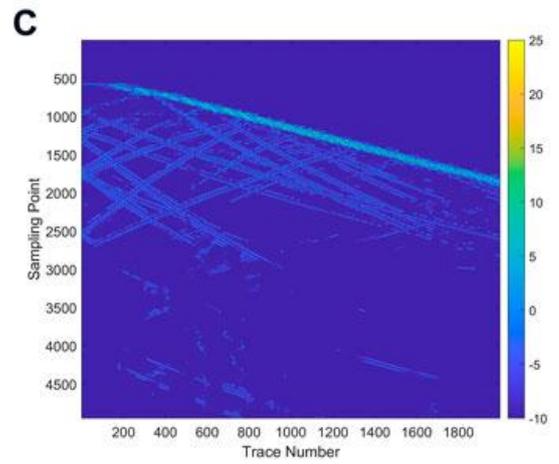
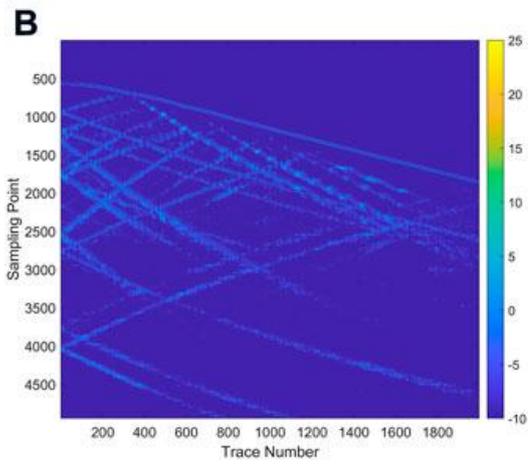
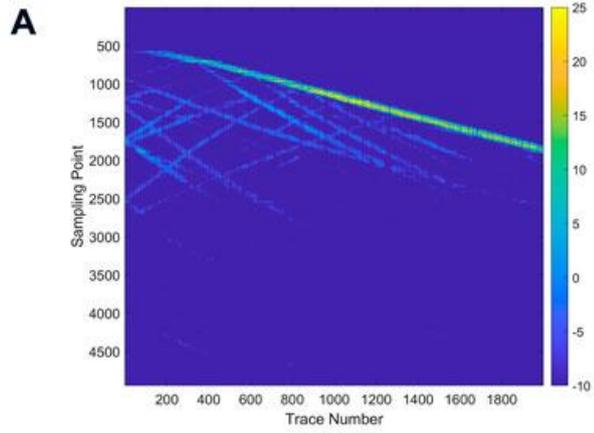


图 4-5. 本地信噪比分析。(A) 合成噪声 DAS-VSP 数据的本地信噪比。(B-G) 带通滤波、小波变换滤波、WNNM、DnCNN、U-Net、MSI-Net 的去噪结果的局部信噪比。

4.2 本章小结

本章综合比较了原始噪声、带通滤波、小波变换滤波、WNNM、DnCNN、UNet 和本文所使用的 MSI-Net，从总体来看，定量分析的结果表明：DnCNN、UNet 和 MSI-Net 三种深度学习方法结果的信噪比远高于传统方法，具有更好的去噪效果，噪声抑制更加均匀彻底，去除的噪声结果中没有明显的信号泄漏。而在深度学习方法中，本文使用的 MSI-Net 结果的信噪比最高，高于 DnCNN 和 U-Net。最后详细列出了几种方法的平均绝对误差 (MAE)、均方根误差 (RMSE)、信噪比 (SNR) 和结构相似性指数 (SSIM) 并进行对比，可以看出，本文提出的方法在提高局部信噪比方面表现最好。

第 5 章 结论和展望

在本文中，我们提出了一种用于 DAS-VSP 记录高分辨率重建的网络。借助多尺度特征学习和尺度间频繁的信息交互，该网络可以成功获取丰富的多分辨率表征。利用不同尺度的低分辨率信息，同时对高分辨率信息进行补充，实现精准的高分辨率重建。所提方法在处理构建的 DAS-VSP 记录时取得了优异的重建效果，特别是提高了信噪比和分辨率。

除此之外，本文还使用正向模拟构建了许多数据集并进行模拟降噪，对于现如今越来越多的深度学习而言，这无疑是一个很好的思路：不需要费尽心思寻找各种拥有典型噪声特征的实地勘探数据集来提高模型的泛化能力，而是直接通过模拟来进行训练，这样训练的模型往往有着比实际数据训练的模型拥有着更好的泛化能力，能更好地应对不同的实际情况。

得益于多尺度分析，该网络比以往的通用网络架构更好地恢复了本地细节。高分辨率重建记录可以对后续成像产生积极影响。相较于本文中提到的其他两种深度学习方案，基于多尺度网络的方案用尺度间的信息交换，更好地融合了多尺度信号，对高分辨率恢复有更好的效果，并且再其他方面也都有着比其余两种方法更好的表现。

也是因为多尺度分析，计算成本不可避免地增加了，在实验室相对稳定且硬件相对较好的环境对模拟数据进行降噪尚需要较长时间等待，在野外环境下模型能否快速稳定地得出结果依然存疑，因此未来将探索更有效的多尺度策略以应对各种各样可能的情况。

同时，基于多尺度分析的卷积神经网络流程进行数据处理依然存在着一些需要解决的问题和挑战，以及一些尚未完善的地方。例如：

- 1、引入注意力机制。引入注意力机制之后，对模型性能会有一些的提升。
- 2、数据集完备性问题。深度学习网络的泛用性通常与训练的数据集完备性呈正相关，本文中提出的方法采用了正向模拟来构建数据集，然而模拟的数据集是否依然有不足之处，抑或是模拟的数量还不足以涵盖绝大部分情况。对于地震领域而言，获取大量有效数据依然较为困难，完善模型也需要新算法的提出。这会是一个挑战。

3、模型优化问题。所有的卷积神经网络都需要多次重复训练并调整参数才能达到最好的效果，在模型选择相同的情况下，调整测试的次数越多，模型的效果越好。同时，模型本身也可以进行优化以取得更好效果。

综上所述，虽然基于多尺度卷积神经网络对 DAS-VSP 噪声抑制效果很好，在高低分辨率的表现都很不错，但是仍需要进一步地研究、测试和调整，从而才能更好地应对各种复杂的条件和地质环境。

参考文献

- [1] A. Buades, B. Coll, and J.-M. Morel, “A non-local algorithm for image denoising,” in IEEE Conference on Computer Vision and Pattern Recognition, vol. 2, 2005, pp. 60–65.
- [2] K. Dabov, A. Foi, V. Katkovnik, and K. Egiazarian, “Image denoising by sparse 3-D transform-domain collaborative filtering,” IEEE Transactions on Image Processing, vol. 16, no. 8, pp. 2080–2095, 2007.
- [3] 鱼跃华,张海波,李昕,寇姣姣,李康,耿国华,周明全.基于数据增强的秦俑碎片深度分类模型[J].激光与光电子学进展,2022,59(18):111-120.
- [4] 周权. 基于深度学习的青光眼图像前房角分类方法研究[D].华中科技大学,2021.DOI:10.27157/d.cnki.ghzku.2021.001546.
- [5] A. Buades, B. Coll, and J.-M. Morel, “Nonlocal image and movie denoising,” International Journal of Computer Vision, vol. 76, no. 2, pp. 123–139, 2008.
- [6] J. Mairal, F. Bach, J. Ponce, G. Sapiro, and A. Zisserman, “Non-local sparse models for image restoration,” in IEEE International Conference on Computer Vision, 2009, pp. 2272–2279.
- [7] M. Elad and M. Aharon, “Image denoising via sparse and redundant representations over learned dictionaries,” IEEE Transactions on Image Processing, vol. 15, no. 12, pp. 3736–3745, 2006.
- [8] W. Dong, L. Zhang, G. Shi, and X. Li, “Nonlocally centralized sparse representation for image restoration,” IEEE Transactions on Image Processing, vol. 22, no. 4, pp. 1620–1630, 2013.
- [9] L. I. Rudin, S. Osher, and E. Fatemi, “Nonlinear total variation based noise removal algorithms,” Physica D: Nonlinear Phenomena, vol. 60, no. 1, pp. 259–268, 1992.
- [10] S. Osher, M. Burger, D. Goldfarb, J. Xu, and W. Yin, “An iterative regularization method for total variation-based image restoration,” Multiscale Modeling & Simulation, vol. 4, no. 2, pp. 460–489, 2005.
- [11] Y. Weiss and W. T. Freeman, “What makes a good model of natural images?” in IEEE Conference on Computer Vision and Pattern Recognition, 2007, pp. 1–8.
- [12] 董安勇,杜庆治,苏斌,赵文博,于闻.基于卷积神经网络的红外与可见光图像融合[J].红外技术,2020,42(07):660-669.

- [13] GU J, DONG C, IEEE COMP SOC. Interpreting Super-Resolution Networks with Local Attribution Maps[C/OL]//2021 IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, CVPR 2021. LOS ALAMITOS: IEEE, 2021: 9195-9204.
- [14] SAAD O M, OBOUE Y A S I, BAI M, et al. Self-Attention Deep Image Prior Network for Unsupervised 3-D Seismic Data Enhancement[J]. IEEE transactions on geoscience and remote Sensing, 2022, 60(Journal Article): 1-14.
- [15] X. Lan, S. Roth, D. Huttenlocher, and M. J. Black, "Efficient belief propagation with learned higher-order Markov random fields," in European Conference on Computer Vision, 2006, pp. 269–282.
- [16] S. Z. Li, Markov random field modeling in image analysis. Springer Science & Business Media, 2009.
- [17] CARION N, MASSA F, SYNNAEVE G, et al. End-to-End Object Detection with Transformers[C/OL]//Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics).
- [18] CAO H, WANG Y, CHEN J, et al. Swin-Unet: Unet-Like Pure Transformer for Medical Image Segmentation[C/OL]//Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics).
- [19] S. Roth and M. J. Black, "Fields of experts," International Journal of Computer Vision, vol. 82.

致谢

日月忽其不淹兮，大学四年匆匆而过，好像是南方下的一场雪，在太阳升起后化成涓涓细流，无影无踪。

我由衷地感谢我爱的人和爱我的人一路给予的支持、关怀和帮助。

吉林大学

毕业论文（设计）指导教师评语

学生姓名 欧阳天成 专业 测控技术与仪器 班号 652024

题目名称 基于多尺度网络的 DAS-VSP 噪声抑制流程设计

评语：该文以将混合蛙跳算法与 MRS 数据处理有机的相结合来解决 MRS 信号反演中的多目标寻优问题。论文选题具有一定的理论价值和实际指导意义；该生在论文写作过程中态度认真，能够在老师指导下查阅文献与搜集资料，且提出了论述课题的实施方案；工作努力，按时完成了写作任务；论文论述全面，逻辑严谨、结构合理、结论准确，格式符合论文写作要求。论文达到学位论文要求，同意参加学位论文答辩。

测控技术与仪器 系 指导教师签字

董新桐

2024 年 6 月 8 日

吉林大学

毕业论文（设计）评阅人评语

学生姓名 欧阳天成 专业 测控技术与仪器 班号 652024

题目名称 基于多尺度网络的 DAS-VSP 噪声抑制流程设计

评语：论文建立了较为完善的 DAS 含噪模型，使用雷克子波通过正向模拟建模，然后作为数据集训练使用了亚当算法多尺度卷积神经网络进行降噪。在深度调整超参数和其他参数得到泛化性较强的模型后与其他多种降噪方法进行比较性测试，测试各项指标达到要求并优于其他方法。

论文表达流畅，内容完整，结果充分，格式符合规范要求，达到本科毕业设计的目标与要求。

同意参加毕业论文答辩。

评阅人签字：蒋川东

评阅人工作单位：仪器科学与电气工程学院

评阅人职务：副教授

2024 年 6 月 8 日

吉 林 大 学

毕 业 论 文（ 设 计 ） 答 辩 意 见

学生姓名 欧阳天成 专业 测控技术与仪器 班号 652024

题目名称 基于多尺度网络的 DAS-VSP 噪声抑制流程设计

评 语： 论文建立了简单的的 DAS 模型，并且以此作为数据集训练了多尺度卷积神经网络。在深度调整超参数和其他参数得到泛化性较强的模型后与其他多种降噪方法进行比较性测试，不断测试并进行修正，直到各项指标达到要求，在综合比较后发现效果最好。

 论文选题、对技术因素与非技术因素分析合理。论文结构合理、图表规范，达到学士论文标准。

毕业论文（设计）成绩：

 75

答辩组组长： 李新义

2024 年 6 月 8 日

