

doi:10.3799/dqkx.2026.076

基于增强残差特征蒸馏的地震图像超分辨率重建

吴迪^{1,2,3,4,5}, 刘刚^{1,2,3,4,5,*}, 陈麒玉^{1,2,3,4,5}, 崔哲思^{1,2,3,4,5}, 方洪峰^{1,2,3,4,5}, 张策^{1,2,3,4,5}

1. 国家地理信息系统工程技术研究中心, 中国地质大学(武汉)计算机学院, 湖北武汉 430074

2. 智能地学信息处理湖北省重点实验室, 湖北武汉 430074

3. 自然资源信息管理与数字孪生工程软件教育部工程研究中心, 湖北武汉 430074

4. 贵州省战略矿产智慧勘查重点实验室, 贵州贵阳, 550081

5. 自然资源部资源定量评价与信息工程重点实验室, 湖北武汉 430074

摘要: 地震图像超分辨率重建对提升地震资料解释与地质建模精度具有重要作用, 但现有方法模型规模较大、计算开销高, 在强噪声和复杂地质结构条件下细节恢复能力有限。针对上述问题, 本文提出了基于增强型残差特征蒸馏生成对抗网络(ERFDN-GAN)的地震图像超分辨率重建方法。该方法以增强型残差特征蒸馏模块(ERFDB)为基本单元, 通过特征蒸馏机制降低模型复杂度, 并引入空间注意力和通道注意力以增强特征表达能力。实验表明, 该方法在 PSNR 和 SSIM 等指标上整体优于目前代表性方法, 并能在复杂场景下保持较低复杂度和稳定的重建性能。所提出的 ERFDN-GAN 方法兼顾效率与精度, 为地震资料解释、地质建模以及多源地学数据采集和挖掘的智能化处理提供了技术支持。

关键词: 地震图像超分辨率重建; 生成对抗网络; 残差特征蒸馏; 注意力机制

中图分类号: P618

收稿日期: 2025-12-23

Seismic Image Super-Resolution Reconstruction Based on Enhanced Residual Feature Distillation

Wu Di^{1,2,3,4,5}, Liu Gang^{1,2,3,4,5,*}, Chen Qiyu^{1,2,3,4,5}, Cui Zhesi^{1,2,3,4,5}, Fang Hongfeng^{1,2,3,4,5}, Zhang Ce^{1,2,3,4,5}

1. National Engineering Research Center for Geographic Information System, School of Computer Science, China University of Geosciences, Wuhan 430074, China

2. Hubei Key Laboratory of Intelligent Geo-Information Processing, Wuhan 430074, China

3. Engineering Research Center of Natural Resources Information Management and Digital Twin Engineering Software, Ministry of Education, Wuhan 430074, China

4. Guizhou Key Laboratory of Intelligent Exploration of Strategic Mineral Resources, Guiyang 550081, China

5. Key Laboratory of Resource Quantitative Assessment and Information Engineering, Ministry of Natural Resources, Wuhan 430074, China

Abstract: Seismic image super-resolution reconstruction is of great significance for improving the accuracy of seismic interpretation and geological modeling. However, existing methods often suffer from large model sizes and high computational costs, and exhibit limited detail recovery capability under strong noise and complex geological structures. To address these issues, this paper proposes an enhanced residual feature distillation generative adversarial network (ERFDN-GAN) for seismic image super-resolution reconstruction. The network is built upon enhanced residual feature distillation blocks (ERFDBs), where a feature distillation mechanism is employed to reduce model complexity. Spatial attention and channel attention mechanisms are further introduced to enhance feature representation capability. Experimental results demonstrate that the proposed method achieves overall superior performance compared with representative methods in terms of PSNR and SSIM, while maintaining low model complexity and stable reconstruction performance under complex scenarios. The proposed ERFDN-GAN method effectively balances computational efficiency and reconstruction quality, providing technical support for seismic interpretation, geological modeling, and the intelligent acquisition and mining of multi-source geoscience data.

Key words: seismic image super-resolution reconstruction; generative adversarial network; residual feature distillation; attention mechanism

基金项目: 国家自然科学基金项目(Nos. 42372345, 42172333); 湖北省自然科学基金(No. 2025AFB179); 贵州省科技重大专项(No. 黔科合重大[2025]016)。

作者简介: 吴迪(1999—), 男, 硕士研究生, 研究方向为智能地学信息处理、三维地质建模, ORCID: 0009-0006-5062-0461, E-mail: wu.di666@qq.com

通讯作者: 刘刚, ORCID: 0000-0002-9651-4473, E-mail: liugang@cug.edu.cn

0 引言

地震图像超分辨率重建在地震资料解释与储层建模等地质工作中具有重要意义,高质量地震数据作为多源地学数据采集与集成的重要组成部分,可显著提升地质结构细节的可识别性和地质信息表达的准确性,为后续储层表征与地质建模提供可靠的数据基础(李晓光和吴潇,2020; Zhang *et al.*,2024; Elgendy *et al.*,2025; 李芳等,2025; 吴海波等,2025)。传统地震分辨率提升方法主要包括滤波(Li *et al.*, 2022b; 赵桢松等, 2023; Duan *et al.*, 2024)和反褶积(Yuan *et al.*, 2020; 程朝辉等, 2023; 倪文军等, 2023),前者通过增强高频成分改善微小结构识别,后者用于压缩子波、提高纵向分辨率。然而,这些方法依赖先验假设,难以恢复复杂构造的精细细节,且易引入伪影,存在一定局限性。随着地震观测数据规模的持续增长,围绕地震资料智能化处理与自动分析的研究不断深化,为复杂地震信息的高效提取提供了新的思路(蒋策等, 2024; 朴健等, 2025)。

近年来,基于卷积神经网络的图像超分辨率方法在自然图像处理中取得了显著进展(Bashir *et al.*, 2021; Li *et al.*, 2021; Kong *et al.*, 2022; Wang *et al.*, 2023),并逐渐应用于地震图像的超分辨率重建。借助深度网络强大的特征学习与建模能力,研究者能够有效恢复高频细节,增强地质结构的可识别性(刘玉敏等, 2022; Mousavi and Beroza, 2022, 2023; Dong *et al.*, 2024a, 2024b)。例如, Li *et al.*(2022a)提出基于 U-Net 的协同建模方法,可同时实现超分与去噪; Min *et al.*(2023)提出双解码器 U-Net (D2 UNet),结合边缘引导机制提升了噪声环境下的重建效果; Hamida *et al.*(2023)设计了相引导损失函数,以增强超分图像在相分类任务中的表现; Zeng *et al.*(2023)提出的深度特征挖掘网络(Deep Feature Mining Network, DFMN)融合多尺度浅层提取与双分支深特征学习,在有限样本下显著提升了模型泛化能力。

在此基础上,一些研究进一步结合注意力机制与对抗学习框架来提升地震图像的重建性能。Sun *et al.*(2022)将残差学习与反投影机制结合,并引入对抗训练,实现了超分与去噪的联合重建; Zhong *et al.*(2024)利用混合双边注意模块建模全局与局部特征,并结合对抗学习,有效改善了弱信号与复杂地质结构的恢复效果。Lin *et al.*(2024)提出 SeisGAN,将生成对抗网络与感知损失相结合,在抑制随机噪声的同时提升了野外地震图像的分辨率,使放大后的图像更加清晰,并突出薄层与断层等细微构造特征。与 SeisGAN 类似, Liu *et al.*(2024)也在训练中结合感知损失与对抗学习,但采用 RCAN 作为生成器,并使用相对式对抗损失(RaGAN),该方法在合成和实际地震数据的重建任务中取得了更高的分辨率和信噪比。总体来看, SeisGAN 与 Liu *et al.*(2024)的方法均属于近年来地震图像超分辨率研究中具有代表性的 GAN (Generative Adversarial Network) 框架。

尽管上述方法推动了地震图像超分辨率的发展,但现有生成器普遍存在模型复杂度较高、计算开销较大等问题,同时在强噪声干扰和复杂地质结构下的细节恢复能力仍显不足。针对上述问题,本文在 SeisGAN 框架的基础上,将生成器替换为残差特征蒸馏网络(Residual Feature Distillation Network, RFDN),并在其残差特征蒸馏块(Residual Feature Distillation Block, RFDB)中引入并行通道注意力(Channel Attention, CA),形成增强型残差特征蒸馏网络(Enhanced Residual Feature Distillation Network, ERFDN)。最终, ERFDN 与 GAN 框架结合,构成增强型残差特征蒸馏生成对抗网络(ERFDN-GAN)。实验结果表明, ERFDN-GAN 在降低模型复杂度的同时保持了重建精度,相较现有方法在断层边界与横向纹理等关键细节恢复方面表现更优,为地震资料解释、地质建模以及多源地学数据采集和挖掘的智能化处理提供了技术支撑。

本文的主要贡献可总结如下:

(1) 在 SeisGAN 框架下引入 RFDN 作为生成器基础结构,并结合地震图像超分辨率任务特点进行增强,构建 ERFDN,通过特征蒸馏机制在保证重建性能的同时有效降低模型复

杂度。

(2) 在残差特征蒸馏块 (RFDB) 中进一步并行融合通道注意力与增强空间注意力, 设计增强型残差特征蒸馏块 (ERFDB), 有效提升模型在强噪声和复杂地质结构条件下的特征表达能力与对抗训练稳定性。

(3) 在合成地震数据和实测地震数据上对所提方法进行了系统验证, 实验结果表明该方法在断层边界、横向纹理及薄层等复杂地质结构细节恢复方面具有明显优势。

1 ERFDN-GAN 方法

1.1 总体框架

本文基于 SeisGAN 框架构建, 提出 ERFDN-GAN 方法, 其总体结构如图 1 示, 模型由生成器和判别器两部分组成, 输入为单通道低分辨率地震图像, 输出为对应的高分辨率图像。

在该框架中, 生成器采用改进的 ERFDN, 能够在小规模模型下高效提取并重建地震图像的细特征, 实现轻量化与高性能的兼顾。判别器沿用 SeisGAN 的设计, 用于区分生成结果与真实高分辨率图像之间的差异, 并通过对抗训练机制引导生成器不断优化, 使其输出结果更符合地质构造特征。

为保证重建结果的准确性与真实性, 网络训练过程中联合引入三类损失函数: 像素损失、感知损失 (基于 VGG 网络) 和对抗损失。其中, 像素损失约束数值一致性, 感知损失维持纹理与结构特征的保真度, 对抗损失则增强生成图像的真实性。三者协同作用, 有效提升了超分辨率重建的整体性能。

与 SeisGAN 相比, ERFDN-GAN 的主要改进在于生成器部分: 通过采用 ERFDN 替代原有结构, 不仅提升了特征表达能力, 还增强了模型的去噪性能, 在保持轻量化的同时进一步改善了重建效果。

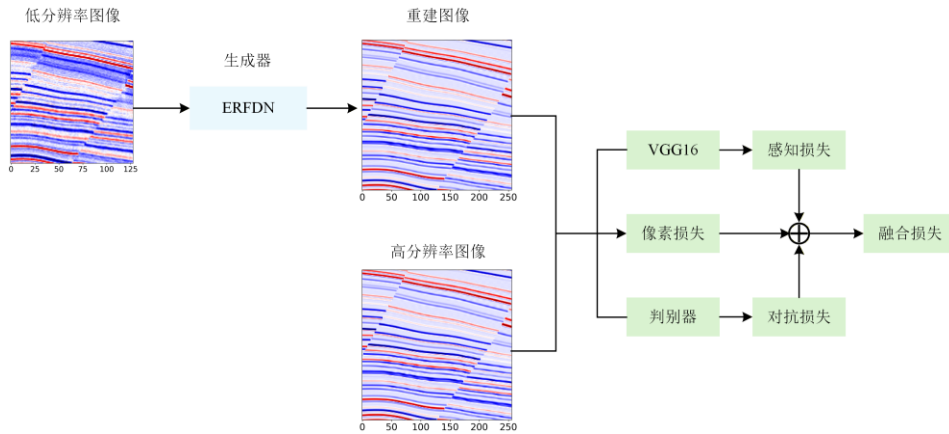


图 1 ERFDN-GAN 的算法总体框架

Fig. 1 Overall framework of the ERFDN-GAN algorithm

1.2 生成器

ERFDN-GAN 的生成器采用 ERFDN, 用于从低分辨率地震图像中高效提取并重建细特征。在 RFDB 的基础上, 笔者针对其核心模块——RFDB 进行了改进: 在保留其增强空间注意力 (Enhanced Spatial Attention, ESA) 的同时, 引入 CA, 并将二者并行融合。该设计显著增强了特征表达能力, 提升了对高噪声地震图像的适应性, 并有助于稳定生成器与判别器的对抗训练。由此得到的改进模块称为 ERFDB, 基于此构建的网络即为 ERFDN。

图 2 展示了 ERFDN 的整体结构, 其主要由 4 个级联的 ERFDB 和一个 SubPixel 上采样模块组成。下文将进一步介绍核心模块 ERFDB 的内部结构, 并阐述 CA 与 ESA 在特征提取与噪声抑制中的作用机制。




图 2 ERFDN 网络结构

Fig. 2 Network architecture of the ERFDN

1.2.1 增强型残差特征蒸馏块（ERFDB） 在轻量化超分辨率网络中，RFDB 通过多阶段通道蒸馏与残差细化机制，能够高效压缩和重组特征，并在末端引入 ESA 以突出关键区域，从而在较低计算开销下保持较好的特征提取能力。然而，RFDB 在地震图像处理场景中也存在不足：其仅依赖空间注意力，难以有效抑制高噪声环境下的冗余通道信息，对抗训练过程中也容易出现不稳定性。

为解决上述问题，本文在 RFDB 的基础上提出 ERFDB。该模块保持原有的特征蒸馏与 ESA 机制，并行引入 CA，以增强噪声抑制能力并提升训练稳定性。具体而言，CA 在通道维度建模特征依赖关系，自适应地削弱噪声通道、强化关键构造特征；ESA 在空间维度生成注意力图，突出地震图像中与地质构造相关的局部区域。二者协同作用，使 ERFDB 在保持轻量化特性的同时，更好地适应高噪声地震图像的重建任务。

具体而言，ERFDB 采用三阶段的特征蒸馏过程。设输入特征为 F_0 ，在每一阶段通过 1×1 卷积获得蒸馏特征，并利用 3×3 卷积结合残差连接对剩余特征进行细化。其过程可表示为：

$$\begin{aligned} D_1 &= \phi(W_{1 \times 1}^1(F_0)), R_1 = \phi(W_{3 \times 3}^1(F_0) + F_0) \\ D_2 &= \phi(W_{1 \times 1}^2(R_1)), R_2 = \phi(W_{3 \times 3}^2(R_1) + R_1) \\ D_3 &= \phi(W_{1 \times 1}^3(R_2)), R_3 = \phi(W_{3 \times 3}^3(R_2) + R_2) \end{aligned} \quad (1)$$

在第三阶段蒸馏以后，进一步通过一个 3×3 卷积得到第四份特征 D_4 ，计算过程如下：

$$D_4 = \phi(W_{3 \times 3}(R_3)) \quad (2)$$

四路特征在通道维度拼接后，经 1×1 卷积融合为综合特征：

$$F_s = W_{1 \times 1}[D_1, D_2, D_3, D_4] \quad (3)$$

在此基础上，ERFDB 并行引入 CA 与 ESA：

$$F_{CA} = CA(F_s), F_{ESA} = ESA(F_s) \quad (4)$$

二者输出在通道维度拼接，经 1×1 卷积融合，最后与输入残差相加，得到模块输出：

$$F_{out} = W_{1 \times 1}[F_{CA}, F_{ESA}] + F_0 \quad (5)$$

其中， $W_{1 \times 1}$ 与 $W_{3 \times 3}$ 分别表示 1×1 与 3×3 卷积操作， $\phi(\cdot)$ 表示非线性激活函数， $[\cdot]$ 表示在通道维度上的拼接操作。CA 与 ESA 的具体结构如图 3(c)和(d)，所示，CA 通过全局平均池化与非线性映射计算通道权重，自适应地抑制噪声通道；ESA 则通过卷积与空间加权生成注意力图，突出关键区域。

通过上述设计，ERFDB 在继承 RFDB 的特征蒸馏优势的基础上，引入通道建模与空间选择的协同注意力机制，从而实现轻量化、细节增强与噪声抑制的统一。特别是在 GAN 框架下，有效缓解了对抗训练中的梯度振荡问题，提升了整体训练稳定性和最终的重建效果。

1.4 损失函数

本文的损失函数设计继承了 SeisGAN 框架，由生成器损失与判别器损失两部分组成。生成器通过联合使用像素损失、感知损失和对抗损失来提升重建图像的质量，而判别器则负责区分生成图像与真实图像，从而在对抗训练中为生成器提供反馈。

1.4.1 生成器损失 生成器的损失函数对超分辨率重建质量至关重要。本文采用均方误差 (MSE)、感知损失 (VGG loss) 与对抗性损失三者的组合，其总体形式为：

$$\mathcal{L}_G = \lambda_{\text{MSE}}\mathcal{L}_{\text{MSE}} + \lambda_{\text{VGG}}\mathcal{L}_{\text{VGG}} + \mathcal{L}_{\text{adv}} \quad (6)$$

其中， \mathcal{L}_{MSE} 表示逐像素的均方误差， \mathcal{L}_{VGG} 表示基于 VGG 网络的感知损失， \mathcal{L}_{adv} 表示对抗损失， λ_{MSE} 与 λ_{VGG} 为权重系数。三种损失的具体描述如下：

(1)像素损失 (MSE loss):

$$\mathcal{L}_{\text{MSE}} = \frac{1}{WH} \sum_{x=1}^W \sum_{y=1}^H (I_{\text{HR}}(x, y) - G(I_{\text{LR}})(x, y))^2 \quad (7)$$

其中， I_{HR} 为真实高分辨率图像， $G(I_{\text{LR}})$ 为生成图像， W 和 H 分别为图像宽与高。

(2)感知损失 (VGG loss):

$$\mathcal{L}_{\text{VGG}} = \frac{1}{C_{i,j}H_{i,j}W_{i,j}} \sum_{c=1}^{C_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} (\phi_{i,j}(I_{\text{HR}})_{c,x,y} - \phi_{i,j}(G(I_{\text{LR}}))_{c,x,y})^2 \quad (8)$$

其中， $\phi_{i,j}$ 表示在 VGG16 网络第 i 个池化层之前、第 j 次卷积后的特征图。VGG 损失用于保持生成结果在高层特征空间的相似性，避免过度平滑。

(3)对抗损失:

$$\mathcal{L}_{\text{adv}} = -\frac{1}{N} \sum_{n=1}^N \log D(G(I_{\text{LR}}^n)) \quad (9)$$

其中， N 为批量大小， $D(\cdot)$ 为判别器输出概率。该损失鼓励生成器生成能够欺骗判别器的图像，从而提升重建结果的真实性与细节表现。

1.4.2 判别器损失 判别器的目标是最大化真实图像被判别为“真”的概率，并最小化生成图像被误判为“真”的概率，其损失函数定义为：

$$\mathcal{L}_D = -\frac{1}{M} \sum_{i=1}^M \log D(I_{\text{HR}}^i) - \frac{1}{N} \sum_{j=1}^N \log 1 - D(G(I_{\text{LR}}^j)) \quad (10)$$

其中， M 与 N 分别为真实样本与生成样本的数量。通过交替优化生成器与判别器，模型能够逐步逼近真实地震图像的分布，从而实现高质量的超分辨率重建。

1.5 方法实现

前文已介绍了 ERFDN-GAN 的总体框架、生成器 ERFDN、判别器以及损失函数。为了更清晰地展现整体训练过程，本节给出 ERFDN-GAN 的具体实现方法，其训练流程如图 5 所示。该训练流程通过交替优化生成器与判别器，使生成器在多重损失约束下不断提升细节恢复能力，并逐步增强对噪声与复杂地质结构的适应性，从而实现高质量的超分辨率重建。

算法1: ERFDN-GAN的训练流程
Input: 低分辨率图像，对应高分辨率图像
Output: 训练完成的ERFDN生成器参数
 初始化ERFDN生成器 G 与判别器 D ，设定优化器和损失函数；
 对于每次训练迭代，执行以下步骤：
 (a) 判别器更新：
 生成器前向传播得到重建结果
 计算判别器损失；
 反向传播更新 D ；
 (b) 生成器更新：
 重新前向传播得到重建结果；
 计算生成器损失；
 反向传播并更新 G ；
 end for
 return 训练好的生成器参数 G 。

图 5 ERFDN-GAN 训练算法示意图

Fig. 5 Schematic diagram of ERFDN-GAN training algorithm

2 实验结果与对比分析

2.1 实验设置

2.1.1 数据集与预处理 本文实验所使用的数据与 SeisGAN 保持一致，均采用其公开提供的合成与真实地震数据集。合成数据集由 Wu *et al.*(2019, 2020)提出的工作流程生成，反射率模型中引入了地层倾角、褶皱和断层等构造特征，随后分别与高频和低频 Ricker 子波卷积以获得成对的高分辨率与低分辨率地震图像，同时在低分辨率图像中加入随机噪声以模拟野外采集条件。该数据集包含 400 对三维地震立方体，共提取 12 800 对二维切片，并按照 8 : 1 : 1 的比例划分为训练集、验证集和测试集。真实地震数据集同样来自 SeisGAN，但不包含配对的高分辨率参考图像，因此仅用于定性结果展示。

与 SeisGAN 的原始训练设置不同，本文在训练阶段进一步采用了随机裁剪操作，将原始的低分辨率图像与高分辨率图像对(128×128 与 256×256)随机裁剪为 96×96 与 192×192，以增强数据多样性并提升模型的泛化能力。此外，所有图像在训练前均进行归一化处理：

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

其中， y 为归一化后的图像， x 为原始图像， x_{\max} 和 x_{\min} 分别表示该图像的最大值与最小值。为了进一步提高模型的鲁棒性，数据增强操作包括随机水平/垂直翻转和 180° 旋转。

2.1.2 实验环境与参数 所有模型的训练与测试均在 Python 3.11 环境下完成，并基于 PyTorch 2.0.1 框架实现。实验运行于一台配备 Intel Xeon W-2133 CPU、NVIDIA GeForce RTX 3090 GPU (24 GB 显存) 和 62 GB RAM 的服务器上。

在训练参数方面，生成器与判别器均采用 Adam 优化器，初始学习率设置为 5×10^{-4} ，并在每 20 轮衰减一半。批量大小为 16，总训练轮数为 100 轮。

在模型参数设置上，判别器结构保持与 SeisGAN 一致，而生成器采用改进后的 ERFDN，其特征通道数设为 50，蒸馏率设为 0.5，以兼顾轻量化与性能提升。在损失函数权重设置方面，对抗损失与感知损失的权重参数分别设置为 0.01 和 0.06，该配置沿用了 SeisGAN 中的经验设置。考虑到 GAN 训练过程对损失权重较为敏感，而系统性的网格搜索将显著增加训练成本，本文未对上述权重进行全面的参数搜索。在初步实验中，笔者观察到该参数组合在 ERFDN 生成器结构下能够保持稳定收敛，并取得较好的重建效果。因此，在保证公平对比的前提下，本文统一采用上述权重配置用于所有对比实验。

2.2 评价指标

为了全面评估超分辨率方法在地震图像上的重建性能，本文采用三类指标：峰值信噪比 (PSNR)、结构相似性指数 (SSIM) 以及频率距离 (Frequency Distance, FD)。前两者衡量图像在空间域的相似性，而 FD 进一步在频率域对比重建图像与真实图像的一致性。

2.2.1 峰值信噪比 (PSNR) PSNR 衡量重建图像与参考高分辨率图像之间的逐像素差异，其定义为：

$$\text{PSNR} = 10 \log_{10} \left(\frac{\text{MAX}^2}{\text{MSE}} \right) \quad (12)$$

其中，MAX 为图像像素的最大值，MSE 为均方误差：

$$\text{MSE} = \frac{1}{WH} \sum_{i=1}^W \sum_{j=1}^H (x_{ij} - y_{ij})^2 \quad (13)$$

其中， W 和 H 分别表示图像的宽度与高度， x_{ij} 和 y_{ij} 分别为参考图像与重建图像在位置 (i, j) 的像素值。

2.2.2 结构相似性指数 (SSIM) SSIM 从亮度、对比度和结构三个方面综合度量两幅图像的相似性：

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (14)$$

其中, μ_x 、 μ_y 为均值, σ_x^2 、 σ_y^2 分别为方差, σ_{xy} 为协方差, C_1 、 C_2 为稳定常数。SSIM 越接近 1, 说明两幅图像的结构越一致。

2.2.3 频率距离 (FD) 考虑到地震图像的频率特征对解释与建模具有重要意义, 本文引入 FD 作为补充指标。FD 衡量生成器重建图像与真实高分辨率图像在频域的差异, 其定义为:

$$\text{FD} = \sqrt{\frac{1}{MN} \sum_{u=1}^M \sum_{v=1}^N (|F_g(u, v)| - |F_r(u, v)|)^2} \quad (15)$$

其中, M 和 N 为图像尺寸, $|F_g(u, v)|$ 表示重建图像经过傅里叶变换后的幅度谱, $|F_r(u, v)|$ 表示真实高分辨率图像的幅度谱。FD 值越小, 说明两幅图像在频域上的相似性越高。

2.3 合成地震数据实验结果

2.3.1 CA 与 ESA 融合方式的消融实验 为验证 ERFDB 模块中 CA 与 ESA 不同融合方式的合理性, 本文在合成地震数据集上进一步开展了消融实验。具体而言, 设计并比较了以下四种结构配置: 仅引入 ESA 模块 (ESA)、串联 CA→ESA、串联 ESA→CA 以及并联 CA||ESA 结构。所有实验均在相同训练设置与评价指标条件下进行, 以保证对比结果的公平性。

表 1 出了不同融合方式在 PSNR、SSIM 以及 FD 指标上的定量对比结果。可以观察到, 相较于仅使用 ESA 模块, 引入 CA 与 ESA 的组合结构均能在三个指标上取得不同程度的性能提升, 表明通道与空间注意力的协同建模对地震图像超分辨率重建具有积极作用。

进一步对比不同融合策略可以发现, 各结构在 PSNR 与 SSIM 指标上的差异整体较为接近, 其中并联 CA||ESA 结构在 SSIM 指标上取得了最优结果, 同时在 FD 指标上表现最佳, 显示出其在频谱保持方面的优势。综合考虑多项定量指标的表现, 并结合地震数据对频谱一致性的实际需求, 本文最终采用并联 CA||ESA 作为 ERFDB 模块的默认融合方式。

表 1 不同 CA 与 ESA 融合方式的消融实验结果

Table 1 Ablation Results of Different CA and ESA Fusion Strategies

融合方式	PSNR	SSIM	FD
ESA	26.275	0.933	1.104
CA → ESA	27.854	0.936	1.038
ESA → CA	27.888	0.933	1.019
CA ESA (本文)	27.890	0.938	0.999

2.3.2 与现有方法的对比分析 在前述消融实验中已确定 ERFDB 中 CA 与 ESA 的融合方式后, 为进一步验证本文方法在合成地震数据上的整体性能, 选取了两类具有代表性的方法作为对比对象。

首先是 SeisGAN, 该方法首次在地震超分辨率任务中同时引入像素重建损失、感知损失 (VGG) 和对抗损失的三合一训练框架, 并在合成与实测数据上均取得了较好的效果, 是本文方法的重要参考与改造起点。其次是 RCAN-GAN(Liu *et al.*, 2024)同样采用三合一训练框架, 但在生成器结构上引入了 RCAN, 以增强网络的特征表达能力。由于原论文未公开源码, 本文参考其思路, 在 SeisGAN 框架下以 RCAN 替换原生成器, 构建了 RCAN-GAN 对比基线。

下面将从定量指标与定性可视化两个方面, 对比分析不同方法在合成地震数据集上的表现。

表 2 给出了 SeisGAN、RCAN-GAN 与本文提出的 ERFDN-GAN 在合成地震数据集上的定量对比结果。整体来看, 三种方法在像素精度、结构相似性及频域恢复方面呈现逐步提升的趋势。相较于 SeisGAN, RCAN-GAN 在三项指标上均有明显改进, PSNR 提升至 27.09 dB、SSIM 提升至 0.930, 且 FD 降低至 1.025, 说明更强的生成器结构能够带来更好的重建效果。

在此基础上,ERFDN-GAN 进一步取得最优结果:PSNR 达到 27.89 dB,SSIM 提升至 0.938,FD 进一步降低至 0.999。该结果表明,ERFDN-GAN 不仅在像素级精度和结构相似性方面优于两种对比方法,而且在频域特征恢复上更接近真实高分辨率图像,能够更好地突出断层边界与横向纹理等细节。

同时,在模型复杂度方面,ERFDN-GAN 的生成器参数量和计算量最低(523 971 参数、8.22 GFLOPs),相比 SeisGAN(565 768 参数、9.54 GFLOPs)和 RCAN-GAN(557 458 参数、9.12 GFLOPs)均有所减少。这说明本文方法在保持高效性的同时实现了更优的重建质量,具有更好的性能与复杂度平衡。

表 2 合成地震数据上的定量对比结果

Table 2 Quantitative comparison results on synthetic seismic data

模型	参数量(生成器)	FLOPs(G)	PSNR	SSIM	FD
SeisGAN	565768	9.54	25.985	0.922	1.137
RCAN-GAN	557458	9.12	27.086	0.93	1.025
ERFDN-GAN(本文)	523971	8.22	27.890	0.938	0.999

进一步的可视化对比结果如图 6 所示,包括低分辨率输入图像、高分辨率参考图像,以及 SeisGAN、RCAN-GAN 和 ERFDN-GAN(本文方法)的输出,并给出了局部区域的放大图。从整体来看,三种方法均显著提升了低分辨率图像的成像清晰度,有效缓解了模糊和细节缺失问题。但从局部放大区域的进一步观察可以发现,不同方法在细节恢复上仍存在差异。

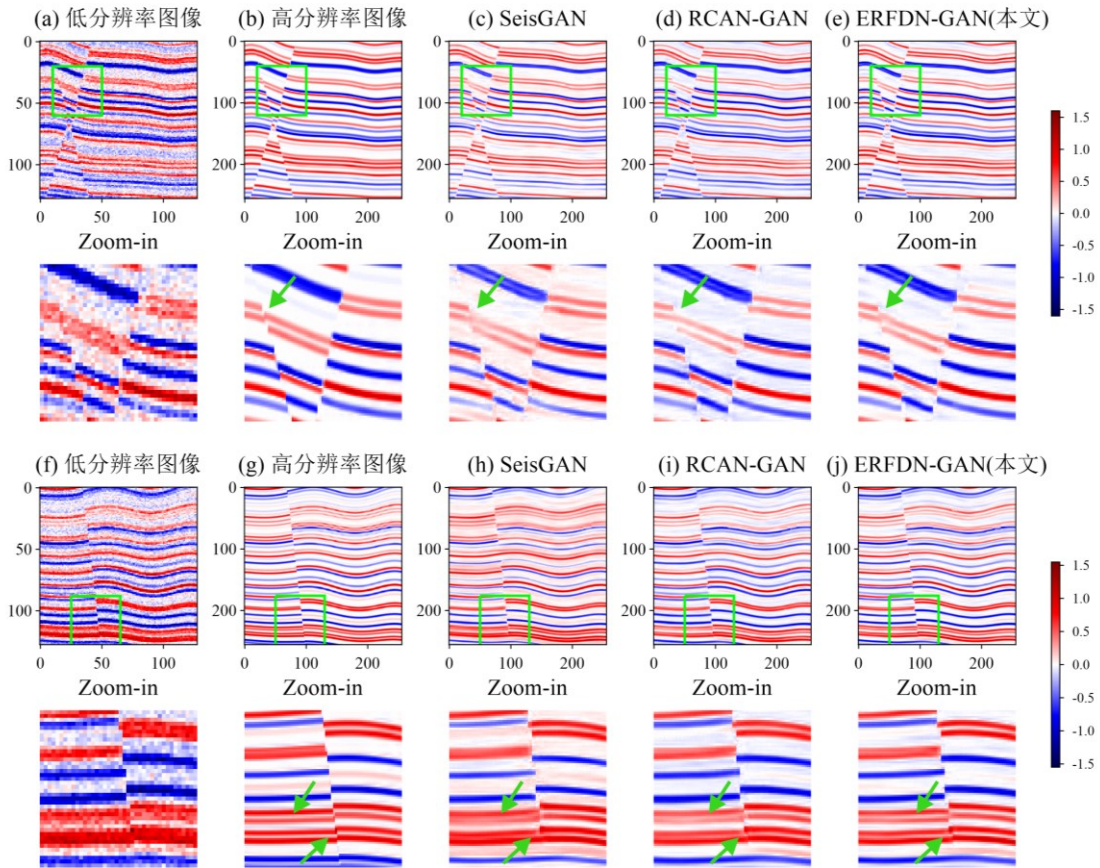


图 6 合成地震数据的可视化对比结果

Fig. 6 Visual comparison results on synthetic seismic data

具体而言,SeisGAN 在部分断层位置的成像仍存在模糊,局部断裂特征未能清晰分离,容易与周围层理混在一起;同时,在部分横向较细小的层理和薄层结构中,恢复效果有限,连续性不足。RCAN-GAN 在这些方面较 SeisGAN 有明显改善,断层位置更清晰,能够辨别

出断裂的存在，薄层结构的恢复也更加接近高分辨率地震图像，但在部分区域出现了断层的局部误连接现象，导致结构边界不够准确。相比之下，ERFDN-GAN 在断层边界和层理细节恢复方面进一步取得最优表现：断层位置更加锐利且保持了正确的断裂特征，没有出现类似的错误，横向薄层的连续性和完整性也优于 RCAN-GAN，更加贴近高分辨率地震图像参考结果。

总体来看，ERFDN-GAN 在弱反射事件的完整性、断层结构解析以及横向层理与薄层细节恢复方面均优于 SeisGAN 和 RCAN-GAN，其结果与高分辨率地震图像更加一致，验证了本文方法在合成地震数据上的有效性与优势。

2.4 实测地震数据实验结果

为了进一步验证本文方法在实际资料中的有效性，本节在实测地震数据上进行了超分辨率重建实验，并从可视化结果、振幅曲线以及频谱特性三个方面展开分析。需要指出的是，实测地震数据通常不包含与之对应的高分辨率参考图像，因此本节相关分析主要用于对不同方法在实测数据上的重建行为进行定性比较，以评估其在保持原始地震信息一致性和频域合理性方面的表现。

图 7 展示了原始低分辨率地震数据、SeisGAN、RCAN-GAN 以及本文提出的 ERFDN-GAN 的重建结果。从整体成像效果来看，三种超分方法均显著提升了图像的清晰度，使地层结构更加易于辨识。但在局部放大区域的对比中，不同方法之间仍存在差异。SeisGAN 在部分断层位置仍显模糊，局部断裂特征未能有效分离，同时在部分横向层理中存在连续性不足的问题。RCAN-GAN 在这些方面较 SeisGAN 有所改善，断层边界刻画更加清晰，层理结构的恢复也更为完整，但在个别区域细节还原上仍存不足。相比之下，ERFDN-GAN 的结果在断层刻画和层理解析上表现更优，能够更好地区分断裂特征，局部构造细节更清晰，横向层理的连续性也优于前两种方法。

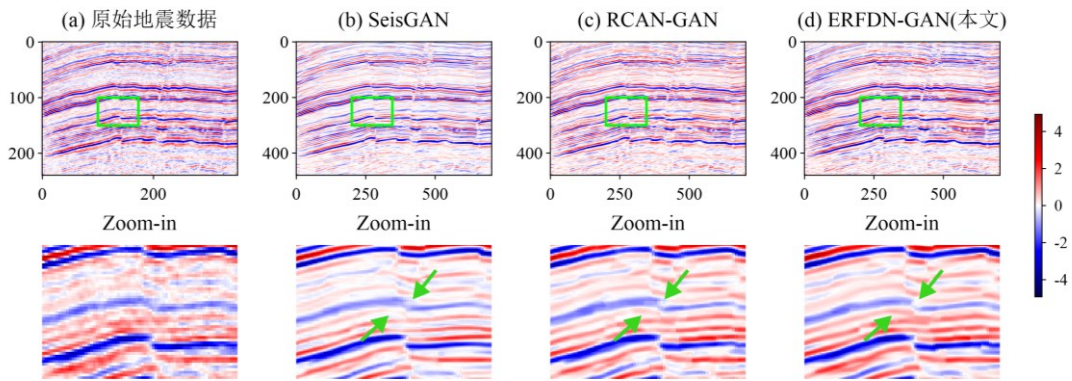


图 7 实测地震数据的可视化对比结果

Fig. 7 Visual comparison results on real seismic data

为评估不同超分辨率方法在实测地震数据上的振幅保持特性，从同一条地震道中提取振幅信息，并对原始地震数据、SeisGAN、RCAN-GAN 以及 ERFDN-GAN（本文方法）的单道振幅曲线进行对比，如图 8 所示。可以观察到，三种超分方法得到的振幅曲线在主要反射事件的位置上整体与原始地震数据保持一致，表明超分重建过程未破坏原始信号的基本结构特征。

相比之下，ERFDN-GAN 的振幅曲线在峰谷位置与原始数据的对应关系更为稳定，在弱反射区及振幅变化较为剧烈的区域未出现明显的异常放大或衰减现象，整体连续性较好。这表明，ERFDN-GAN 在增强细节信息的同时，能够较好地保持原始地震信号的振幅特征。




图 8 实测地震数据的单道振幅曲线对比

Fig. 8 Comparison of single-trace amplitude curves on real seismic data

进一步地，对原始地震数据、SeisGAN、RCAN-GAN 以及 ERFDN-GAN（本文方法）的结果进行了频谱对比分析，如图 9 所示。图 9 a 给出了未归一化的幅度谱对比结果，可以看到，各超分方法在中高频段均表现出较原始地震数据更高的频率能量，说明超分重建在一定程度上补偿了原始数据中衰减的高频成分，但不同方法之间的整体能量幅值仍存在差异。

为消除整体增益差异的影响，进一步对频谱进行了 RMS 归一化处理，结果如图 9 b 所示。归一化后，各方法在低频和中频段的频谱形态整体保持一致，而在高频段存在一定差异。其中，ERFDN-GAN 的高频能量变化相对平滑，未出现明显的异常放大或振荡现象，表明该方法在补偿高频信息的同时能够较好地维持频域结构的稳定性。

综上，频谱分析结果表明，ERFDN-GAN 在实测地震数据的超分重建过程中，能够在增强高频信息的同时保持与原始数据一致的整体频谱特征。

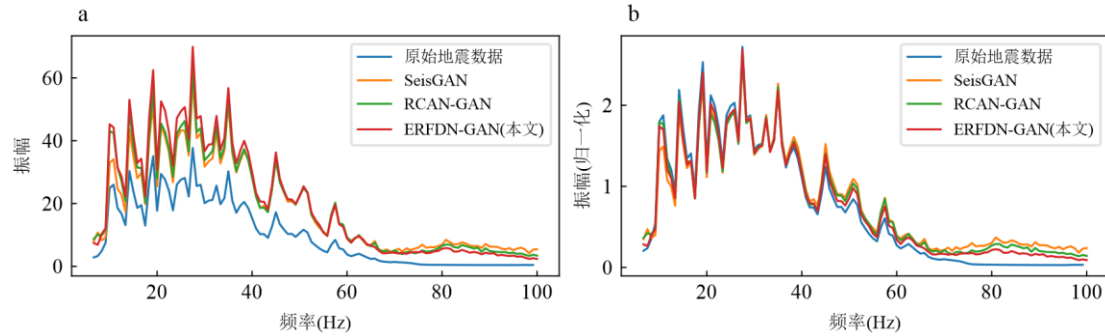


图 9 实测地震数据的频谱对比

Fig. 9 Comparison of frequency spectra on real seismic data

3 结论

针对地震图像超分辨率重建过程中训练不稳定及噪声干扰显著等问题，本文在 SeisGAN 框架下提出了一种增强型残差特征蒸馏生成对抗网络（ERFDN-GAN）。该方法以 RFDN 作为生成器基础结构，引入特征蒸馏机制以降低模型复杂度，并结合地震图像超分辨率任务特点进行针对性改进，在保证重建性能的同时实现了模型的轻量化设计。

在生成器结构设计方面，本文在残差特征蒸馏块中并行融合 CA 与 ESA，构建增强型残差特征蒸馏块（ERFDB）。该设计能够有效增强关键地质结构特征的表达能力，抑制强噪声干扰，并提升生成对抗训练过程的稳定性，从而提高复杂地质条件下地震图像重建结果的可靠性与可解释性。

实验结果表明，ERFDN-GAN 在合成地震数据集和实测地震数据上均取得了优于 SeisGAN 和 RCAN-GAN 的重建效果。在定量评价方面，该方法在 PSNR、SSIM 和 FD 等指标上整体表现最优；在定性分析中，其在断层边界、层理连续性及薄层结构等关键地质细节的恢复方面更加清晰完整。实测数据实验进一步表明，所提方法在振幅保持和频谱特性方面

均与原始数据保持良好一致，验证了其在复杂噪声背景下的稳定性与泛化能力。

此外，ERFDN-GAN 在生成器参数量和计算量方面均低于对比方法，表明该方法在提升地震图像重建质量的同时兼顾了计算效率，具备在大规模地震数据处理与智能化地学信息处理流程中应用的潜力。未来研究可进一步探索该模型在不同工区和复杂地质条件下的泛化能力，并将其与地震属性分析、断层解释和地层建模等下游任务深度融合，为多源地学数据的智能化挖掘与综合解释提供更高质量的地震数据基础，从而更好地服务于矿产预测与资源评价等应用场景。

References

- Bashir, S.M.A., Wang, Y., Khan, M., Niu, Y., 2021. A Comprehensive Review of Deep Learning-Based Single Image Super-Resolution. *PeerJ Computer Science*, 7: e621. doi: 10.7717/peerj-cs.621
- Cheng, Z.H., Yuan, Y.J., Liu, S., Fan, C.X., Li, Z.H., Li, Y., 2023. Application of Broadband Wavelet Deconvolution in Seismic Data Processing of Tight Reservoirs. *Oil Geophysical Prospecting*, 62(1): 119–129 doi: 10.3969/j.issn.1000-1441.2023.01.010 (in Chinese with English abstract).
- Dong, X., Lu, S., Lin, J., Zhang, S., Ren, K., Cheng, M., 2024a. Can Deep Learning Compensate for Sparse Shots in the Imaging Domain? A Potential Alternative for Reducing the Acquisition Cost of Seismic Data. *Geophysics*, 89(2): V119–V137. doi: 10.1190/geo2022-0711.1
- Dong, X., Wei, C., Zhong, T., Cheng, M., Dong, S., Li, F., 2024b. Seismic Data Reconstruction Based on a Multicascade Self-Guided Network. *Geophysics*, 89(3): V179–V195. doi: 10.1190/geo2022-0712.1
- Duan, J., Zhang, G., Li, X., Zhang, Y., Li, L., Liu, W., Ran, S., Cao, C., Tang, W., Yang, F., Luo, Y., 2024. Seismic Facies-Guided Trace-by-Trace High-Precision Strong and Weak Reflection Separation. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 1–17. doi: 10.1109/TGRS.2024.3386749
- Elgendy, N.H., Reda, M., Elmashaly, M.M., Raef, A., Al-Hashim, M.H., Barakat, M.Kh., 2025. Three-Dimensional Reservoir Modeling of the Pliocene Reservoir Based on Seismic Data Advances for New Prospect Assessment. *Marine Georesources & Geotechnology*, 43(7): 1281–1298. doi: 10.1080/1064119X.2024.2400689
- Hamida, A., Alfarraj, M., Al-Shuhail, A.A., Zummo, S.A., 2023. Facies-Guided Seismic Image Super-Resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 1–13. doi: 10.1109/TGRS.2023.3289151
- Jiang, C., Lü, Z. Y., Fang, L. H., 2024. Earthquake Detection Model Trained on Velocity and Acceleration Records and Its Application in Xinfengjiang Reservoir. *Earth Science*, 49(2): 469–479. doi: 10.3799/dqkx.2023.186 (in Chinese with English abstract).
- Kong, L., Wang, Y., Chang, D., Zhao, Y., 2022. Contour Enhanced Image Super-Resolution. *Journal of Visual Communication and Image Representation*, 89: 103659. doi: 10.1016/j.jvcir.2022.103659
- Li, F., Sun, W.Y., Wang, R., Li, J.P., 2025. Seismic Rock Physics Modeling and Key Reservoir Parameter Prediction of Ultra-Shallow Loose Sandstone Reservoirs in Ultra-Deepwater Areas. *Natural Gas Industry*, 45(6): 112–120. (in Chinese with English abstract)
- Li, J., Fang, F., Li, J., Mei, K., Zhang, G., 2021. MDCN: Multi-Scale Dense Cross Network for Image Super-Resolution. *IEEE Transactions on Circuits and Systems for Video Technology*, 31(7): 2547–2561. doi: 10.1109/TCSVT.2020.3027732
- Li, J., Wu, X., Hu, Z., 2022a. Deep Learning for Simultaneous Seismic Image Super-Resolution and Denoising. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 1–11. doi:

10.1109/TGRS.2021.3057857

- Li, X.G., Wu, X., 2020. New Advances of Artificial Intelligence in Seismic Data Processing and Interpretation: Insights from SEG Annual Meeting. *World Petroleum Industry*, 27(4): 27–35. (in Chinese with English abstract).
- Li, Y., Zhang, G., Du, H., Li, L., Qian, F., Duan, J., Zhan, Y., 2022b. Multiscale Adaptive Side Window Filtering and Its Application on Seismic Data. *IEEE Geoscience and Remote Sensing Letters*, 19: 1–5. doi: 10.1109/LGRS.2022.3147837
- Lin, L., Zhong, Z., Cai, C., Li, C., Zhang, H., 2024. SeisGAN: Improving Seismic Image Resolution and Reducing Random Noise Using a Generative Adversarial Network. *Mathematical Geosciences*, 56(4): 723–749. doi: 10.1007/s11004-023-10103-8
- Liu, J., Cao, J., Zhao, L., You, J., Li, H., 2024. Super-Resolution Reconstruction of Seismic Images Based on Deep Residual Channel Attention Mechanism. *IEEE Access*, 12: 149032–149044. doi: 10.1109/ACCESS.2024.3477984
- Liu, Y.M., Wei, H.J., Yuan, S., An, Z.W., 2022. Seismic Data Denoising Method Based on Convolutional Neural Networks. *Journal of Jilin University (Information Science Edition)*, 40(2): 231–239. (in Chinese with English abstract).
- Min, F., Wang, L., Pan, S., Song, G., 2023. D2UNet: Dual Decoder U-Net for Seismic Image Super-Resolution Reconstruction. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 1–13. doi: 10.1109/TGRS.2023.3264459
- Mousavi, S.M., Beroza, G.C., 2022. Deep-Learning Seismology. *Science*, 377(6607): eabm4470. doi: 10.1126/science.abm4470
- Mousavi, S.M., Beroza, G.C., 2023. Machine Learning in Earthquake Seismology. *Annual Review of Earth and Planetary Sciences*, 51(1): 105–129. doi: 10.1146/annurev-earth-071822-100323
- Ni, W.J., Liu, S.Y., Wang, L.P., Han, B.K., Sheng, S., 2023. Wavelet Shaping Deconvolution Method Based on Deep Learning. *Oil Geophysical Prospecting*, 58(6): 1313–1321. doi: 10.13810/j.cnki.issn.1000-7210.2023.06.002 (in Chinese with English abstract)
- Piao, J., Xiong, J., Zheng, D. C., Wang, L. T., Yun, N. D., Pei, W. L., Zhou, Y. J., Zhou, S. Y., 2025. Advances in Intelligent Processing of Seismic Data: Focal Mechanisms, Fault Zone Head Waves, and Dynamic Triggering Detection and Analysis. *Earth Science*, 51(1): 56-73. doi: 10.3799/dqkx.2025.252 (in Chinese with English abstract)
- Sun, Q.F., Xu, J.Y., Zhang, H.X., Duan, Y.X., Sun, Y.K., 2022. Random Noise Suppression and Super-Resolution Reconstruction Algorithm of Seismic Profile Based on GAN. *Journal of Petroleum Exploration and Production Technology*, 12(8): 2107–2119. doi: 10.1007/s13202-021-01447-0
- Wang, F., Yin, D., Song, R., 2023. Image Super-Resolution Using Only Low-Resolution Images. *The Visual Computer*, 39(10): 5069–5084. doi: 10.1007/s00371-022-02646-4
- Wu, H.B., Zhang, P.S., Xu, S.A., Huang, Y.P., Dong, S.H., Cheng, Y., Li, D.H., Zhang, S., Zhang, M., 2025. Development Status and Trends of Seismic Prediction and Evaluation Techniques for Coalbed Methane Reservoirs. *Coal Geology & Exploration*, 53(6): 233–245. doi: 10.12363/issn.1001-1986.25.04.0301 (in Chinese with English abstract).
- Wu, X., Geng, Z., Shi, Y., Pham, N., Fomel, S., Caumon, G., 2020. Building Realistic Structure Models to Train Convolutional Neural Networks for Seismic Structural Interpretation. *Geophysics*, 85(4): WA27–WA39. doi: 10.1190/geo2019-0375.1
- Wu, X., Liang, L., Shi, Y., Fomel, S., 2019. FaultSeg3D: Using Synthetic Data Sets to Train an End-to-End Convolutional Neural Network for 3D Seismic Fault Segmentation. *Geophysics*, 84(3): IM35–IM45. doi: 10.1190/geo2018-0646.1
- Yuan, Y., Li, Y., Zhou, S., 2020. Multichannel Statistical Broadband Wavelet Deconvolution for Improving Resolution of Seismic Signals. *IEEE Transactions on Geoscience and Remote Sensing*, 59(2): 1772–1783. doi: 10.1109/TGRS.2020.2997977

- Zeng, D., Xu, Q., Pan, S., Song, G., Min, F., 2023. Seismic Image Super-Resolution Reconstruction Through Deep Feature Mining Network. *Applied Intelligence*, 53(19): 21875–21890. doi: 10.1007/s10489-023-04660-y
- Zhang, J., Yin, X., Gu, Y., Zhou, Y., 2024. Sandstone Reservoir Rock Physics Modeling and Time-Lapse Seismic Analysis. *Journal of Applied Geophysics*, 222: 105318. doi: 10.1016/j.jappgeo.2024.105318
- Zhao, Y.S., Yang, P., Xu, H.Q., Huang, X.P., Nie, R., Yang, M.Q., 2023. Seismic High-Resolution Processing Method Based on Adjustable Gabor Wavelet Transform. *Oil Geophysical Prospecting*, 58(2): 345–350. doi: 10.13810/j.cnki.issn.1000-7210.2023.02.011 (in Chinese with English abstract)
- Zhong, T., Yang, F., Dong, X., Dong, S., Luo, Y., 2024. SHBGAN: Hybrid Bilateral Attention GAN for Seismic Image Super-Resolution Reconstruction. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 1–12. doi: 10.1109/TGRS.2024.3492142
- 程朝辉, 苑益军, 刘晟, 范承祥, 李子卉, 李影. 2023. 宽带子波反褶积方法在致密储层地震资料处理中的应用. *石油物探*, 62(1): 119-129
- 蒋策, 吕作勇, 房立华, 2024. 融合处理速度和加速度记录的地震检测模型及其在新丰江水库的应用. *地球科学*, 49(2): 469-479.
- 李芳, 孙万元, 汪锐, 李进鹏. 2025. 超深水超浅层疏松砂岩储层地震岩石物理建模及储层关键参数预测. *天然气工业*, 45(06): 112-120
- 李晓光, 吴潇. 2020. 从 SEG 年会看人工智能在地震数据处理与解释中的新进展. *世界石油工业*, 27(4): 27-35
- 刘玉敏, 魏海军, 袁硕, 安志伟. 2022. 基于卷积神经网络的地震数据去噪方法. *吉林大学学报(信息科学版)*, 40(2): 231-239
- 倪文军, 刘少勇, 王丽萍, 韩冰凯, 盛燊. 2023. 基于深度学习的子波整形反褶积方法. *石油地球物理勘探*, 58(6): 1313-1321
- 朴健, 熊健, 郑定昌, 汪龙潭, 运乃丹, 裴玮来, 周一剑, 周仕勇, 2025. 地震资料智能化处理进展: 震源机制、断层首波, 以及动态触发的识别与分析. *地球科学*, 51(1): 56-73.
- 吴海波, 张平松, 许时昂, 黄亚平, 董守华, 程彦, 李东会, 张生, 张敏. 2025. 煤层气储层地震预测与评价技术发展现状及趋势. *煤田地质与勘探*, 53(06): 233-245
- 赵桢松, 杨平, 许辉群, 黄鑫鹏, 聂荣, 杨梦琼. 2023. 基于可调因子 Gabor 小波变换的地震高分辨处理方法. *石油地球物理勘探*, 58(2): 345-350