arXiv:2602.01909v1 [physics.geo-ph] 2 Feb 2026

将先验从远偏移距传播至近偏移距：一种用于逐步恢复拖缆数据近偏移距的自监督扩散框架

预印本

Shijun Cheng
物理科学与工程学部 阿卜杜拉国王科技大学
图瓦勒 23955-6900，沙特阿拉伯
sjcheng.academic@gmail.com

Tariq Alkhalifah
物理科学与工程学部 阿卜杜拉国王科技大学
图瓦勒 23955-6900，沙特阿拉伯
tariq.alkhalifah@kaust.edu.sa

2026年2月3日

摘要

在海洋拖缆地震采集中，最近的水听器通常距离震源两百米，导致近偏移距道缺失，进而影响表面相关多次波压制、速度分析和全波形反演等关键处理流程。现有重建方法（如变换域插值）往往会产生运动学不一致和振幅失真，而监督式深度学习方法则需要完整的近偏移距真实数据，而这类数据在实际采集场景中无法获得。为解决这些限制，我们提出了一种自监督扩散框架，无需近偏移距参考数据即可重建缺失的近偏移距道。我们利用可用远偏移距剖面，通过单道步长提取重叠块来训练条件扩散模型，使其学习控制事件曲率、振幅变化和子波特征的依赖偏移距统计模式。在推理时，我们从最近的已记录偏移距开始，逐道向零偏移距递归外推，将学到的先验信息逐步从远偏移距传播至近偏移距。该生成式方法还通过集成采样提供不确定性估计，从而量化缺乏验证数据时的预测置信度。在合成数据集和野外数据集上开展的受控验证实验表明，与传统抛物线Radon变换基线方法相比，本方法的性能显著提升。在实际近偏移距缺口上的应用证明，即使无法进行真实数据验证，该方法在实际操作中仍切实可行。值得注意的是，尽管训练时仅使用远偏移距观测，重建波形仍保留了真实的振幅随偏移距变化趋势；不确定性图也能准确识别具有挑战性的外推区域，为从业者在下游处理决策中提供可操作的质量指标。

关键词 拖缆数据 · 近偏移距重建 · 生成式扩散模型 · 自监督 · 不确定性量化

1 引言

在海洋地震勘探中，拖缆采集凭借作业效率高、覆盖面积广以及多道能力强，已成为记录地下反射数据的常用方法 [Widmaieret al., 2019]。然而，气枪震源与第一个水听器组之间必须保持固定的横向间距，因此不可避免地无法记录真正的近偏移距道。近偏移距数据的缺失会损害关键处理流程。例如，表面相关多次波压制（SRME） [Verschuur etal., 1992]从根本上依赖近偏移距记录来构建震源位于检波器上方的采集几何，以实现精确的多维卷积；缺少这些记录会严重降低其效果 [Cheng et al., 2025a]。同样，初至层析成像、振幅随偏移距变化分析和全波形反演都能从小角度、近零

偏移距反射信息中获益，从而约束速度模型并提高速度分辨率 [Swan，2001，Alkhalifah，2014，Salaun et al.，2020，Jimenez-Tejero et al.， 2022]。因此，重建缺失的近偏移距数据对于恢复处理流程的完整性，以及提高后续地震成像与解释的准确性至关重要。

为缓解采集阶段的近偏移距缺口，现代测线采用了 TopSeis 等震源位于拖缆上方的几何布局，其中气枪阵列直接拖曳于拖缆上方，从而无需额外设备即可采集真正的零偏移距和近偏移距道。当无法实施或未能完整实施采集调整时，则采用基于处理的重建方法。最基础的流程是先对一次波进行常规正常时差拉平，将最近的已记录地震道复制到每个缺失的近偏移距位置，然后反向执行正常时差拉伸以恢复真实几何布局 [Curry and Shan, 2010, Cheng et al., 2025a]。更先进的预测误差滤波器（PEF）方法利用中偏移距和远偏移距数据估计非平稳滤波器，以外推缺失的近偏移距样点，同时保持振幅 [Curry and Shan, 2010]。变换域插值方法，例如利用频率-空间域局部线性的 F-X预测滤波，以及将能量相干地映射至零偏移距区域的双曲拉东映射，可实现高保真度的缺口填补，并获得准确的运动学特征 [Kabir and Verschuur, 1995, Sacchi and Ulrych, 1997, Trad et al., 2002, Xu et al., 2018]。最后，基于多次波的重建利用表面相关多次波消除（SRME），通过对已记录的一次波和多次波进行卷积来合成伪一次波近偏移距道，从而有效生成虚拟震源-检波器测线 [Van Groenestijn and Verschuur, 2009a,b, Lopez and Verschuur, 2015, Zhang and Verschuur, 2019]。实际应用中，通常采用混合流程，将最近道或 PEF 与变换域及基于多次波的算子结合，以优化计算效率、振幅一致性和运动学精度，然后再进行速度分析和成像。

近年来，深度学习的进展为地震道重建引入了数据驱动的替代方法，利用深度神经网络学习从不完整波场到完整波场的复杂映射 [Jia 等人，2017，Wang 等人，2019，Harsuko 和 Alkhalifah，2022，Cheng 等人，2023，Mousavi 等人， 2024]。最初为图像分割设计的 U-Net架构 [Ronneberger 等人， 2015], 已被用于插值缺失地震道，通过在多个尺度上利用层次化特征提取和空间上下文信息 [Park 等人，2019，Chai 等人，2020，Park 等人，2021，Fang 等人，2021a，He 等人，2021，Cheng 等人， 2024]。长短期记忆网络能够捕捉地震序列中的时间依赖关系，从而沿偏移距轴或时间轴对缺失样本进行相干预测 [Yoon 等人， 2020]。生成对抗网络（GANs）通过训练生成器-判别器对，展现出合成逼真地震数据的能力，进而恢复缺失道，同时增强高频成分和结构保真度 [Oliveira 等人，2018，Chang 等人，2020，Kaur 等人，2021，Wei 等人，2021a]。在拖缆采集近偏移距重建领域，监督式深度学习方法展现出良好前景：通过使用配对数据集进行训练，将完整的合成剖面进行人工退化，以模拟采集缺口 [Qu 等人，2021，Huff 等人， 2024]。与传统信号处理技术相比，这些方法通常能够取得更高的重建质量，尤其适用于处理复杂的地下结构和含噪的实际采集条件。

尽管取得了成功，监督学习方法仍面临一个根本性的泛化挑战：在合成数据集上训练的模型往往无法适应野外数据 [Alkhalifah 等人， 2022]。有标签训练对的匮乏进一步限制了这些方法的实际应用，因为在真实的拖缆采集中，完整真实数据鲜少可得。为解决这一局限，自监督学习（SSL）范式应运而生，成为一种很有前景的替代方案，使模型无需完整参考数据，便能直接从不完整观测数据中学习重建映射。据我们所知，目前仅有两种针对拖缆数据近偏移距重建的自监督方法见诸报道。Wang 等人 [2022] 提出了一种单阶段自监督框架，通过利用格林函数的空间互易性，并借助旋转截断流程生成近偏移距伪标签，来重建规律性缺失炮和近偏移距数据。该方法无需合成数据预训练，直接从野外数据中学习，从而能够同时恢复缺失炮和近偏移距缺口。然而，该策略要求旋转后近偏移距倾角近似为零，而选择合适的旋转角并非易事。旋转不准确可能扭曲反射几何，并显著降低重建性能。相比之下，Park 等人 [2024] 专门针对近偏移距外推，提出了两阶段自监督学习范式。其方法首先在一个包含人工构造近偏移距缺口的多样化合成数据集上预训练 U-Net3+（全尺度连接 UNet）模型，以学习通用的近偏移距表征；随后通过自监督迁移学习使模型适应野外数据，其中通过遮蔽并恢复最近已记录偏移距来生成伪标签。在推理阶段，适配后的模型通过基于图块的预测外推实际的近偏移距缺口。然而，这种两阶段策略的成功高度依赖于预训练所用合成数据的多样性和代表性，而且基于图块的推理可能破坏长程结构连续性，导致外推近偏移距区域时产生拼接伪影。

在本研究中，我们提出了一种用于拖缆数据近偏移距重建的自监督生成扩散模型（SSGDM），以解决上述局限。我们方法的核心创新在于递归推理策略：我们使用可用的远偏移距数据训练条件扩散模型，然后逐步

从最近的已记录偏移距开始，逐道向缺失的近偏移距区域外推。训练过程中，我们通过提取横向仅相差一道的重叠区块对，利用已记录远偏移距剖面中的空间冗余。更接近零偏移距的数据块作为目标分布 x_0，而较远的数据块则提供条件上下文 y，使模型能够学习条件分布 $p(x_0|y)$。这种训练范式使扩散模型能够捕捉事件曲率、振幅变化和子波特征从远偏移距向近偏移距演变时所遵循的统计模式。在推理时，我们从最近的可用道开始重建，并以此前重建的（或已记录的）偏移距为条件，迭代预测后续每一条缺失道，从而以符合物理规律的方式，将学得的先验信息从远偏移距逐步传递至近偏移距。至关重要的是，这种递归表述无需完整的真实数据，同时自然适应填补近偏移距缺口所需的定向外推。此外，扩散模型的概率特性还可通过集成采样实现不确定性量化：通过生成多个缺失近偏移距剖面的实现，我们能够评估重建置信度，并识别外推不确定性较高的区域。我们在合成示例和两个海洋实测数据集上验证了所提方法，结果表明，该方法具有更高的重建保真度，并能提供有意义的不确定性估计。

2 方法

2.1 用于地震插值的条件扩散模型

去噪扩散概率模型（DDPMs）是一类生成模型，它们通过学习逆转逐渐加噪的过程来合成数据样本 [Ho 等人，2020，Nichol 和 Dhariwal，2021]。前向扩散过程会逐步破坏一个干净数据样本 $x_0 \sim q（x_0）$，在 T 个时间步内按照预定义的方差调度添加高斯噪声 $\{\beta_t\}_{t=1}^T$：

$$q(x_t|x_{t-1}) = \mathcal{N}(x_t; \sqrt{1-\beta_t}x_{t-1}, \beta_t\mathbf{I}), \tag{1}$$

其中，x_t 表示时间步 t处的含噪样本。利用重参数化技巧，可以在任意时间步 t直接对前向过程进行采样：

$$x_t = \sqrt{\bar{\alpha}_t}x_0 + \sqrt{1-\bar{\alpha}_t}\epsilon, \quad \epsilon \sim \mathcal{N}(0, \mathbf{I}), \tag{2}$$

其中 $\alpha_t = 1-\beta_t$ 一个和 $\bar{\alpha}_t = \prod_{s=1}^{t}\alpha_s$。随着 t 增加，x_t 会逐渐失去结构，并收敛为纯高斯 n 噪声，其中 $t \to T$。

反向扩散过程通过迭代去噪，学习将 $x_T \sim \mathcal{N}(0, \mathbf{I})$ 恢复为来自数据分布的样本$q(x_0)$。这可以通过训练神经网络（NN）来预测添加的噪声 ϵ 或直接预测干净数据 x_0 来实现。近期地震处理研究表明，与噪声预测 x_0 相比，直接预测 [（Cheng 等人，2025b]）可获得更高的重建质量。基于这一发现，我们采用x_0预测形式，其中 NN $f_\theta(x_t, t)$ 经过训练，可从含噪观测中预测干净数据：

$$\mathcal{L}_{\text{simple}} = \mathbb{E}_{t,x_0,\epsilon}\left[\|x_0 - f_\theta(x_t, t)\|^2\right], \tag{3}$$

其中，x_t 通过向 x_0 添加噪声得到，具体依据公式2。给定预测值$\hat{}x_0 = f_\theta(x_t, t)$，反向转移可表示为：

$$p_\theta(x_{t-1}|x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \sigma_t^2\mathbf{I}), \tag{4}$$

其中，预测均值的计算方式为：

$$\mu_\theta(x_t, t) = \frac{\sqrt{\bar{\alpha}_{t-1}}\beta_t}{1-\bar{\alpha}_t}\hat{x}_0 + \frac{\sqrt{\alpha_t}(1-\bar{\alpha}_{t-1})}{1-\bar{\alpha}_t}x_t. \tag{5}$$

在地震数据插值中，条件扩散模型已被用于重建缺失道，其方法是根据可用观测对生成过程进行条件约束 [Durall 等人，2023，Liu 和 Ma，2024，Wang 等人，2025]。具体而言，令 x_0 表示完整目标数据（包括观测道和缺失道），并令 y表示部分观测数据（缺失道置零或屏蔽）。条件扩散模型通过训练网络 x_0 以 y 为条件生成 $f_\theta(x_t, y, t)$，根据噪声版本 x_t 和条件上下文预测完整干净数据 y：

$$\mathcal{L}_{\text{cond}} = \mathbb{E}_{t,x_0,y,\epsilon}\left[\|x_0 - f_\theta(x_t, y, t)\|^2\right]. \tag{6}$$

在训练过程中，y 通常会沿通道维度与 x_t 拼接后输入去噪网络，使模型能够学习条件分布 $p(x_0|y)$ [Liu 和 Ma，2024]。在推理时，去噪

扩散模型通过迭代将随机噪声细化为重建后的完整剖面，使其与观测道 y 保持一致。

然而，这种监督训练范式需要获取完整的真实数据 x_0（即没有缺失道的地震剖面），并将其与人工退化后的版本配对 y（通过合成移除地震道来模拟采集缺口）。在实际应用中，由于震源与检波器之间存在物理间距，完整的近偏移距数据本就无法获取，因此监督训练难以实现。此外，基于合成数据退化模式训练的模型，往往无法泛化到野外数据中遇到的特定采集几何和地下复杂性。因此，如何开发一种能够直接从不完整观测数据中学习重建映射的自监督学习框架，仍是近偏移距重建面临的一项关键挑战。

2.2 用于近偏移距重建的自监督条件扩散模型

我们的训练策略利用记录到的远偏移距剖面中的空间冗余，在无需完整近偏移距真实数据的情况下构建自监督训练样本对。令 $\mathbf{D} \in \mathbb{R}^{N_s \times N_t \times N_r}$ 表示与某种拖缆几何相对应的完整目标海洋地震数据集，其中 N_s、N_t 和 N_r 分别表示炮数、时间采样点数和检波器数。在这一完整情形下，每个炮集 $\mathbf{D}_i \in \mathbb{R}^{N_t \times N_r} (i = 1, \ldots, N_s)$ 包含来自 N_r 个检波器的记录，并按照与震源的偏移距递增顺序排列。由于拖缆采集中震源与检波器间距固定，我们假设最前面的 N_m 个近偏移距道缺失，且仅记录了远偏移距道 $\{N_m + 1, N_m + 2, \ldots, N_r\}$。令 $\mathbf{D}_{\text{obs}} \in \mathbb{R}^{N_s \times N_t \times (N_r - N_m)}$ 表示实际记录的观测数据，其中仅包含记录到的远偏移距道；令 $\mathbf{D}_{\text{miss}} \in \mathbb{R}^{N_s \times N_t \times N_m}$ 表示我们要重建的缺失近偏移距区域。

每次训练迭代中，我们从$\mathbf{D}_{\text{obs}}$中随机选取一个炮集，并提取两个宽度为W条地震道的重叠数据块。具体而言，令 $x_0 \in \mathbb{R}^{N_t \times W}$表示由索引为 $[r_i, r_i + W - 1]$的地震道组成的目标块，令$y \in \mathbb{R}^{N_t \times W}$表示由索引为 $[r_i + 1, r_i + W]$的地震道组成的条件块。因此，这两个数据块在横向上仅相差一条地震道，其中 x_0 的位置比 y更靠近零偏移距：

$$x_0 = \mathbf{D}_{\text{obs}}(j, :, r_i : r_i + W - 1), \quad y = \mathbf{D}_{\text{obs}}(j, :, r_i + 1 : r_i + W), \tag{7}$$

其中，j是从 $\{1, \ldots, N_s\}$中随机抽取的炮索引，r_i从范围 $\{N_m + 1, \ldots, N_r - W\}$ 内均匀抽取，以确保两个数据块均完全位于记录到的远偏移距观测范围内。

给定训练对(x_0, y)，我们通过对 x_0 在随机抽取的时间步 $t \sim \text{Uniform}(1, T)$应用前向扩散过程（公式2），合成其噪声版本 x_t：

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t}\epsilon, \quad \epsilon \sim \mathcal{N}(0, \mathbf{I}). \tag{8}$$

随后训练条件扩散模型 $f_\theta(x_t, y, t)$，使其根据带噪输入 x_t 和条件上下文 y 预测干净目标 x_0。将条件块 y 沿通道维度与 x_t 拼接，形成大小为 $\mathbb{R}^{2 \times N_t \times W}$ 的输入，再由基于 U-Net 架构、包含二维卷积层的神经网络进行处理。训练损失定义为真实目标与预测重建结果之间的均方误差（MSE）：

$$\mathcal{L} = \mathbb{E}_{j, r_i, t, \epsilon} \left[\|x_0 - f_\theta(x_t, y, t)\|_2^2 \right]. \tag{9}$$

通过在整个训练数据集上最小化该损失（训练数据集由可用实测数据的窗口构成），模型能够学习捕捉地震事件随偏移距变化的统计依赖关系。关键在于，这种训练范式不需要缺失的近偏移距区域中的任何数据，而仅依赖实测远偏移距道的自洽性。采用单道步长的重叠补丁设计，可明确训练模型执行推理时所需的精确外推任务。

2.3 使用 DDIM 采样进行递归推断

在推理时间，我们从最近的已记录地震道开始，逐道依次重建缺失的近偏移距道，并逐步向零偏移距外推。令 $r_{\text{start}} = N_m + 1$ 表示第一条已记录地震道的索引（即最靠近缺失区域的地震道），并令 $r_k = N_m$，$N_m - 1$，.....，1 按降序排列缺失道索引。

为重建索引为 r_k 的地震道，我们通过组合从索引 $r_k + 1$ 开始的 W 条连续地震道，构造条件上下文 $y_k \in \mathbb{R}^{N_t \times W}$：

$$y_k = [\hat{x}_{r_k+1}, \hat{x}_{r_k+2}, \ldots, \hat{x}_{r_k+W}], \tag{10}$$

其中，$\hat{x}_{r_k+i}$ 表示 t 索引为 $r_k + i$ 的重建道（如果 $r_k + i < r_{\text{start}}$），或已记录地震道（如果 $r_k + i \geq r_{\text{start}}$）。

算法 1 通过 DDIM 采样递归重建近偏移距

要求： 观测到的远偏移距数据 $\mathbf{D}_{\text{obs}}$、训练好的模型 f_θ、图块宽度 W、DDIM 步数 S、缺失道数量 N_m
确保： 重建的近偏移距剖面 $\{\hat{x}_1, \hat{x}_2, \ldots, \hat{x}_{N_m}\}$
令 $\{t_1, t_2, \ldots, t_S\}$ 为均匀间隔的 DDIM 时间步，其中 $t_S = T$ 和 $t_0 = 0$
初始化 $r_{\text{start}} \leftarrow N_m + 1$ ▷ 首个已记录地震道的索引
初始化重建道：$\hat{x}_i \leftarrow \mathbf{D}_{\text{obs}}(:, i)$，用于 $i \geq r_{\text{start}}$ ▷ 复制记录道
对于 $k = N_m, N_m - 1, \ldots, 1$ **do** ▷ 从远偏移距迭代到近偏移距
  构建条件上下文：$y_k \leftarrow [\hat{x}_{k+1}, \hat{x}_{k+2}, \ldots, \hat{x}_{k+W}]$
  初始化随机噪声：$x_T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$，形状为 $\mathbb{R}^{N_t \times W}$ ▷ $t_S = T$(最大噪声)
  对于 $s = S, S-1, \ldots, 1$ **do** ▷ DDIM反向扩散
    预测干净数据：$\hat{x}_0 \leftarrow f_\theta(x_{t_s}, y_k, t_s)$
    更新：$x_{t_{s-1}} \leftarrow \sqrt{\bar{\alpha}_{t_{s-1}}}\hat{x}_0 + \sqrt{1 - \bar{\alpha}_{t_{s-1}}} \cdot \dfrac{x_{t_s} - \sqrt{\bar{\alpha}_{t_s}}\hat{x}_0}{\sqrt{1 - \bar{\alpha}_{t_s}}}$
  结束循环
  提取重建道：$\hat{x}_k \leftarrow \hat{x}_0(:, 1)$ ▷ 输出的第一道
循环结束
返回 $\{\hat{x}_1, \hat{x}_2, \ldots, \hat{x}_{N_m}\}$

为了加快采样过程，我们采用去噪扩散隐式模型（DDIM）[Song 等人， 2020], 该模型通过直接计算反向过程中的大步长转换，实现确定性且更快速的采样。DDIM 从完整的训练时间表中 S时间步 $\{t_1, t_2, \ldots, t_S\}$ 均匀选取一个子序列 $\{0, 1, \ldots, T\}$，其中 $t_S = T$对应纯高斯噪声，而 $t_0 = 0$ 对应干净数据。采用 $S \ll T$（例如， $S = 50$ 用于$T = 1000$）时，DDIM 将函数评估次数从 T减少到 S，同时保持高质量的生成效果。
我们从纯高斯噪声 $x_T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ 开始采样，其形状为 $\mathbb{R}^{N_t \times W}$，表示扩散时间 $t_S = T$处的最大噪声水平。将该噪声样本与条件上下文 y_k 沿通道维度拼接，形成形状为 $\mathbb{R}^{2 \times N_t \times W}$的网络输入。在每个反向扩散步 $s = S, S-1, \ldots, 1$，给定扩散时间 t_s处的含噪样本 x_{t_s}，我们预测干净数据 $\hat{x}_0 = f_\theta(x_{t_s}, y_k, t_s)$，并使用以下公式更新至下一个扩散时间$t_{s-1}$：

$$x_{t_{s-1}} = \sqrt{\bar{\alpha}_{t_{s-1}}}\hat{x}_0 + \sqrt{1 - \bar{\alpha}_{t_{s-1}}} \cdot \frac{x_{t_s} - \sqrt{\bar{\alpha}_{t_s}}\hat{x}_0}{\sqrt{1 - \bar{\alpha}_{t_s}}}. \tag{11}$$

经过 S 个反向扩散步后，我们得到最终重建结果 $\hat{x}_0 \in \mathbb{R}^{N_t \times W}$，其空间范围与条件上下文相同 y_k，但向零偏移距方向移动了一道。具体而言，$\hat{x}_0$ 由索引$[r_k, r_k + 1, \ldots, r_k + W - 1]$至的地震道组成，实际上舍弃了最远的地震道 $\hat{x}_{r_k+W}$，并从 y_k生成新的近偏移距地震道 $\hat{x}_{r_k}$。我们提取重建块中的第一道，并将其纳入下一次迭代的条件上下文，即 $y_k \leftarrow \hat{x}_0 = [\hat{x}_{r_k}, \hat{x}_{r_k+1}, \ldots, \hat{x}_{r_k+W-1}]$。该递归过程持续进行，直至所有缺失道都重建至零偏移距。完整的递归推理过程总结于算法 1。
这种递归形式确保每条新重建的道都以最新可用的偏移距信息为条件，从而维持重建近偏移距剖面中的运动学与振幅一致性。至关重要的是，预测块 $\hat{x}_0$ 与条件上下文 y_k 之间相差一道，这与训练策略相呼应：目标块 x_0 和条件块 y 也相差一道，从而确保训练与推理过程完全对齐。此外，这种单通道增量策略有助于实现平滑、渐进的外推，因为地震振幅、旅行时和波形在相邻偏移距之间连续变化，而非突变，从而降低递归传播过程中重建误差累积的风险。

2.4 通过集成采样量化不确定性

基于扩散的框架的一项关键优势是能够自然地量化重建不确定性。与只能给出单点估计的确定性神经网络不同，扩散模型会从学习到的条件分布 $p(x_0|y)$ 中生成样本，使我们能够评估重建结果的变化程度及其置信度。

对于每个缺失道，我们使用不同的随机噪声初始化$x_{t_S}^{(m)} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$进行 M 次独立的 DDIM 采样 $m = 1, \ldots, M$，生成实现集合 $\{\hat{x}_0^{(m)}\}_{m=1}^{M}$。平均重建为

计算如下：

$$\bar{x}_0 = \frac{1}{M}\sum_{m=1}^{M} \hat{x}_0^{(m)}, \tag{12}$$

逐点标准差提供逐像素不确定性图：

$$\sigma(x_0) = \sqrt{\frac{1}{M-1}\sum_{m=1}^{M}\left(\hat{x}_0^{(m)} - \bar{x}_0\right)^2}. \tag{13}$$

较高的标准差值标示出模型预测不确定性较大的区域，这些区域通常对应于需要基于可用条件数据进行困难外推的部分。这类不确定性估计对于地震处理工作流程中的质量控制和风险评估尤其有用，因为它们能够指出基于现有数据重建结果可能不够可靠的地震道或同相轴，因此可能需要进一步估计或采用其他处理策略。

2.5 网络架构

条件扩散模型采用改编自改进型 DDPM 的 U-Net 架构 [Nichol 和 Dhariwal，2021]。该网络接受一个由带噪目标块 x_t 和条件块 y拼接而成的双通道输入，并输出单通道预测 $\hat{}x_0$。U-Net 由包含五个分辨率尺度的编码器-解码器结构组成。编码器通过步幅卷积逐步对输入进行下采样，并应用通道倍增系数 (1、2、4、8、16)，将基础维度设为 64 道，从而在各级依次生成包含 64、128、256、512 和 1024 道的特征图。每个尺度包含两个残差块，并通过学习得到的缩放-偏移参数进行自适应组归一化，以实现时间步条件化。解码器与编码器结构相对应，通过转置卷积对特征进行上采样。对称的跳跃连接会在每个尺度直接拼接编码器特征与对应的解码器特征，使网络能够恢复下采样过程中丢失的细粒度空间细节。在编码器和解码器路径的第三和第四个尺度（下采样因子为 8 和 16）中，均加入了具有 4 个头的自注意力层，以捕获长程空间相关性。

3 受控验证实验

为评估所提出的自监督框架在受控条件下的性能，我们在具有近偏移距真实地震道的合成和海洋地震实测数据集上开展了全面实验，以进行定量评估。具体而言，我们从原本包含这些地震道的数据集中人为移除10条近偏移距道，在剩余的不完整数据上训练模型，并以已知真实值为基准测量重建精度。这种受控验证策略能够与基线方法进行严格的定量比较，同时深入分析重建保真度、振幅保持、相位一致性和频谱特征。我们将我们的方法与抛物线Radon变换（PRT）进行比较。PRT是地震道插值中广泛采用的基准方法，从而展示我们方法的优势。

关键在于，尽管真实数据用于事后评估，但训练过程本身以自监督方式进行，无需访问完整的近偏移距参考数据，从而反映了拖缆采集的实际约束。在这些受控验证实验之后，我们将在下一节展示其在实际近偏移距缺口中的实际部署；在这种情况下，真实值验证在本质上是不可能的。

3.1 合成数据

合成数据集通过声学有限差分波动方程模拟，在开源二维 SEAM（SEG高级建模）速度模型上进行正演模拟生成。我们采用主频为 10 Hz 的 Ricker子波作为震源子波。为模拟真实的拖缆几何，我们采用单侧检波器配置。共模拟 882 炮，炮间距为 10 m。每个炮集包含 320 个检波器，间距为 10 m；数据采样为 1200 个时间步，时间采样间隔为 4 ms，因此最大记录时间约为 4.8 s。全部 882 个炮集构成我们的训练数据集。为模拟拖缆采集固有的近偏移距缺口，我们从所有炮集中移除前 10 个近偏移距道，形成 100 米的缺口。

训练时，横向补丁宽度 W 设为 32 道地震道（见公式 7），并从每个炮集的可用远偏移距区域随机提取数据块。模型的批量大小为 16，固定学习率为 1×10^{-4}，并使用 AdamW 优化器进行训练。训练在单块 NVIDIA RTX 8000 上进行，迭代次数为 20000

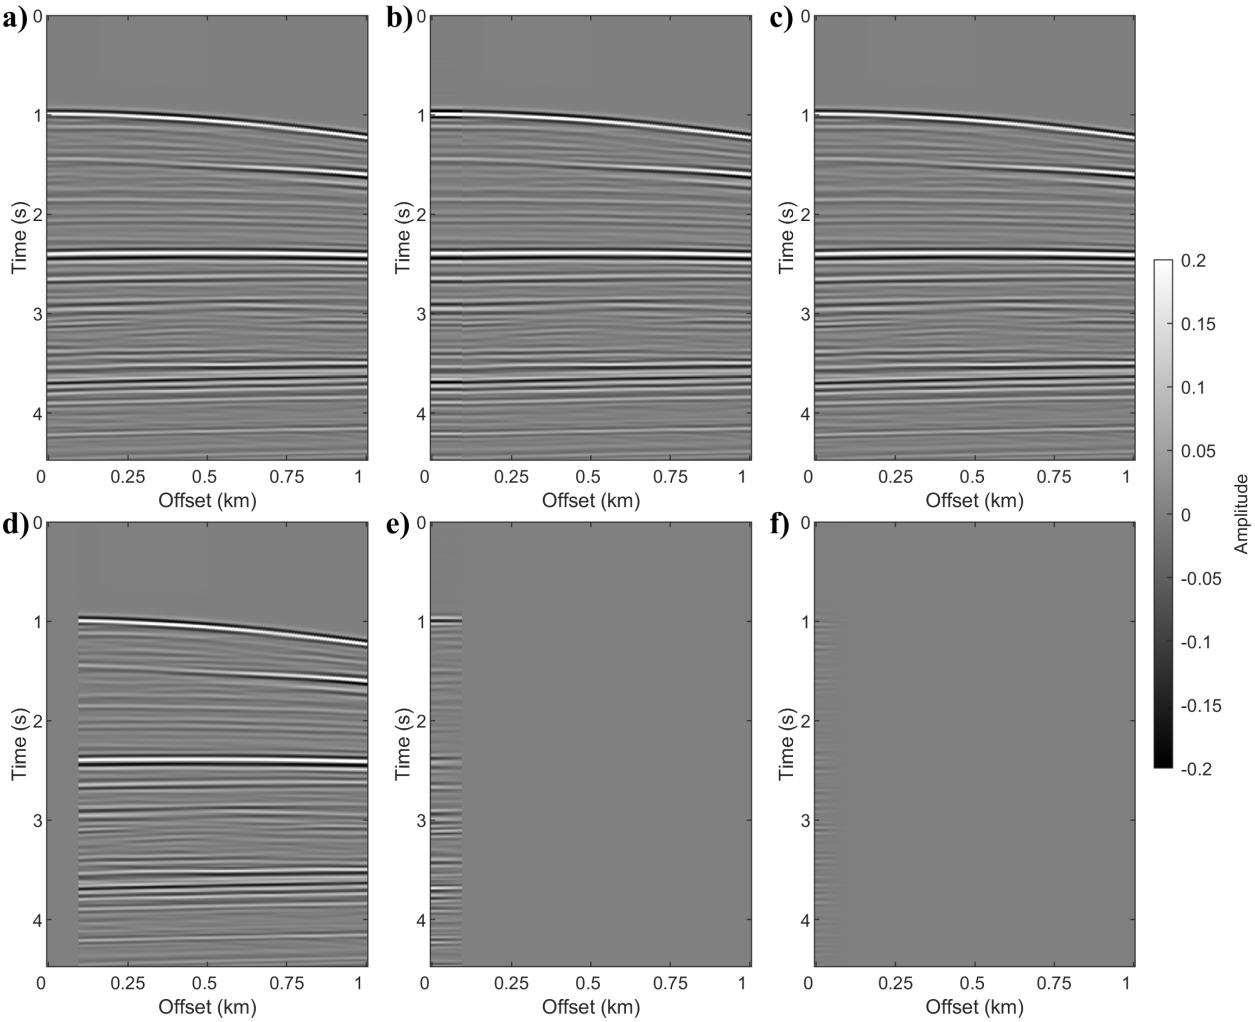


图 1：合成数据上的近偏移距重建结果对比。图中显示最接近零偏移距的 101 道（0–1 km）。(a) 完整的真实炮集。(b) PRT 和 (c) 我们的方法重建的数据。(d) 移除前 10 道近偏移距道后的不完整观测数据。(e) PRT 和 (f) 我们的方法的重建误差（与真实值的差异）。

GPU，耗时约 7 小时。扩散过程在训练期间采用 $T = 1000$ 个时间步，推理时则使用 $S = 10$ 步的 DDIM 采样，以提高计算效率。

训练完成后，我们从数据集中选取一个炮集来评估重建性能。图1 对比了 PRT 和我们的方法的重建结果，重点展示最接近零偏移距的 101 道（偏移距约为 0–1 km），以突出近偏移距重建质量。(a) 显示这 101 道的完整真实数据，作为参考。(d) 显示移除前 10 道近偏移距道后的不完整观测数据，这也是两种方法的输入。(b) 和 (c) 分别展示 PRT 和我们的方法重建得到的炮集。(e) 和 (f) 展示相应的重建误差，即重建数据与真实数据之差。目视检查表明，与 PRT 相比，我们的方法实现了显著更高的插值精度，能够有效恢复缺失的近偏移距道，并提升运动学与振幅一致性。值得注意的是，PRT 插值道存在明显的相位错位，且在重建道与记录道的交界处出现突变；而我们的方法则实现了平滑、连续的过渡，使整个偏移距范围内的地震事件均能良好对齐。

为进一步评估重建数据的谱特征，我们计算了频率-波数（F-K）谱，并将结果展示在图2中。(a) 图展示了完整真实数据的 F-K 谱。(b) 图和 (c) 图分别展示了通过 PRT 和我们的方法获得的重建数据的 F-K 谱，

而 (d) 图和 (e) 图则展示了相应的频谱误差（与真实频谱的差异）。我们的方法生成的 F-K 谱与真实值高度吻合，误差图中的残余能量极少，表明其出色地保留了地震波场的频谱内容和空间相干性。相比之下，PRT 会引入明显的频谱伪影，并且无法准确恢复与近偏移距道相关的低波数分量，这一点从 (d) 图中较大的残余能量可以看出。

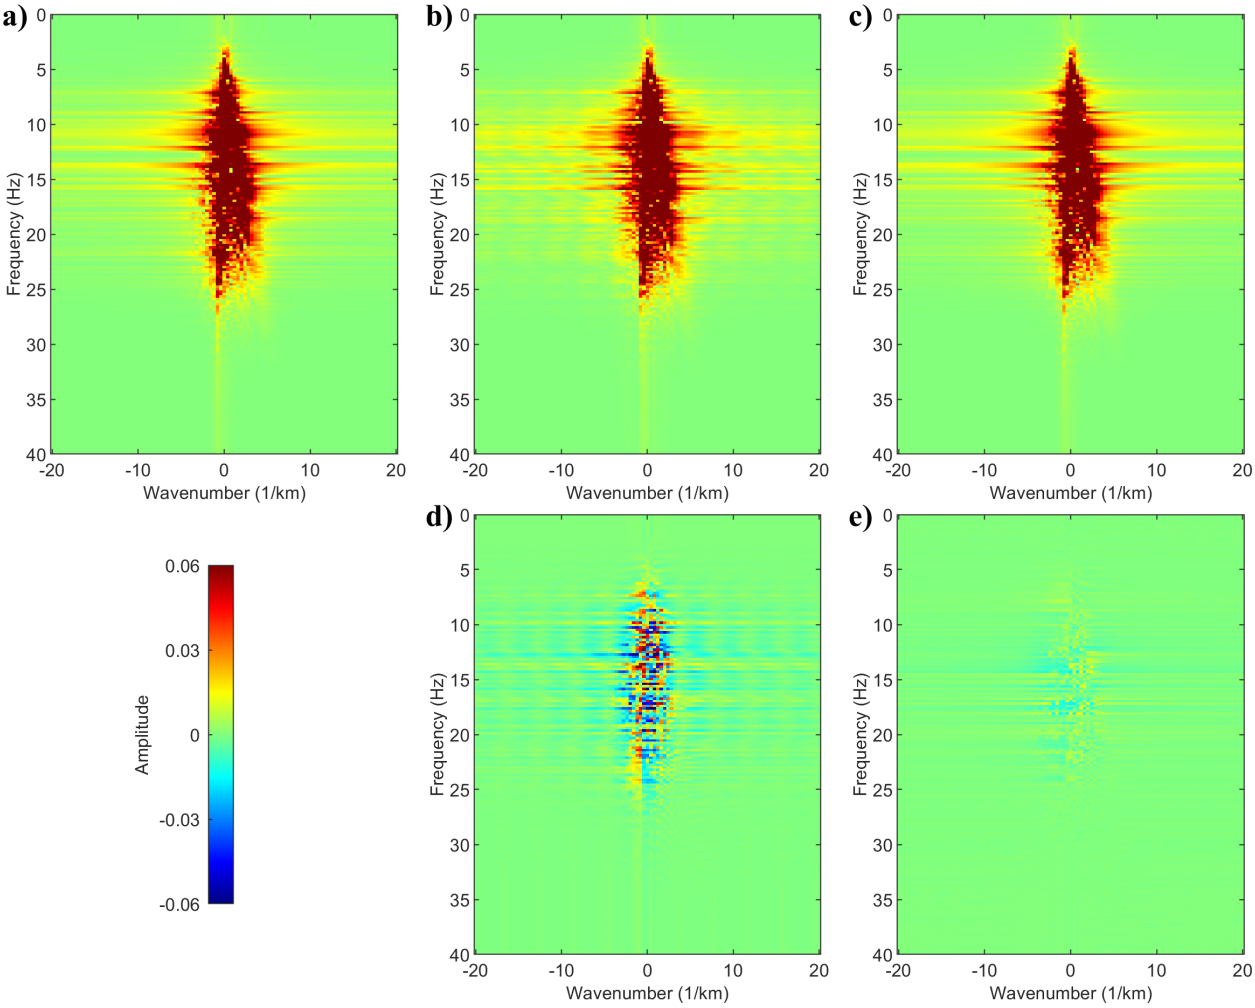


图 2：合成数据上近偏移距重建的频率–波数（F-K）谱对比。（a）完整真实数据的 F-K 谱。与（b）PRT 和（c）我们的方法相对应的重建数据的 F-K 谱。（d）PRT 和（e）我们的方法的谱误差（与真实值的差异）。

为了进行更详细的波形级对比，我们从重建的近偏移距剖面中提取五条单独的地震道，并在图 3 中将其与相应的真实道进行比较。面板（a1）–（a5）展示了由 PRT 获得的第 10、7、5、3 和 1 条重建道（从远偏移距到近偏移距）及其对应的真实波形，而面板（b1）–（b5）则展示了我们的方法对应的比较结果。在每个面板中，蓝色实线表示真实波形，橙色虚线表示重建波形。PRT 在所有地震道上均表现出明显的振幅差异，即使是最接近可用远偏移距数据的第 10 条道也不例外。随着偏移距减小（趋近于零偏移距），相位错位日益明显，例如第 3 条和第 1 条道，其中可以观察到显著误差。这些相位误差会严重降低后续处理步骤的效果，包括速度分析和全波形反演。相比之下，我们的方法在所有地震道上都实现了出色的波形匹配。对于第 10 条至第 5 条道，重建波形在振幅和相位上都几乎与真实值完美对齐。即使对于最近偏移距的地震道（第 3 条和第 1 条），尽管此处的外推不确定性最高，我们的方法仍保持了极高的保真度，仅在少量同相轴上出现轻微振幅偏差和可忽略的相位误差。

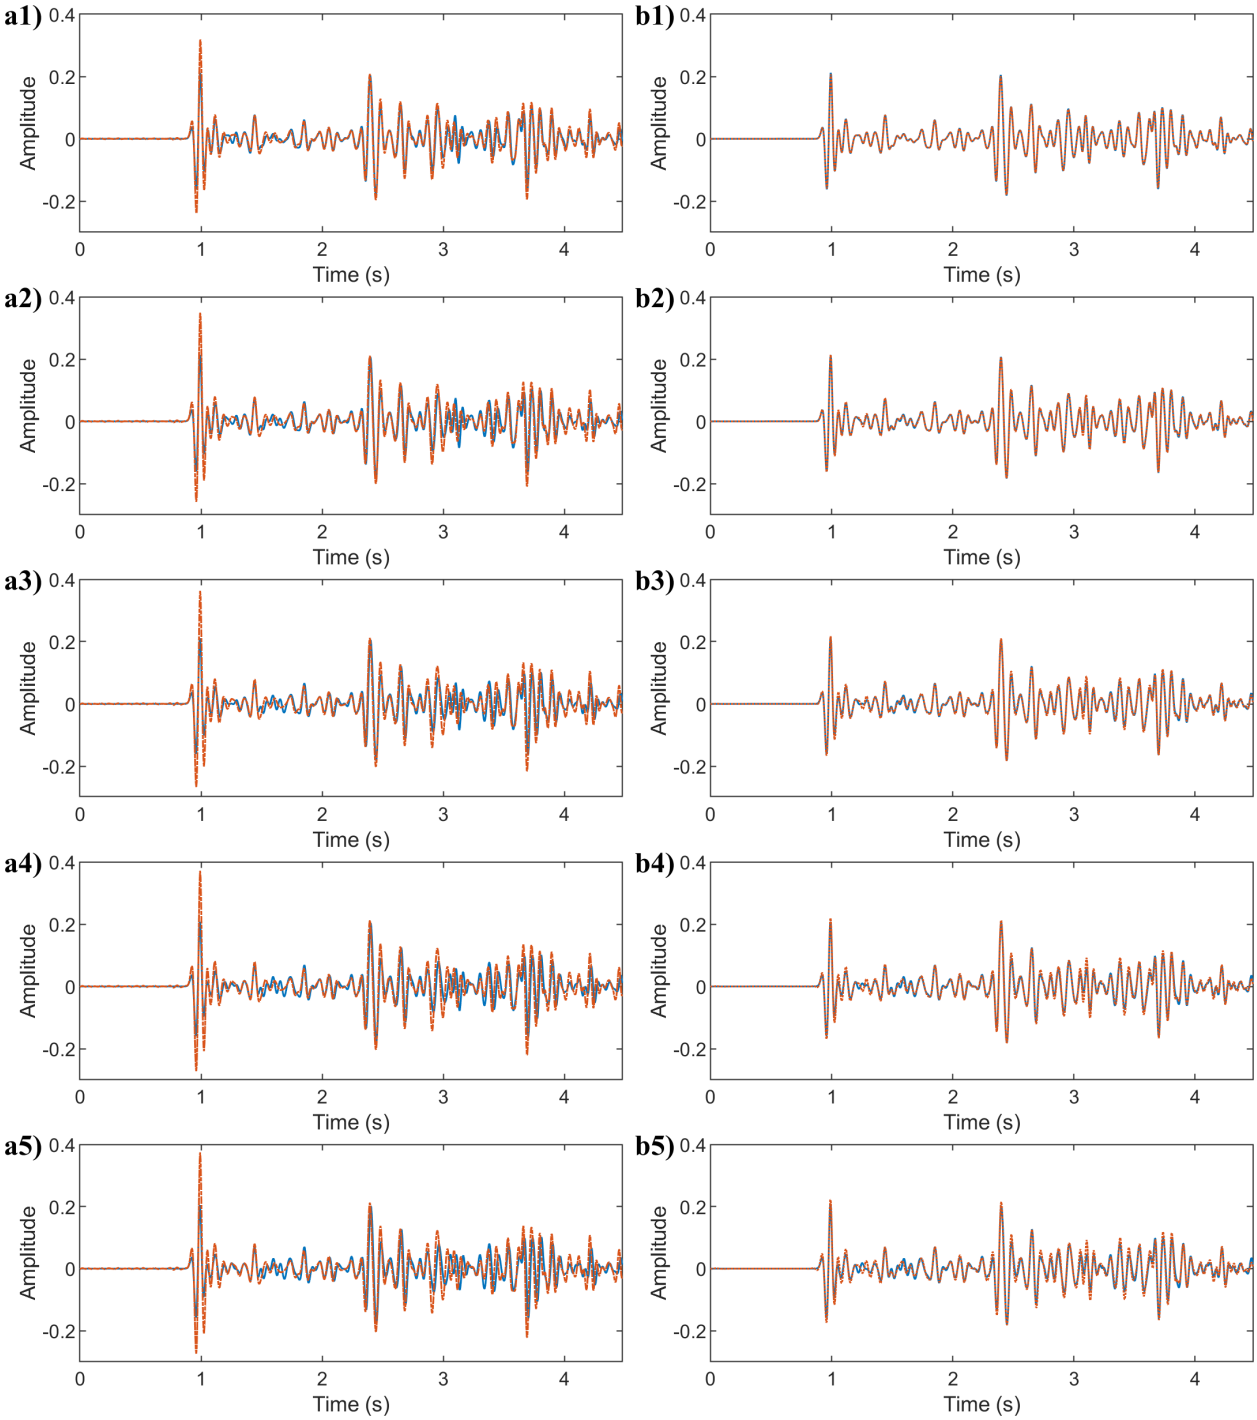


图3：合成数据上重建的近偏移距道的波形对比。蓝色实线表示真实波形，橙色虚线表示重建波形。(a1-a5) 对比 PRT 得到的第10、7、5、3和1条重建道（按偏移距从远到近排列）与真实值。(b1-b5) 我们的方法对应的对比结果。

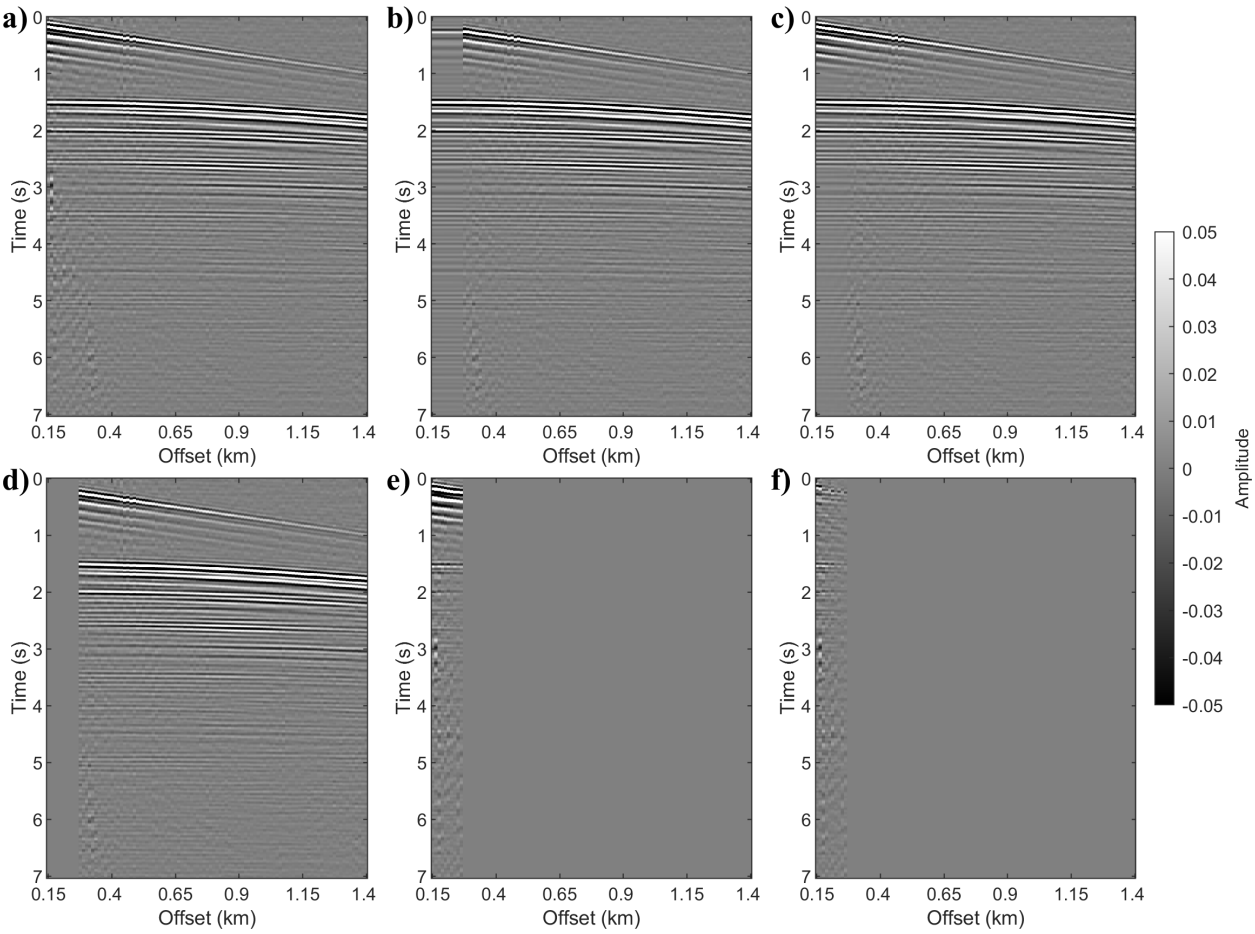


图4：澳大利亚西北部野外数据上用于验证的近偏移距重建结果。显示最接近零偏移距的101道地震道。(a) 完整真实值（从 ∼150 m偏移距开始的记录道）。为验证目的移除的10道的重建数据：(b) PRT，(c)我们的方法。(d) 不完整数据（为验证而从已记录部分人为移除10道）。重建误差（与真实值之差）：(e) PRT，(f)我们的方法。

3.2 现场数据 I：澳大利亚西北部测线

第一个现场数据集是在澳大利亚西北部近海使用变深度拖缆系统采集的。该测线包含1824炮，炮间距约为18.75 m。每个炮集包含648个检波器，间距为12.5 m，以及7040个时间采样点，采样间隔为1 ms，最大记录时间约为7 s。需要指出的是，与大多数拖缆采集一样，该数据集由于物理上的震源—检波器间距，已存在约150 m的固有近偏移距缺口（对应于间距12.5 m的12道地震道）。然而，在本受控实验中，为了验证目的，我们将从150 m偏移距开始的记录道视为完整数据。随后，我们从这一已记录部分再人为移除10道（即偏移距为150–275 m的地震道），以模拟缺失的近偏移距区域，从而能够对照伪真实值参考进行定量性能评估。实际0–150 m缺口的重建将在下一节中展示。

我们将前 1000 炮用作训练数据集。这里需要特别注意的是，在训练过程中，每次迭代都会从每个炮集中随机提取数据块（见公式 7），我们将训练样本块提取限制在前 200 道（从实测数据起始处、150 m 偏移距位置开始测量），而不是使用整个偏移距孔径。之所以作此限制，是因为观察发现，远偏移距道的振幅变化显著大于近偏移距道，这是几何扩散造成的；这可能会主导训练损失，并妨碍模型学习与近偏移距重建相关的细微振幅趋势。

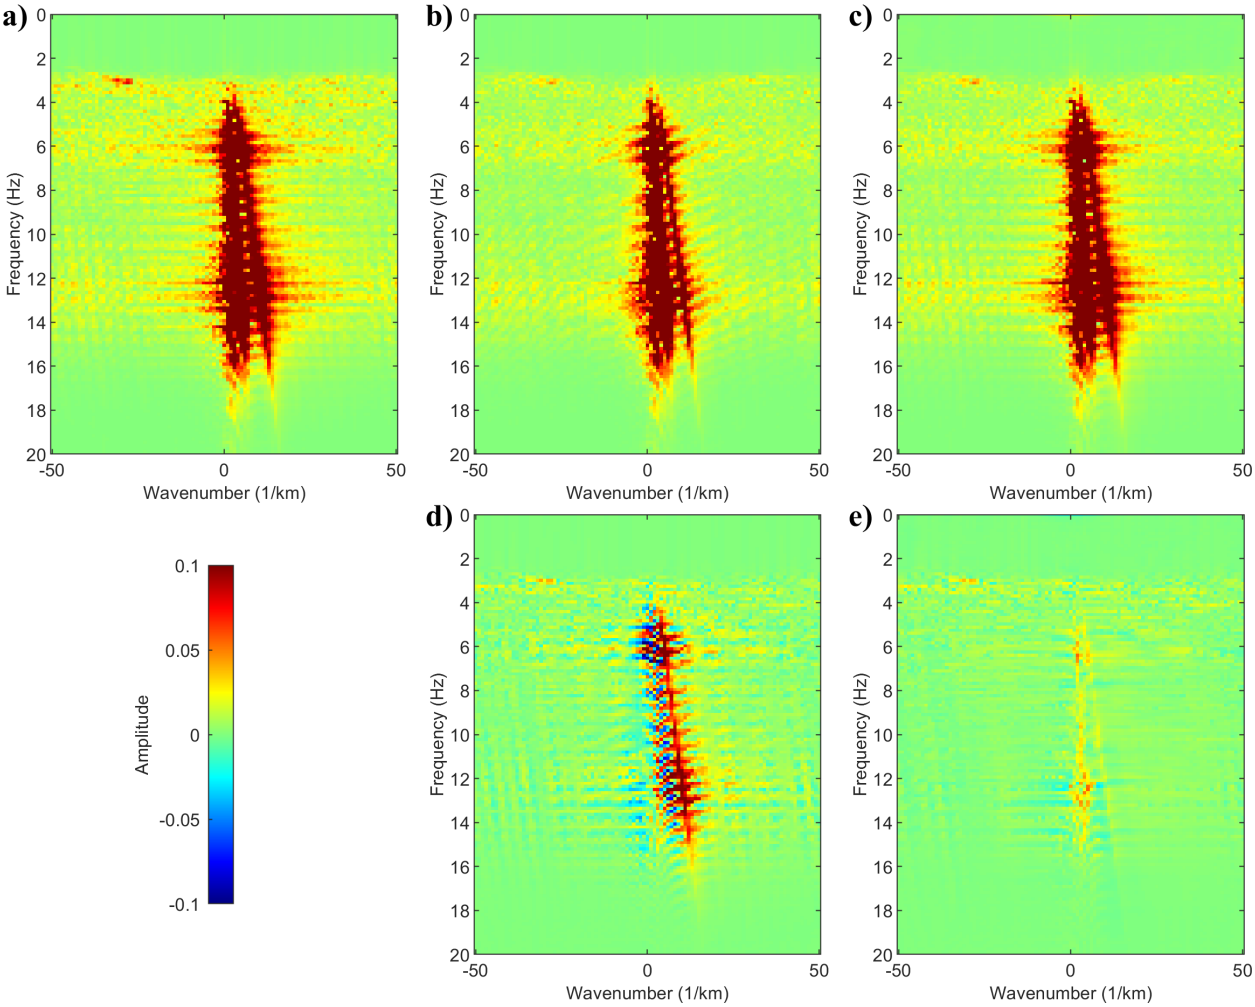


图5：野外数据（澳大利亚西北部）验证实验的 F-K 谱对比。(a) 真实数据（来自记录道）的 F-K 谱。与 (b) PRT 和 (c) 我们的方法相对应的重建数据的 F-K 谱。(d) PRT 和 (e) 我们的方法的谱误差（与真实值的差异）。

我们并未从随机初始化开始训练，而是采用迁移学习，使用在合成数据集上训练的模型初始化网络。这种热启动策略显著加快了收敛速度，将所需训练迭代次数减少至 8000 次（合成数据为 20000 次），并将单块 NVIDIA RTX 8000 GPU 上的总训练时间缩短至约 2 小时 21 分钟。其余训练超参数（批量大小、学习率、优化器、扩散步数）均与合成数据训练时相同。

与合成实验采用相同的评估方法，我们选取一个测试炮集来评估重建性能。图 4 展示了最接近零偏移距的 101 道的重建对比（偏移距范围约为 0.15–1.4 km）。子图 (a) 显示完整的真实炮集（将记录道用作参考），子图 (d) 显示不完整观测数据，其中人为移除了 10 道近偏移距道；子图 (b) 和 (c) 分别显示由 PRT 和我们的方法得到的重建结果。子图 (e) 和 (f) 展示了重建误差。与合成结果一致，相比 PRT，我们的方法实现了显著更高的重建保真度。查看误差图可见，PRT（子图 e）存在明显的信号泄漏，直达波和一次反射波的残余能量均清晰可见。相比之下，我们的方法（子图 f）实现了近乎无伪影的重建，且信号泄漏极少。值得注意的是，两种方法都具备一定的噪声抑制能力，在恢复近偏移距道的同时有效衰减了采集噪声。

图中 F-K 谱的对比5 进一步证实了这些观察结果。我们的方法（图 c）很好地再现了真实值（图 a）的谱特征，误差图（图 e）中的残余能量极少。相比之下，PRT（图 b）出现了频谱畸变，尤其是在对应于低波数区域的部分

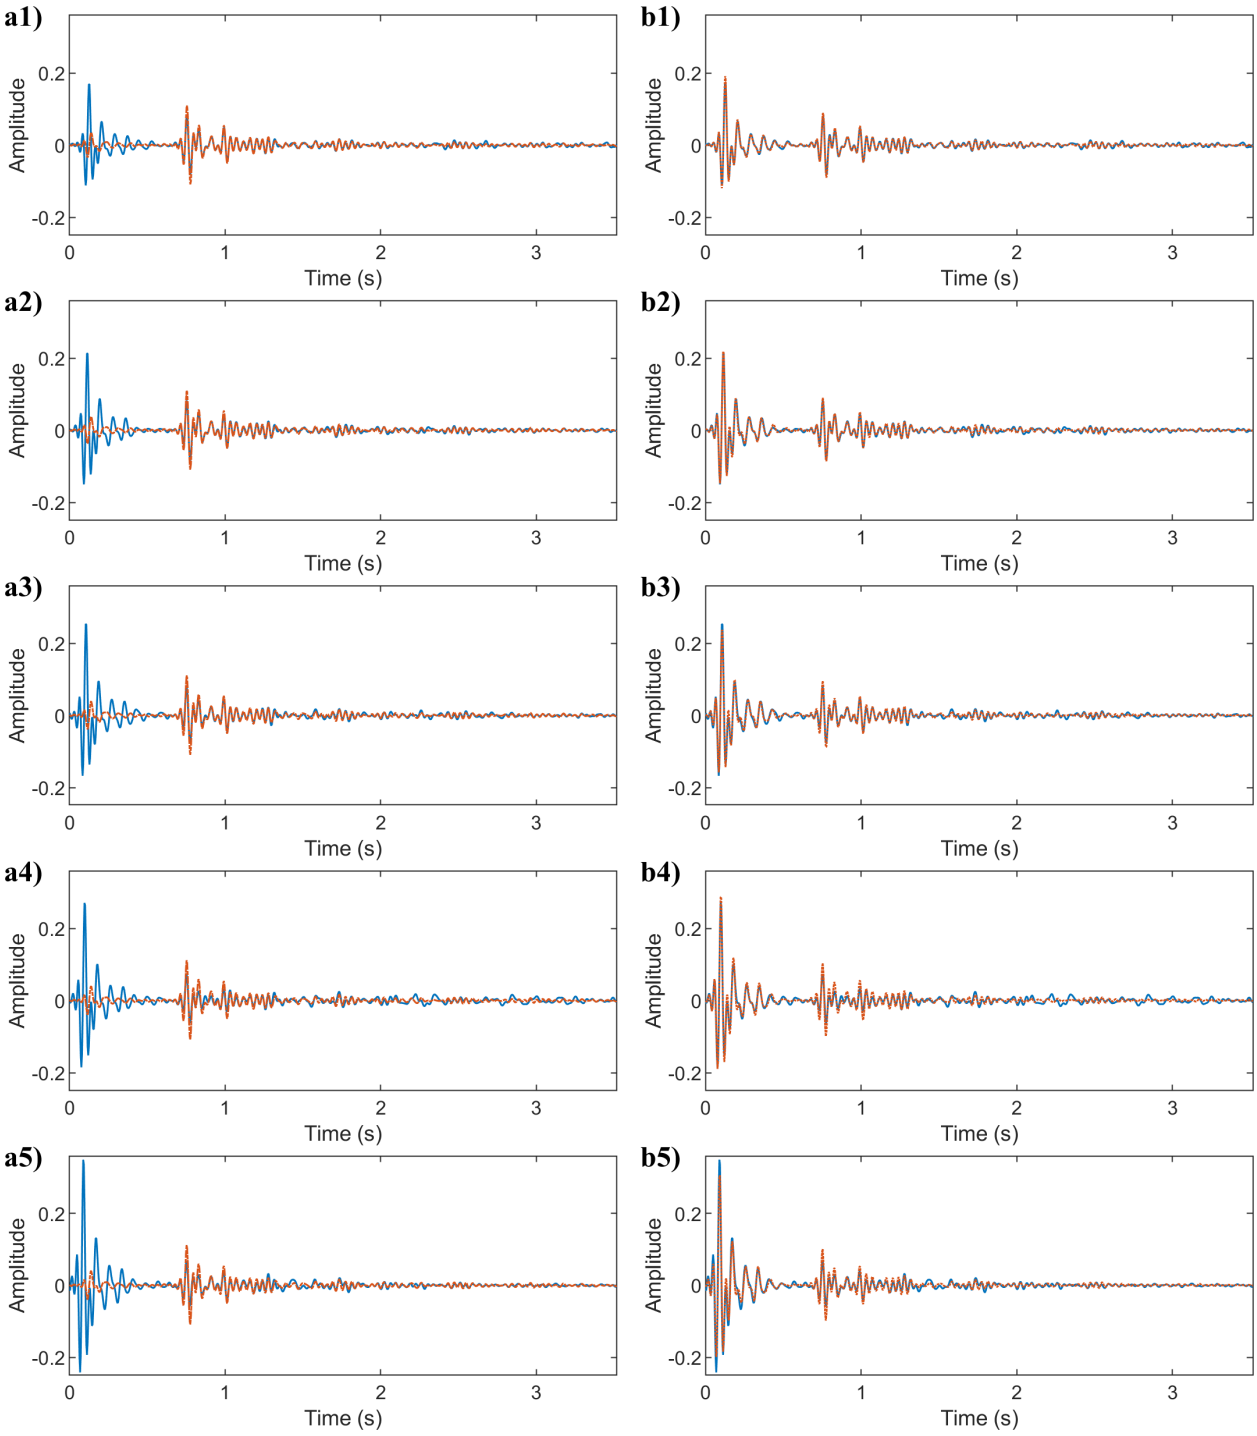


图6：现场数据 I（澳大利亚西北部）验证实验的波形对比。蓝色实线：真实值（记录道）；橙色虚线：重建。(a1-a5) 第10、第7、第5、第3和第1条人工去除道（从远偏移距到近偏移距）的PRT结果。(b1-b5) 所提方法的结果。

对于近偏移距同相轴，正如图（d）中较大的残差所示。这些频谱伪影可能传播到后续处理步骤中，并降低成像质量。

图6展示了第10、7、5、3和1条重建道的详细波形对比。PRT（图 a1–a5）在所有地震道上均表现出一致的振幅高估或低估，且随着偏移距减小，相位误差逐渐增大。所提方法（图 b1–b5）对第10至第5条地震道实现了出色的波形保真度，仅在外推难度更大的第3和第1条地震道上出现轻微振幅偏差。重要的是，即使在最近偏移距处，相位仍保持高度对齐，从而确保重建的近偏移距道能够可靠地支持后续速度反演流程，而这类流程并不太依赖振幅。

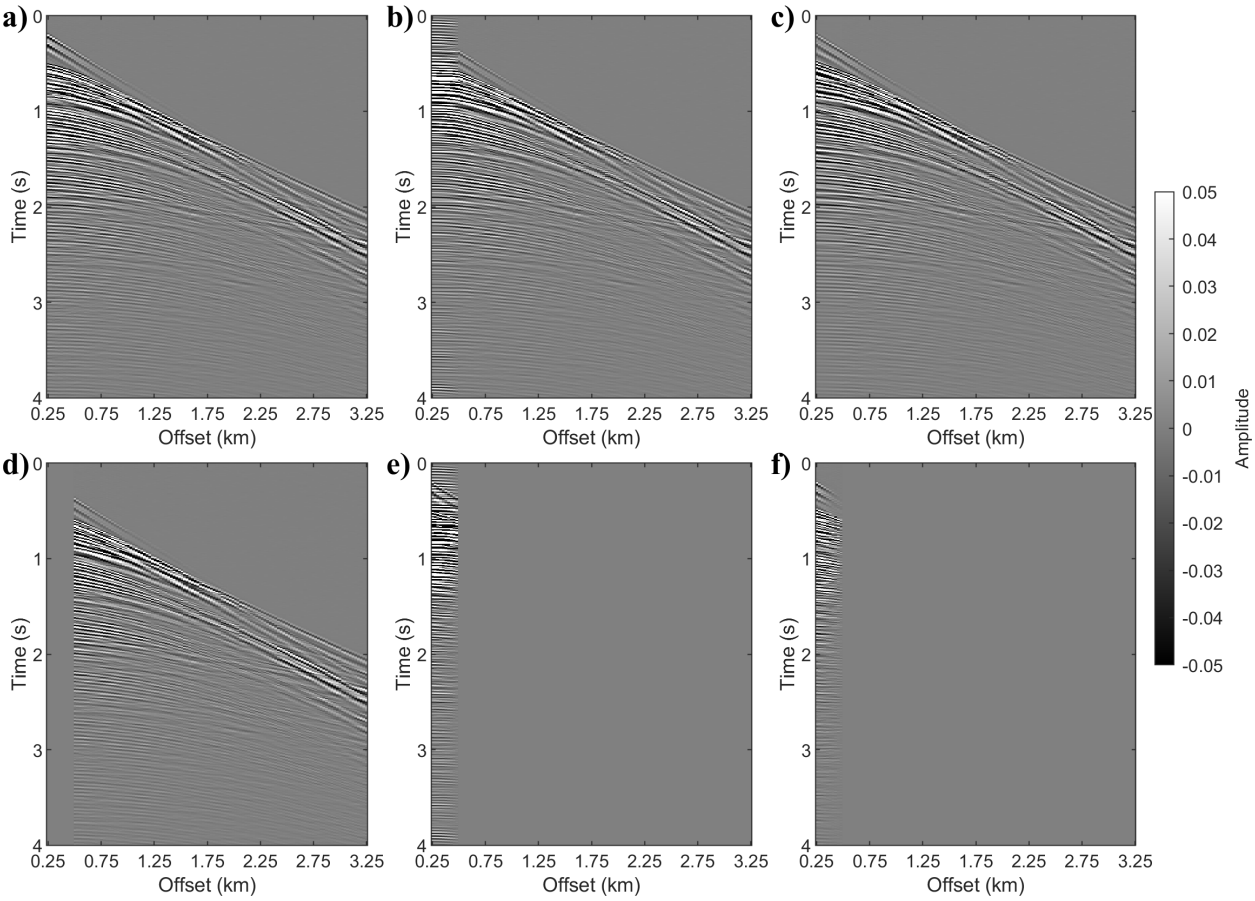


图7：用于验证的 Mobil AVO Viking Graben 第 12 测线数据集近偏移距重建结果。图中显示了最接近零偏移距的101道。（a）完整真实值（从偏移距为 ~250 m处开始的记录道）。用于验证的10条移除道的重建数据：（b）PRT；（c）我们的方法。（d）不完整数据（从记录部分中人为移除10道以供验证）。重建误差（与真实值之差）：（e）PRT；（f）我们的方法。

3.3 现场数据 II：Mobil AVO Viking Graben L 第 12 行

第二个野外数据集是公开可用的 SEG Mobil AVO Viking Graben 第 12 测线，该测线采用拖缆几何采集。此次海洋地震勘测共包含 1001 炮，每炮有 120 个检波器。炮间距和检波器间距均为 25米。记录长度约为 6 秒，时间采样间隔为 4 毫秒。与野外数据集I类似，由于震源—检波器间距的影响，该采集数据天然缺少约 250米的近偏移距区（按 25米间距计为 10 道）。为进行验证，我们采用与前述野外实验相同的策略：将从 250米偏移距开始记录的地震道作为参考数据，并从这部分记录中人为去除额外的 10 道，以便与真实值进行定量评估。实际的 0–250米缺失区将在下一节中重建。

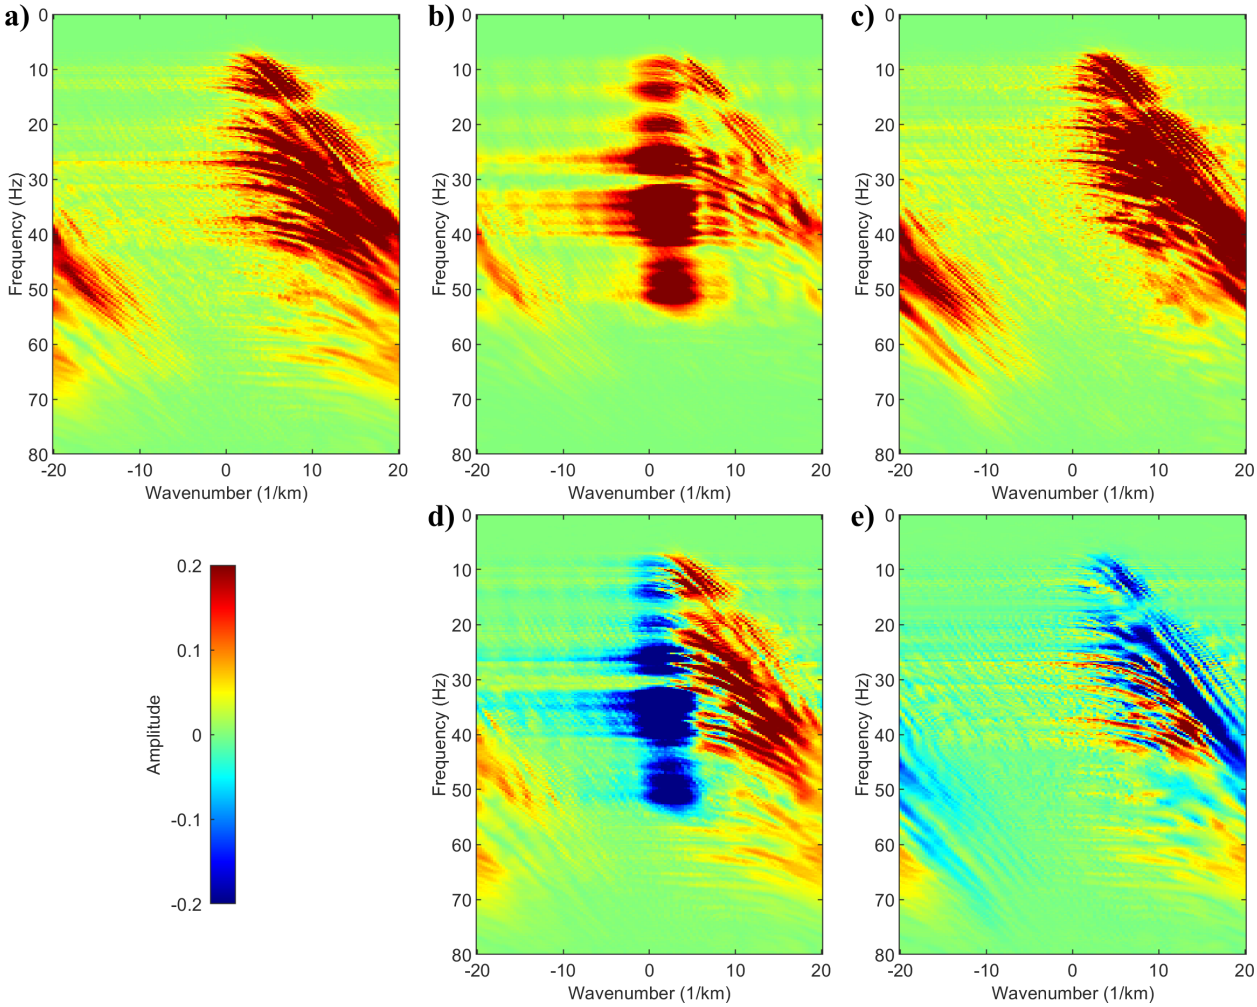


图8：野外数据 II（Mobil AVO Viking Graben 第 12 测线）验证实验的 F-K 谱对比。(a) 真实数据（来自记录道）的 F-K 谱。(b) PRT 和 (c) 我们的方法所对应重建数据的 F-K 谱。(d) PRT 和 (e) 我们的方法的谱误差（与真实值的差异）。

我们使用完整的 1001炮数据集进行训练，并将每个炮集截取至前 4 秒，以聚焦于初至反射区。与合成示例和第一个野外示例相比，该数据集带来了难度显著更高的重建场景。对完整数据的目视检查（图 7a）显示，由于检波器间距相对较大（25米），数据存在明显的空间混叠，导致地震事件的横向连续性较差，陡倾到达波和高频分量尤为如此。训练配置沿用合成实验的超参数设置，并通过合成数据训练的模型进行迁移学习初始化。网络训练 20000 次迭代，在单块 NVIDIA RTX 8000 GPU 上耗时约 6 小时。

图 7 展示了重建结果对比，其中显示了约 120 道，偏移距范围约为 0.25–3.25 km。与 PRT 基线方法相比，我们的方法具有更高的重建保真度，误差图 (e) 和 (f) 中可见的信号泄漏也明显减少。PRT 重建（图 b）存在一种严重的失效模式：重建的近偏移距同相轴几乎呈水平状，与已记录的远偏移距数据存在严重的运动学不一致。这导致重建边界处的横向连续性极差，在高振幅浅层事件（时间 $<$ 1s）处尤为明显；PRT 在此引入了强烈的伪影，与真实波场结构几乎毫无相似之处。这些伪影源于该方法无法妥善处理空间混叠数据，导致 Radon 域中的事件映射错误。相比之下，我们的方法（图 c）与记录数据之间的横向连续性显著更好，并在重建边界两侧保持了同相轴的连贯对齐。然而，与前两个实验相比，两种方法都出现了更严重的信号泄漏，这反映出仅凭稀疏采样的远偏移距观测来重建混叠近偏移距数据本身就存在困难。

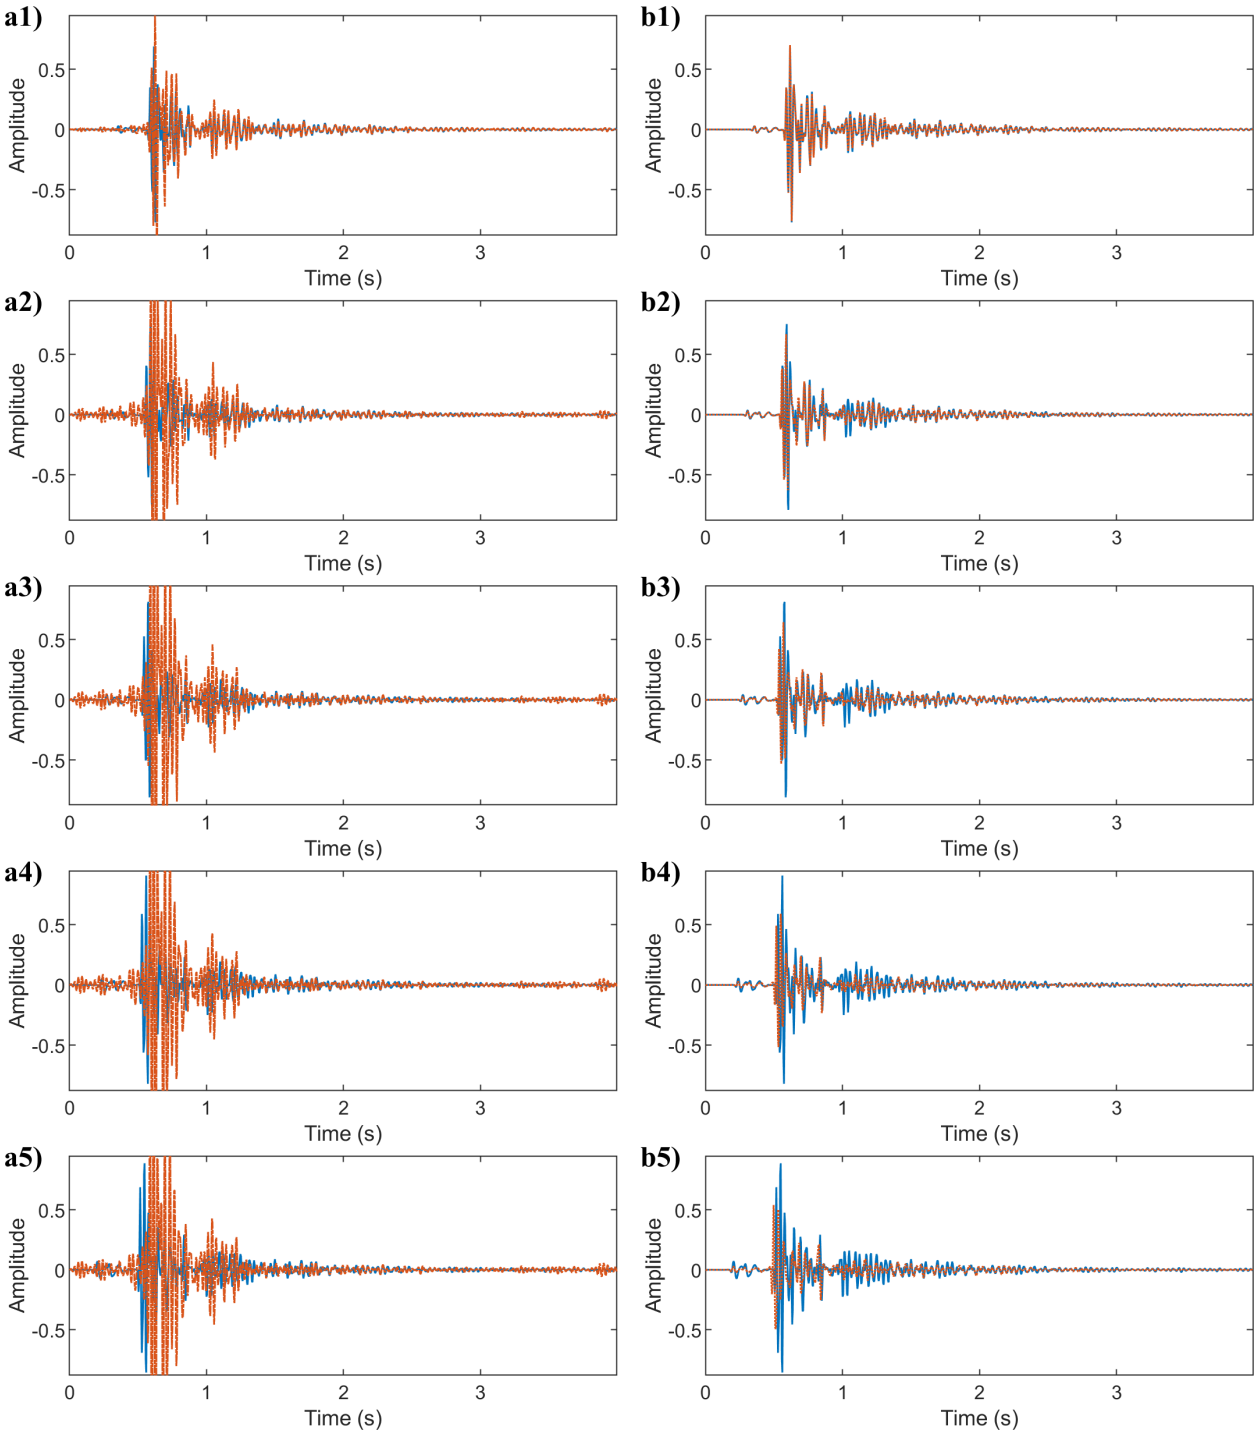


图9：现场数据 II（Mobil AVO Viking Graben 第 12 测线）验证实验的波形对比。蓝色实线：真实值（记录道）；橙色虚线：重建结果。（a1-a5）分别为 PRT 对第 10、7、5、3 和 1 条人工去除道的处理结果（从远偏移距到近偏移距）。（b1-b5）为所提方法的处理结果。

图中 F-K频谱分析8 进一步量化了这些观察结果。PRT 频谱（图 b）与真实频谱（图 a）存在显著偏差，误差图（图 d）显示，在较宽的频率和波数范围内都出现了严重的频谱失真。这表明，在强混叠情况下，PRT 无法恢复近偏移距波场的基本谱特征。尽管存在可见的残余误差（图 e），反映出该数据集具有较大的挑战性，但我们的方法（图 c）实现了显著更好的频谱重建，所得频谱更接近真实频谱。与 PRT 相比，我们重建中的频谱泄漏处于可接受范围且小得多，证实了该方法在存在混叠伪影时能更好地保留空间相干性。

图中波形级对比9 为 PRT 在这个具有挑战性的数据集上的局限性提供了最有力的证据。对于强振幅反射事件，PRT 重建结果（图 a1-a5）即使在紧邻实测数据的第 10 道上也存在明显误差。所有地震道上都出现了严重的振幅差异和相位错位，使重建道无法用于后续处理流程。与之形成鲜明对比的是，我们的方法（图 b1-b5）在第 10 至第 5 道上实现了出色的相位对齐，只有轻微的振幅偏差，且保留了整体波形特征。随着重建向零偏移距推进（第 3 道和第 1 道），外推误差有所增加，部分强反射事件开始出现相位变化。尽管如此，总体重建质量仍远胜于 PRT，尤其是在保持运动学一致性方面。这些结果表明，尽管所提出的框架在处理空间混叠的野外数据时面临挑战，但与传统变换域方法相比，其鲁棒性和重建保真度仍显著更高。

3.4 定量性能比较

为全面定量评估重建质量，我们采用三种广泛使用的指标评估 PRT 和所提方法：平均绝对误差（MAE）、结构相似性指数（SSIM）和信噪比（SNR）。这些指标综合评估重建保真度的不同方面。

MAE 衡量重建的近偏移距数据与近偏移距真实数据之间的平均绝对差异：

$$\mathrm{MAE} = \frac{1}{N}\sum_{i=1}^{N}|\hat{x}_i - x_i|, \tag{14}$$

其中，$\hat{}x_i$ 和 x_i 分别表示重建样本和真实样本，N 表示近偏移距区域中的样本总数。MAE 值越低，振幅精度越高。

SSIM 通过综合考量亮度、对比度和结构信息来评估重建数据与真实数据之间的感知相似性 [Wang 等人， 2004]：

$$\mathrm{SSIM}(\hat{\mathbf{x}}, \mathbf{x}) = \frac{(2\mu_{\hat{\mathbf{x}}}\mu_{\mathbf{x}} + C_1)(2\sigma_{\hat{\mathbf{x}}\mathbf{x}} + C_2)}{(\mu_{\hat{\mathbf{x}}}^2 + \mu_{\mathbf{x}}^2 + C_1)(\sigma_{\hat{\mathbf{x}}}^2 + \sigma_{\mathbf{x}}^2 + C_2)}, \tag{15}$$

其中，μ和 σ 表示均值和标准差，$\sigma_{\hat{\mathbf{x}}\mathbf{x}}$ 表示协方差，C_1和 C_2 是用于保证数值稳定性的小常数。SSIM 的取值范围为 -1 至 1，值越高表示结构保真度越好。

信噪比用于量化信号功率与重建误差功率之比：

$$\mathrm{SNR} = 10\log_{10}\left(\frac{\sum_{i=1}^{N} x_i^2}{\sum_{i=1}^{N}(\hat{x}_i - x_i)^2}\right)\ (\mathrm{dB}). \tag{16}$$

信噪比值越高，表示相对于信号强度而言，重建误差越低。

表 1 总结了三个测试数据集上的定量比较结果。对于合成数据集，与 PRT 相比，我们的方法取得了显著提升：平均绝对误差降低了 81.5%（从 0.0178 降至 0.0033），结构相似性指数从 0.6727 提高至 0.9597，信噪比则从 2.52 dB 大幅提升至 13.62 dB。对于野外数据集I（澳大利亚西北部），我们的方法仍具有显著的性能优势：平均绝对误差降低了 54.5%（从 0.0088 降至 0.0040），结构相似性指数从 0.8355 提高至 0.9455，信噪比从 0.20 dB 提高至 10.92 dB。对于野外数据集II（Mobil AVO Viking Graben 第 12 测线），由于空间混叠严重，该数据集的重建场景最具挑战性。与 PRT 相比，我们的方法取得了更低的平均绝对误差（0.0214 对 0.0705）和更高的结构相似性指数（0.8063 对 0.5419）。然而，两种方法的信噪比均为负值（我们的方法为 -1.6655 dB，PRT 为 -9.2979 dB），这表明近偏移距区域的重建误差超过了信号功率。这反映了从稀疏采样的远偏移距观测中恢复混叠近偏移距信息的根本难题。尽管如此，我们的方法的信噪比仍比 PRT 高出 8 dB，而显著更低的平均绝对误差也证实，即使在严重混叠条件下，我们的方法仍能实现更准确的重建。

表1：比较 PRT 与我们的方法在三个数据集上的平均绝对误差、结构相似性指数和信噪比，粗体表示最佳精度。

数据集	方法	MAE	SSIM	SNR
合成数据集	PRT	0.0178	0.6727	2.5237
	我们的方法	**0.0033**	**0.9597**	**13.6237**
野外数据集I	PRT	0.0088	0.8355	0.1962
	我们的方法	**0.0040**	**0.9455**	**10.9246**
野外数据集II	PRT	0.0705	0.5419	-9.2979
	我们的方法	**0.0214**	**0.8063**	**-1.6655**

总体而言，定量指标一致表明，所提方法在不同数据集上的表现均优于传统基线方法；性能提升幅度从混叠数据等挑战性场景中的中等改善，到采样充分样例中的显著提升不等。

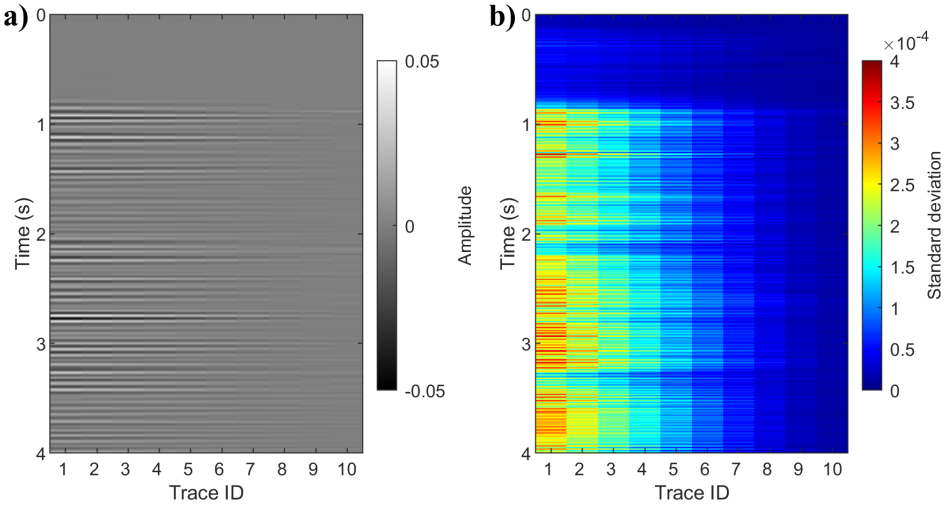


图 10：合成数据集的不确定性量化。(a) 前 10 个重建近偏移距道的重建误差（50 次实现的均值减去真实值）。(b) 不确定性图（50 次实现的标准差）。

3.5 不确定性量化分析

与确定性重建方法相比，所提出的基于扩散的框架有一项独特优势，即能够通过集成采样自然地进行不确定性量化。为评估重建不确定性的可靠性及空间分布，我们对每条缺失的近偏移距道采用不同的随机噪声初始化进行 DDIM 采样，生成 50 个独立实现。这些实现的逐点标准差构成逐像素不确定性图，用于量化模型对重建结果的置信度。

在此，我们将分析重点放在前 10 条重建道（最接近零偏移距的道）上。图 10、11和 12 分别展示了合成数据集、野外数据集I（澳大利亚西北部）和野外数据集II（Mobil AVO Viking Graben 第 12 测线）的不确定性量化结果。对于每个数据集，我们展示了重建误差（平均重建与真实值之差，图 a）以及相应的不确定性图（50 个实现的标准差，图 b），针对的是 10 条重建的近偏移距道。

在全部三个数据集中，呈现出若干一致且富有启示性的规律。首先，不确定性的空间分布与重建误差高度相关：预测误差较大的区域（例如重建较差的同相轴）始终显示出较高的不确定性值，而波场中准确重建的部分则表现出较低的不确定性。这种相关性验证了集成方差能够精确反映重建置信度。其次，当偏移距从第10道（距零偏移距最远）减小至第1道（距零偏移距最近）时，重建误差与不确定性总体上均增大。这一趋势证实了我们此前基于波形对比（图3、6和9）的定性观察：随着与可用实测数据的距离增大，外推会逐渐变得更具挑战性，所受约束也更少。第10道紧邻

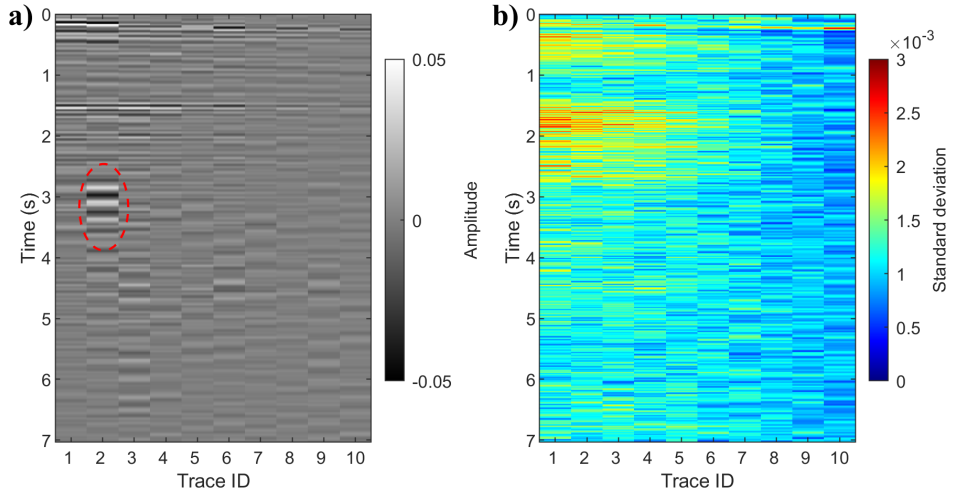


图11：与图10类似，但针对野外数据集I（澳大利亚西北部）。

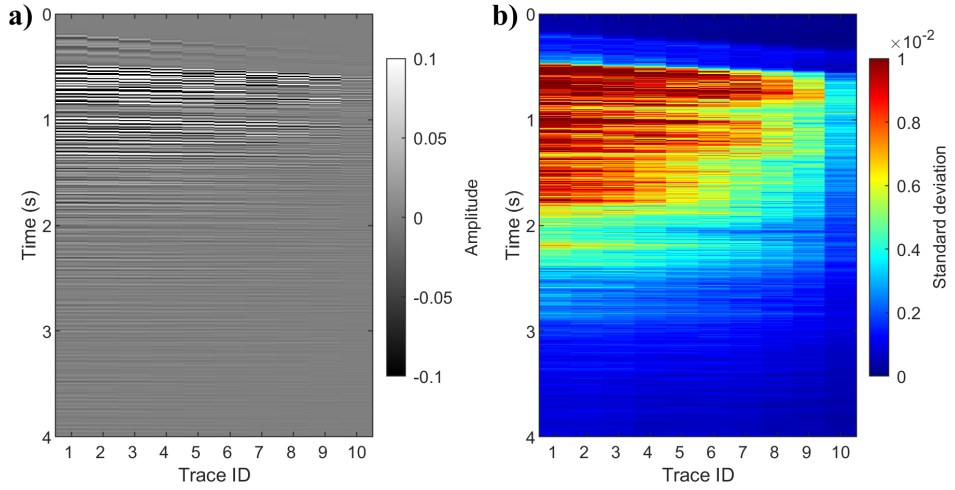


图12：与图10类似，但针对野外数据集II（Mobil AVO Viking Graben 第 12 测线）。

实测远偏移距区域，表现出极低的不确定性，而距任何条件信息最远的第1道则表现出最高的不确定性。

然而，在图11a中红色虚线椭圆标示的区域，观察到一个特别能说明问题的例外。该区域的重建误差较高，但图11b中的不确定性却明显较低。仔细检查图4a中的原始真实数据可见，该区域含有显著的采集噪声。该区域误差较高，实际上反映了所提方法成功抑制噪声：在全部50次实现中，重建结果始终生成更干净的地震道（因此不确定性较低），但这些去噪后的预测与含噪真实值不同（因此误差较高）。这一现象有力地验证了不确定性量化的可靠性：它衡量的是模型预测的变异性，而非简单地追踪与真实值之间的差异。

重建误差与不确定性之间所展现的关系，以及该方法在噪声占主导区域中的信息指示能力，凸显了不确定性量化在实际地震处理工作流程中的重要实用价值。在现实的拖缆采集中，无法获得完整的近偏移距真实数据，因此既无法计算重建误差，也无法直接评估插值精度。然而，我们的方法生成的不确定性图提供了一种有效的替代评估方式，无需真实值即可评估重建可靠性。可将高不确定性区域标记出来进行人工检查、从后续处理步骤中排除，或采用其他重建策略；而低不确定性区域则可放心用于表面相关多次波压制和成像工作流程。更重要的是，该方法展现出区分随机预测变异性（高不确定性）与确定性去噪行为（低不确定性，尽管存在误差）的能力，

这进一步提升了这些不确定性估计的实用价值。这种自我评估能力使所提出的基于扩散的方法有别于传统的确定性方法，并显著增强了其适用性。

4 实际近偏移距缺口的真实场景应用

在前述验证实验中，我们通过从记录的野外数据中人为移除近偏移距道，评估了所提框架，并据此参照真实值对其性能进行了定量评估。这种受控评估策略清楚地证明，与传统基线方法相比，该方法具有更高的重建保真度。然而，开发该框架的主要动机，是解决拖缆采集中因震源与检波器之间存在物理间距而固有的近偏移距缺口；对于这类缺口，从根本上说不可能通过真实值进行验证。

本节展示了所提方法在两个现场数据集的实际缺失近偏移距区域中的应用。与验证实验中从已记录部分人为移除额外地震道不同，我们现在直接使用采集到的完整观测数据训练模型，然后重建缺失的近偏移距区域。由于没有真实值可用于验证，不确定性量化便成为评估重建可靠性的主要手段。

4.1 应用于现场数据 I

现场数据集 I（澳大利亚西北部）存在约 150 m 的固有近偏移距缺口，相当于在检波器间距为 12.5 m 时缺失 12 道。因此，我们的目标是重建实际的 0–150 m 近偏移距缺口（缺失 12 道）。我们使用从 150 m 偏移距开始的完整观测数据重新训练模型，并采用验证实验中确定的相同训练配置。

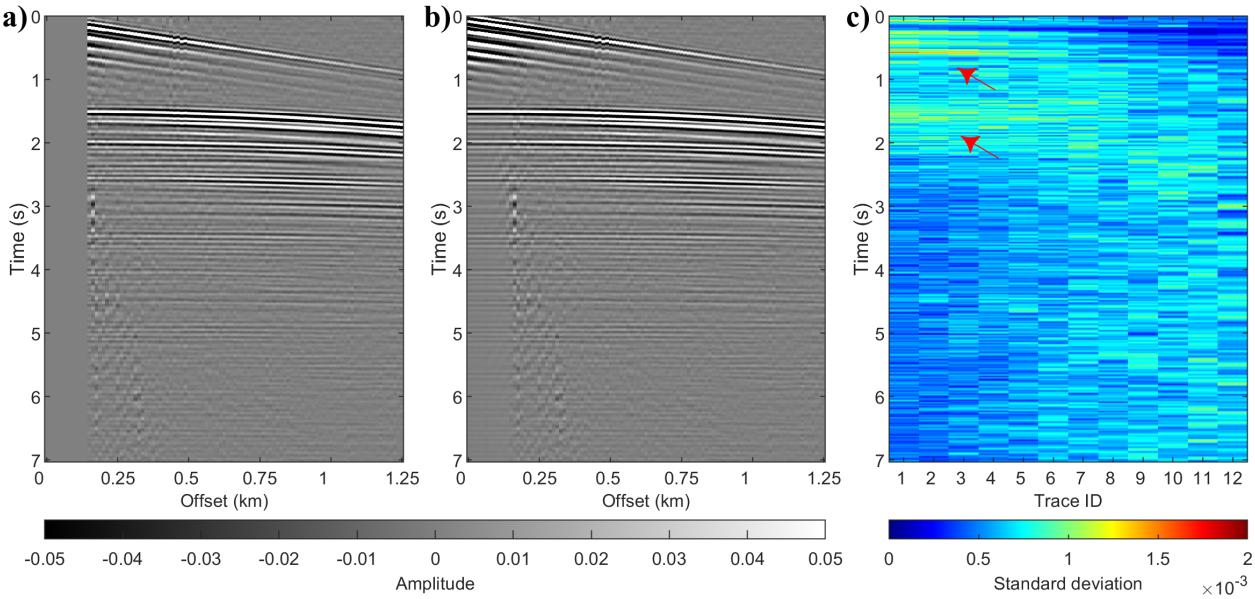


图 13：现场数据 I（澳大利亚西北部）的实际近偏移距缺口重建。(a) 测试炮集，显示完整的 0–1.25 km 偏移距范围，其中实测数据从 ∼0.15 km（第 13 道）开始。(b) 重建后的完整剖面，包括新生成的 12 条近偏移距道（0–150 m）。(c) 12 条重建道的不确定性图（基于 50 次实现计算的标准差）。

图13 展示了实际 0–150 m 近偏移距缺口的重建结果。面板 (a) 显示了一个测试炮集，其偏移距范围完整覆盖 0 至 1.25 km，实测数据则从约 0.15 km（道13）处开始。面板 (b) 展示了包含新生成的 12 道近偏移距道的完整重建剖面，面板 (c) 则展示了根据 50 次实现的标准差量化得到的不确定性图。目视检查可见，重建结果具有若干令人鼓舞的特点。首先，重建道（0–150 m）与记录道（> 150 m）具有出色的横向连续性，在重建边界处同相轴过渡平滑，且没有明显的运动学不连续。重建剖面十分干净，有效避免了噪声

污染（这与验证实验中观察到的噪声抑制表现一致），而这类污染可能存在于实测远偏移距数据中。其次，零偏移距处重建出的直达波出现在约零时刻，这与零偏移距下预期的震源—接收器几何关系在物理上相符。这种运动学精度验证了模型已成功学习并将远偏移距训练数据中的时差特征外推至近偏移距区域。不确定性图（面板 c）为评估重建置信度提供了有价值的信息。如面板 (c) 中红色箭头所示，有两个局部区域的不确定性较高：一个位于约 1 s 处，另一个位于约 2 s 处，且两者都集中在道 1–4。在地表地震记录中，浅部近偏移距反射波往往具有最大的曲率，这或许可以解释外推中的较高不确定性。这些区域对应浅部的高振幅直达波和反射事件。较高的不确定性准确地标示出需要进一步检查的区域，表明在缺少真实值验证的情况下，不确定性量化对质量控制具有实际价值。相反，道 8–12 和深部事件（$>$ 3 s）的不确定性较低，说明这些区域的重建置信度较高。

为详细考察重建波形，图14 比较了第1、第4、第8和第12条重建道的时间序列。这四条道覆盖了整个缺失区，从零偏移距（道1）延伸至与实测数据的交界处（道12）。可以看到，这四条道的波形呈现出渐进的振幅变化和相位变化，反映了真实的AVO行为。值得注意的是，随着偏移距从道1增加到道12，直达波和浅层反射事件的振幅系统性衰减，并出现相位变化。鉴于模型仅使用从150 m偏移距开始的数据进行训练，训练期间从未见过任何近偏移距道，这种与AVO一致的行为尤为显著。波形的渐进变化表明，扩散模型并非只是将实测数据中的近偏移距事件复制或平移到缺失区，而是真正通过传播远偏移距训练数据中蕴含的AVO先验，对动态波场属性进行了外推。

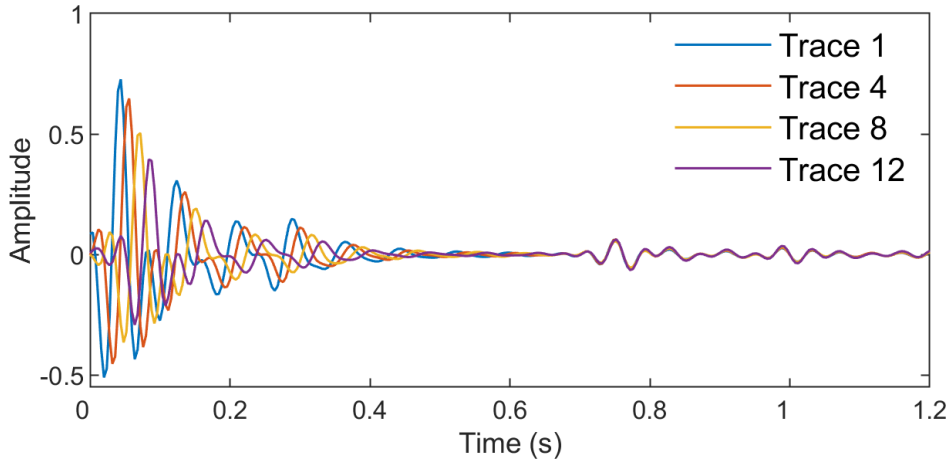


图 14：Wav eform对比，针对现场数据 I 中第1、第4、第8和第12条重建近偏移距道。

4.2 应用于野外数据II

野外数据集II（Mobil AVO Viking Graben 第 12 测线）缺少约250米的近偏移距数据，相当于道间距为25米时的10条缺失道。因此，这里需要重建采集中固有的实际0-250米近偏移距缺口（10条缺失道）。模型使用从250米偏移距开始的完整观测数据重新训练，并遵循验证实验中建立的训练配置。

图 15展示了实际0-250米缺口的重建结果。分图（a）显示了一个偏移距范围为0-3.25 km的示例炮集，其中实测数据从0.25 km（道11）开始。分图（b）展示了重建后的完整剖面，分图（c）给出了10条重建道的不确定性图。尽管存在具有挑战性的空间混叠，重建仍在重建道与记录道的边界处实现了合理的事件连续性。重建的近偏移距同相轴保持了连贯的时差模式。值得注意的是，零偏移距处的直达波再次大约在零时刻出现，表明了运动学一致性。不确定性图（分图c）显示，与野外数据集I相比，不确定性显著升高，这与验证实验一致。同时，不确定性分布呈现出两个明显趋势：

- 首先，在偏移距维度上，不确定性从道10（最接近250米处实测数据的道）向道1（零偏移距）逐渐增加，这反映了一个根本性挑战：随着与条件信息之间距离的增加，外推置信度会降低。

• 其次，在时间维度上，不确定性呈现出明显的规律：浅层事件（< 2 s）的不确定性显著高于深部事件（> 2 s）。

这种浅层与深部的不确定性对比源于两个因素的相互作用。首先，由于浅层反射具有更陡的动校正斜率，在较粗的 25 m 检波器间距下，旅行时变化迅速，因此会受到更严重的空间混叠影响。相比之下，深部同相轴的曲率较缓，因而混叠程度较低，使模型能够在训练过程中建立更可靠的统计模式。同时，与深部事件相比，浅层反射在近偏移距处通常具有更大的曲率。曲率越大，波场外推就越困难。因此，在 < 2s 时，1–5 道的不确定性最高，因为所有不利因素在此交汇；而重建剖面的深部区域则表现出可接受的低不确定性。对重建局限性所做的客观评估，证明了不确定性量化框架的可靠性：在严重混叠和高振幅条件下，升高的不确定性准确反映了外推相干信息所面临的真实困难。

图中的波形分析 16 比较了跨越0-250米缺失区的第1、第4、第7和第10条重建道。与野外数据集I（图14）类似，重建波形呈现出清晰的AVO效应，并在各地震道上表现出逐渐的振幅变化，表明扩散模型尽管仅在远偏移距数据（> 250米）上训练，仍成功外推了偏移距相关振幅特征。这四条地震道在不同偏移距上也显示出适当的相位变化，反映了真实的动校正变化。值得注意的是，2 s以下的浅层强反射事件相比深部事件表现出更明显的相位变化，这与浅层区域更陡的动校正曲率相一致，该曲率会导致更严重的空间混叠，正如在图15c中观察到的升高的不确定性所反映的那样。

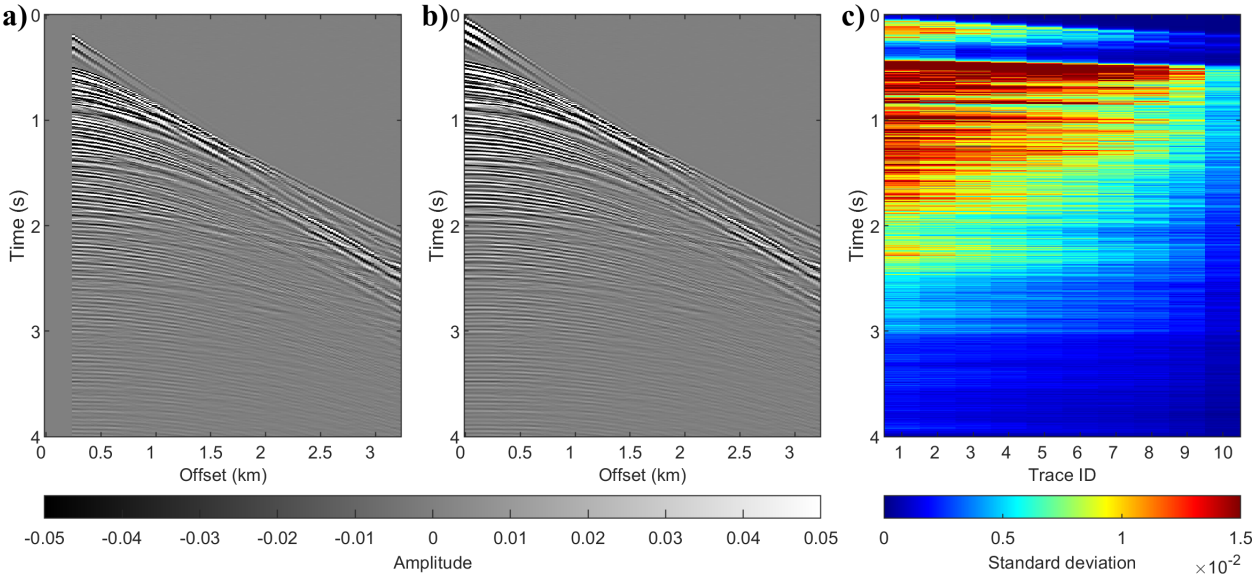


图15：野外数据集II（Mobil AVO Viking Graben 第 12 测线）的真实近偏移距缺口重建。(a) 测试炮集显示完整偏移距范围0-3.25 km；实测数据始于 ∼0.25 km（道11）。(b) 重建的完整剖面，包括10条新生成的近偏移距道（0-250米）。(c) 10条重建道的不确定性图（50次实现的标准差）。

5 讨论

验证与实际应用实验结果表明，所提出的自监督扩散框架相较于传统抛物线Radon变换，在合成数据集和野外数据集上均实现了更优的近偏移距重建性能。表1 中的定量指标显示，平均绝对误差、结构相似性指数和信噪比均有显著改善，尤其是在采样良好的数据上。这些性能提升源于该方法能够直接从可用的远偏移距数据中学习复杂的、依赖偏移距的统计模式，并通过递归推理策略将所学先验信息向近偏移距传播。重要的是，该方法在实际近偏移距缺口上的成功部署，验证了其在无法进行真值验证的实际地震处理工作流程中的实用可行性。

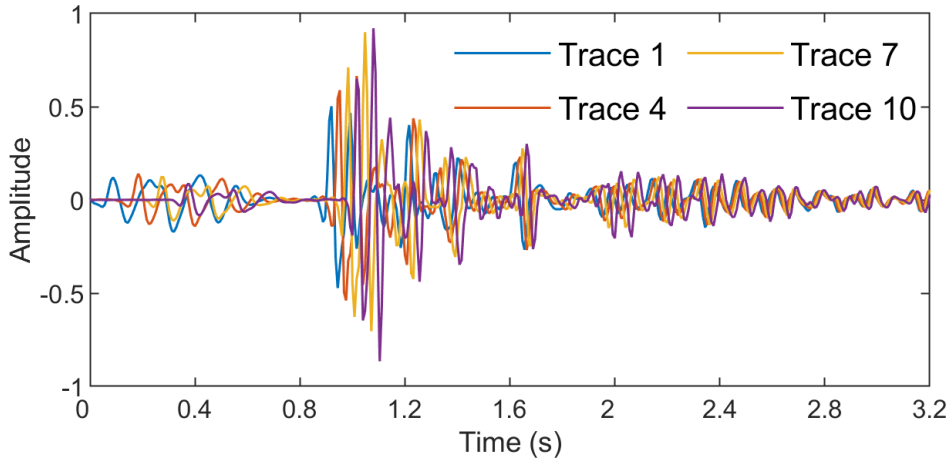


图16：波形　野外数据 II 中第1、4、7和10条重建近偏移距道的波形对比 .

所提方法一项特别值得注意的能力，是其在训练期间从未接触完整近偏移距数据的情况下仍能有效外推近偏移距道。这些令人振奋的结果——即从训练集中完全缺失的区域重建信息——得益于扩散模型捕捉并泛化远偏移距观测中所蕴含底层波场物理的能力。仔细检查两项验证实验中的波形对比（图3、6和9）以及实际应用（图13 和15）揭示了一个更为显著的现象：重建的近偏移距道在不同偏移距上呈现出振幅变化，这些变化与扩散模型从多炮可用数据中学到的规律相符，并与振幅随偏移距变化（AVO）效应一致。具体而言，同一反射事件的重建波形显示出逐渐变化的振幅，可能反映了由界面反射率随入射角变化所引起的真实AVO行为。这种AVO保持在实际间隙重建中尤为明显：训练与评估期间均不存在近偏移距真实数据，但外推地震道仍捕捉到了符合实际的依赖偏移距的振幅趋势。这表明，该模型已隐式地学会从远偏移距训练数据中外推的不仅是运动学属性（旅行时和动校正曲率），还包括动力学属性（AVO趋势）。

这种 AVO 感知重建背后的机制可从两个互补的角度来理解。首先，远偏移距数据本身包含 AVO 信息，因为反射振幅会因依赖角度的反射率而随记录的偏移距范围系统变化。通过在跨越多个偏移距的重叠区块上训练，条件扩散模型能够学习振幅随偏移距变化的统计依赖关系。关键的是，训练会同时利用数据集中的所有炮集进行。这种跨炮训练策略尤为有效，因为由于震源-接收器几何不同，一个炮集中缺失的近偏移距区域内某个反射事件的 AVO 信息，可能已在另一个炮集记录的远偏移距数据中体现出来。例如，炮集 A 中偏移距为 100 m 的反射（缺失）可能对应于炮集 B 中偏移距为 300 m 处的同一地质界面（已记录），这样模型就能从炮集 B 学习该界面的振幅特征，并将其迁移到炮集 A，以重建相应数据。其次，递归推理策略在将这一已学习的先验从远偏移距传播到近偏移距的过程中起着关键作用。在逐道重建的每一步，模型都以最新可用的偏移距信息（重建或已记录）为条件，从而将振幅趋势逐步传递至零偏移距。即使缺少直接的近偏移距监督，这种渐进式外推也能使模型维持物理上合理的振幅变化。

这种 AVO感知重建背后的机制可以从两个互补的角度来理解。首先，远偏移距数据本身包含 AVO 信息，因为反射振幅会因依赖角度的反射率而在记录的偏移距范围内呈现系统性变化。通过在涵盖多个偏移距的重叠区块上进行训练，条件扩散模型能够学习振幅随偏移距变化的统计依赖关系。其次，递归推理策略在将这一已学习的先验从远偏移距传递到近偏移距的过程中发挥着关键作用。在逐道重建的每一步，模型都会以最新可用的（已重建或已记录的）偏移距信息为条件，从而逐步将振幅趋势传递至零偏移距。这种渐进式外推使模型即使缺少直接的近偏移距监督，也能保持物理上合理的振幅特征。

除了重建精度外，所提方法还具备一项重要优势，即能够自然地进行不确定性量化。验证实验（图10、11和12）以及实际应用（图13c和15c）中的集成采样分析表明，不确定性图始终与重建误差的大小（在有真实值时）相关，并且随着偏移距减小而逐渐增大。这证实了认知不确定性确实反映了随着与条件数据的距离增加，外推难度也随之增大的情况。这种自我评估能力解决了实际近偏移距重建场景中的一个根本局限：缺少用于验证的真实数据。在实际地震处理过程中，地球物理学家无法直接评估重建质量，因为完整的近偏移距道本就无法获得，因此，不确定性图成为不可或缺的替代质量指标，可用于识别适合后续处理的高置信度区域，并标记需要人工检查或采用其他策略的低置信度区域。

然而，该方法的有效性从根本上取决于数据中地震事件的空间连续性与相干性。所提方法基于这样的假设：相邻偏移距道在运动学特征和动力学特征上均呈现平滑、可预测的变化。当这一假设成立时，例如在合成数据集和野外数据集I中，扩散模型能够成功捕捉潜在的波场结构，并实现高保真度重建。相较之下，当检波器间距较大、空间混叠显著等因素导致空间连续性降低时（如野外数据集II），模型性能会下降。验证结果显示，信噪比值为负，且重建误差较高（表1）；而实际的 0-260 m 缺失区重建表现出显著更高的不确定性，尤其是在浅层区域，陡峭的动校正曲率加剧了混叠效应。这些结果反映出，从存在混叠的远偏移距观测中外推近偏移距信息固有的困难：高频分量采样不足，且事件相干性遭到破坏。

对于存在严重空间混叠的数据集，一种潜在的缓解策略是在近偏移距重建之前进行去混叠预处理。预测误差滤波器 [Chen 等人、 2021], 稀疏数学变换[Schonewille 等人、2009、Naghizadeh 和 Sacchi、 2013], 或基于深度学习的去混叠 [Fang 等人、2021b、Wei 等人、2021b] 可通过插值生成更多伪道或抑制混叠伪影来增强空间连续性，从而为基于扩散的外推提供更有利的输入。这一方向为将所提出的框架拓展至更具挑战性的采集场景提供了有前景的途径。
现场数据 I 实验揭示的另一项实际考量是，将训练样本块提取限制在适当的偏移距范围内十分重要。正如现场数据 I 中所述，我们将样本块采样限制在前 200 道，而没有使用整个偏移距孔径。这一限制旨在解决振幅缩放问题：由于几何扩散、衰减和复杂的多次波干扰，远偏移距道往往表现出显著更大的振幅变化，这些变化可能主导训练损失，并妨碍模型学习与近偏移距重建相关的细微振幅趋势。将训练集中在近至中等偏移距区域，可使模型学习到更能代表目标重建区域的模式，从而提升泛化能力。这一设计选择凸显了在将扩散模型应用于地球物理应用时，领域特定考量的重要性。

6 结论

我们开发了一种自监督扩散框架，用于重建海洋拖缆地震数据中缺失的近偏移距道，无需完整的真实值训练数据。所提方法利用从现有远偏移距剖面中以单道为步长提取的重叠块，训练条件扩散模型以学习依赖偏移距的统计模式，并从远偏移距到近偏移距逐道进行递归推断。在合成数据集和野外数据集上开展的全面验证实验表明，该方法的性能优于传统抛物线Radon变换。在实际近偏移距缺口上的应用进一步证明了该方法在实际场景中的可行性：我们分别重建了野外数据集I中原有的0–150 m缺口和野外数据集II中的0–260 m缺口。值得注意的是，验证实验和实际应用均表明，重建的近偏移距道呈现出与真实偏移距相关振幅特征一致的振幅随偏移距变化，尽管模型在训练期间从未接触过近偏移距数据。这说明仅凭远偏移距训练数据，就成功外推了波场的运动学和动力学属性。此外，扩散模型的概率特性使其能够通过集成采样自然地量化不确定性，为从业者提供自我评估能力，使其无需真实值近偏移距参考数据即可评估重建可靠性。虽然在空间连续性遭到破坏的严重混叠数据上，方法性能会下降，但该方法在各种采集场景中展现出稳健的泛化能力，因此为实际地震处理工作流程提供了一种实用解决方案。

7 致谢

本出版物基于阿卜杜拉国王科技大学（KAUST）资助的研究工作。作者感谢 DeepWave 赞助方提供的支持。作者衷心感谢 CGG 提供在澳大利亚西北部近海采集的海洋拖缆数据集。作者还感谢勘探地球物理学家学会（SEG）公开提供 Mobil AVO Viking Graben第12测线野外数据集以及二维 SEG AdvancedModeling（SEAM）速度模型。本研究使用了位于沙特阿拉伯图瓦勒的阿卜杜拉国王科技大学（KAUST）超级计算实验室的计算资源。

8 代码可用性

支持本研究结论的数据及配套代码可在以下地址获取：https://github.com/DeepWave-KAUST/SSLDiff-Interpolation-pub。（在审稿过程中，代码库处于私有状态。稿件一经接收，我们便会将其公开。）

参考文献

Martin Widmaier、David O'Dowd 和 Carine Roalkvam。重新定义海洋拖缆采集。*FirstBreak*，37(11):57–62，2019。

Dirk J Verschuur、AJ Berkhout 和 CPA Wapenaar。自适应表面相关多次波消除。《*Geophysics*》，57(9): 1166–1177，1992。

Shijun Cheng、Ning Wang 和 Tariq Alkhalifah。采用多维卷积的自监督表面相关多次波压制。*arXiv* 预印本 *arXiv:2505.00419*，2025a。

Herbert W Swan。基于振幅随偏移距变化的速度。《*Geophysics*》，66(6):1735–1743，2001。

Tariq Alkhalifah。波形反演梯度的基于散射角的滤波。*Geophysical Journal International*，200(1):363–373，2014。

N Salaun、M Reinier、G Henin、G Gigou 和 A Wright。利用震源置于缆线之上的采集，在巴伦支海开展速度模型构建。载于*EAGE 2020*年度在线会议暨展览会，第2020卷，第1–5页。欧洲地球科学家与工程师协会，2020年。CE Jimenez-Tejero、Cesar R Ranero、Valenti Sallares 和 Claudia Gras。海洋地震反射数据的下延拓：一种被低估的速度模型改进工具。《国际地球物理学杂志》，230(2)：831–848，2022年。William Curry 和 Guojian Shan。利用多次波和预测误差滤波器进行近偏移距插值。《*Geophysics*》，75(6)：WB153–WB164，2010年。MM Nurul Kabir 和 DJ Verschuur。通过抛物线Radon变换恢复缺失偏移距。《地球物理勘探》，43(3)：347–368，1995年。Mauricio D Sacchi 和 Tadeusz J Ulrych。使用fx间隙填充算法恢复近偏移距。载于*SEG 1997*技术会议扩展摘要，第1096–1099页。勘探地球物理学家协会，1997年。Daniel O Trad、Tadeusz J Ulrych 和 Mauricio D Sacchi。利用高分辨率时变Radon变换实现精确插值。《*Geophysics*》，67(2)：644–656，2002年。Zhuo Xu、Daniel Sopher、Christopher Juhlin、Liguo Han 和 Xiangbo Gong。Radon域干涉插值，用于重建海洋地震数据中的近偏移距缺口。《应用地球物理学杂志》，151：125–141，2018年。GJ Van Groenestijn 和 DJ Verschuur。通过稀疏反演估计一次波，并将其应用于近偏移距数据重建。《*Geophysics*》，74(3)：A23–A28，2009a。GJA Van Groenestijn 和 DJ Verschuur。通过稀疏反演估计一次波并重建近偏移距：海洋数据应用。《*Geophysics*》，74(6)：R119–R128，2009b。Gabriel A Lopez 和 DJ Verschuur。闭环表面相关多次波消除及其在同时数据重建中的应用。《*Geophysics*》，80(6)：V189–V199，2015年。

Dong Zhang 和 E Verschuur。结合闭环表面相关多次波估计与全波场偏移，应用于浅水环境。载于*第81届EAGE会议暨展览会2019*，第2019卷，第1–5页。欧洲地球科学家与工程师协会，2019年。Yongna Jia 和 Jianwei Ma。机器学习能为地震数据处理做些什么？一种插值应用。《*Geophysics*》，82(3)：V163–V177，2017年。Benfeng Wang、Ning Zhang、Wenkai Lu 和 Jialin Wang。基于深度学习的地震数据插值：初步成果。《*Geophysics*》，84(1)：V11–V20，2019年。Randy Harsuko 和 Tariq A Alkhalifah。Storseismic：深度学习地震处理的新范式。*IEEE*地球科学与遥感汇刊，60：1–15，2022年。Ming Cheng、Jun Lin、Shaoping Lu、Shiqi Dong 和 Xintong Dong。基于多尺度注意力深度学习的地震数据重建。*IEEE*地球科学与遥感汇刊，61：1–18，2023年。S Mostafa Mousavi、Gregory C Beroza、Tapan Mukerji 和 Majid Rasht-Behesht。深度神经网络在勘探地震学中的应用：技术综述。《*Geophysics*》，89(1)：WA95–WA115，2024年。Olaf Ronneberger、Philipp Fischer 和 Thomas Brox。U-Net：用于生物医学图像分割的卷积网络。载于国际医学影像计算与计算机辅助介入会议，第234–241页。Springer，2015年。Jiho Park、Daeung Yoon、Soon Jee Seol 和 Joongmoo Byun。采用卷积U-Net并考虑最优训练输入数据重建地震野外数据。载于*SEG*国际博览会暨年会，第D023S027R005页。SEG，2019年。Xintao Chai、Genyang Tang、Shangxu Wang、Kai Lin 和 Ronghua Peng。深度学习在不规则与规则缺失三维数据重建中的应用。*IEEE*地球科学与遥感汇刊，59(7)：6244–6265，2020年。Jiho Park、Jihun Choi、Soon Jee Seol、Joongmoo Byun 和 Young Kim。利用卷积U-Net重建地震数据时合理选择训练数据集的方法。《*Geophysics*》，86(5)：V375–V388，2021年。Wenqian Fang、Lihua Fu、Meng Zhang 和 Zhiming Li。基于带纹理损失U-Net的地震数据插值。《*Geophysics*》，86(1)：V41–V54，2021a。Tao He、Bangyu Wu 和 Xu Zhu。基于多阶段神经网络训练过程的地震数据连续缺失道插值。《*IEEE*地球科学与遥感快报》，19：1–5，2021年。Shijun Cheng、Randy Harsuko 和 Tariq Alkhalifah。元处理：一种稳健的多任务地震处理框架。《地球物理学进展》，45(4)：1081–1116，2024年。Daeung Yoon、Zeu Yeeh 和 Joongmoo Byun。利用带跳跃连接的深度双向长短期记忆网络进行地震数据重建。《*IEEE*地球科学与遥感快报》，18(7)：1298–1302，2020年。Dario AB Oliveira、Rodrigo S Ferreira、Reinaldo Silva 和 Emilio Vital Brazil。利用条件生成对抗网络插值地震数据。《*IEEE*地球科学与遥感快报》，15(12)：1952–1956，2018年。Dekuan Chang、Wuyang Yang、Xueshan Yong、Guangzhi Zhang、Wenlong Wang、Haishan Li 和 Yihui Wang。利用双域条件生成对抗网络进行地震数据插值。《*IEEE*地球科学与遥感快报》，18(10)：1856–1860，2020年。Harpreet Kaur、Nam Pham 和 Sergey Fomel。利用生成对抗网络进行深度学习地震数据插值。《地球物理勘探》，69(2)：307–326，2021年。Qing Wei、Xiangyang Li 和 Mingpeng Song。利用条件生成对抗网络重建不规则缺失地震数据。《*Geophysics*》，86(6)：V471–V488，2021a。Shan Qu、Eric Verschuur、Dong Zhang 和 Yangkang Chen。仅用合成数据训练深度网络：基于深度学习的近偏移距重建，用于浅水野外数据的（闭环）表面相关多次波估计。《*Geophysics*》，86(3)：A39–A43，2021年。Owen Rohwer Huff、Vemund Stenbekk Thorkildsen、Thomas Larsen Greiner、Jan Erik Lie、Andreas Kjelsrud Evensen、Aina Juell Bugge 和 Jan Inge Faleide。利用卷积神经网络重建海洋地震数据近偏移距。《地球物理勘探》，72(6)：2164–2185，2024年。Tariq Alkhalifah、Hanchen Wang 和 Oleg Ovcharenko。Mlreal：弥合机器学习中合成数据训练与真实数据应用之间的差距。《地球科学中的人工智能》，3：101–114，2022年。Benfeng Wang、Dong Han 和 Jiakuo Li。利用自监督深度学习，通过塔式拖缆重建海洋地震数据中的缺失炮和近偏移距。*IEEE*地球科学与遥感汇刊，60：1–9，2022年。

Jiho Park、Sooyoon Kim、Soon Jee Seol 和 Joongmoo Byun。基于自监督学习的近偏移距缺失道外推。*IEEE*地球科学与遥感汇刊，2024。Jonathan Ho、Ajay Jain 和 Pieter Abbeel。去噪扩散概率模型。神经信息处理系统进展，33:6840–6851，2020。Alexander Quinn Nichol 和 Prafulla Dhariwal。改进的去噪扩散概率模型。载于国际机器学习会议，第8162–8171页。PMLR，2021。Shijun Cheng、Randy Harsuko 和 Tariq Alkhalifah。面向一体化地震处理框架的生成式基础模型。《地球物理学进展》，46:1173–1215，2025b。Ricard Durall、Ammar Ghanim、Mario Ruben Fernandez、Norman Ettrich 和 Janis Keuper。用于地震处理的深度扩散模型。计算机与地球科学，177:105377，2023。Qi Liu 和 Jianwei Ma。通过扩散概率模型实现生成式插值。《*Geophysics*》，89(1):V65–V85，2024。Xinyang Wang、Qianyu Ge、Xintong Dong、Shiqi Dong 和 Tie Zhong。用于三维地震数据重建的自监督扩散模型。《*Geophysics*》，90(5):1–124，2025。Jiaming Song、Chenlin Meng 和 Stefano Ermon。去噪扩散隐式模型。*arXiv*预印本 *arXiv:2010.02502*，2020。Zhou Wang、Alan C Bovik、Hamid R Sheikh 和 Eero P Simoncelli。图像质量评价：从误差可见性到结构相似性。*IEEE*图像处理汇刊，13(4):600–612，2004。Yangkang Chen、Sergey Fomel、Hang Wang 和 Shaohuan Zu。使用非平稳预测误差滤波器进行五维去假频地震数据插值。《*Geophysics*》，86(5):V419–V429，2021。Michel Schonewille、Andreas Klaedtke、Alan Vigner、John Brittan 和 Tony Martin。使用抗假频抗泄漏傅里叶变换进行地震数据规则化。*First Break*，27(9)，2009。Mostafa Naghizadeh 和 Mauricio Sacchi。地震记录的多维去假频Cadzow重建。《*Geophysics*》，78(1):A1–A5，2013。Wenqian Fang、Lihua Fu、Shaoyong Liu 和 Hongwei Li。使用基于深度学习的预测误差滤波器进行去假频地震数据插值。《*Geophysics*》，86(4):V317–V328，2021b。Qing Wei、Xiangyang Li 和 Mingpeng Song。使用条件Wasserstein生成对抗网络进行去假频地震数据插值。计算机与地球科学，154:104801，2021b。