

基于梯度增强扩散模型的三维阻抗反演

刘泽洋¹, 李景叶¹, 刘达伟², 张伟², 刘国昌¹, 陈小宏^{1*}

¹ 中国石油大学(北京)地球物理学院, 北京 102249

² 阿尔伯塔大学物理系, 埃德蒙顿, 加拿大, T6G 2E1

* 通信作者, chenxh@cup.edu.cn

收稿日期: 2025-11-13; 修回日期: 2026-01-15

国家自然科学基金(42374130)资助

摘要 传统的模型驱动反演方法依赖于先验信息和正则化, 往往会出现过度简化地质特征的现象。随着深度学习的快速发展, 扩散模型由于其能学习数据的复杂分布特征, 为求解反问题提供了更好的先验信息。受此启发, 本文引入扩散模型提高反演结果的可靠性和稳定性。该方法通过对合成阻抗模型的加噪和去噪过程学习其数据分布, 之后利用以地震数据为条件的后验采样, 引入低频模型约束、三维横向约束和动量估计, 提高横向连续性和梯度更新的稳定性, 实现地震数据和阻抗模型的稳健映射。合成数据和实际数据的应用结果表明, 新方法能够生成服从观测地震数据且细节丰富的阻抗模型, 与传统模型驱动方法相比, 本文方法对单井反演准确率提升了 5%。新的反演框架减弱了对先验信息的依赖并且大大提高了泛化性和可靠性, 同时也为求解其他复杂的地球物理反问题提供了新思路。

关键词 扩散模型; 3D 反演; 声波阻抗; 梯度增强; 横向约束

中图分类号: P631.4; TP391.4

3D impedance inversion based on a gradient-enhanced diffusion model

LIU Zeyang¹, LI Jingye¹, LIU Dawei², ZHANG Wei², LIU Guochang¹, CHEN Xiaohong^{1*}

¹ College of Geophysics, China University of Petroleum, Beijing 102249, China

² The Department of Physics, University of Alberta, Edmonton T6G 2E1, Canada

* Corresponding author, chenxh@cup.edu.cn

Received: 2025-11-13; Revised: 2026-01-15

Abstract Traditional model-driven inversion methods rely on prior information and regularization, which often lead to oversimplification of geological features. With the rapid development of deep learning, diffusion models have emerged as a powerful alternative for solving inverse problems, as they can learn the complex data distribution characteristics and provide better prior information. Inspired by this, this paper introduces diffusion models to enhance the reliability and stability of inversion results. The method learns the data distribution through the processes of noise addition and denoising applied to a synthetic impedance model. Subsequently, by utilizing posterior sampling conditioned on seismic data, it incorporates low-frequency model constraints, 3D lateral constraints, and momentum estimation to improve lateral continuity and the stability of gradient updates, thereby achieving a robust mapping between seismic data and the impedance model. Application results on both synthetic and

引用格式: 刘泽洋, 李景叶, 刘达伟, 张伟, 刘国昌, 陈小宏. 基于梯度增强扩散模型的三维阻抗反演. 石油科学通报, 2026, 11(2): 415–428

LIU Zeyang, LI Jingye, LIU Dawei, ZHANG Wei, LIU Guochang, CHEN Xiaohong. 3D impedance inversion based on a gradient-enhanced diffusion model. Petroleum Science Bulletin, 2026, 11(2): 415–428. DOI: 10.3969/j.issn.2096-1693.2026.01.012

real data demonstrate that the new method can recover impedance models that are both detailed and geologically plausible. Compared to traditional model-driven methods, the proposed method improves the accuracy of single-trace inversion by 5%. The new inversion framework reduces reliance on prior information and significantly enhances generalizability and reliability, while also providing new approaches for solving other complex geophysical inverse problems.

Keywords diffusion model; 3D inversion; acoustic impedance; gradient enhancement; lateral constraint

DOI: 10.3969/j.issn.2096-1693.2026.01.012

0 引言

声波阻抗是地震储层预测的核心参数之一,其精准预测是地震反射特征分析的关键^[1-3]。然而,子波的带通滤波效应,难以恢复阻抗的低频趋势和高频细节信息;此外,噪声也给阻抗预测带来了困难。为了解决这些问题,需要选择合适的反演方法。传统的反演方法,例如包括广义线性方法^[4]、L1 反演方法^[5]、自回归谱外推方法^[6],以及含横向连续性约束反演方法^[7]、全变分反演方法等^[8-11],虽然能在一定程度上解决阻抗反演问题,但是都依赖于准确的先验信息。

随着机器学习的快速发展,其在解决地球物理反问题中得到了充分的发挥,在阻抗反演方面,有 Caianiello 神经网络^[12]、数据模型驱动的网络^[13]等诸多方法。基于深度学习的反演方法通常可以分为监督学习、弱监督学习、无监督学习和生成模型 4 类。监督学习方法有着较高的预测精度,但是需要大量且标记良好的数据集^[14-15];而弱监督学习和无监督学习减弱了这一需求,利用物理模型约束在一定程度上提高泛化性,但是存在模型稳定性和可靠性的问题^[16];生成模型能学习复杂数据分布和生成真实样本的能力,因此得到了广泛的关注和快速发展。

在诸多生成模型中,扩散模型^[17]由于其灵活且稳健的方法脱颖而出,成为了深度学习强大的工具,并且在去噪^[18]和图像生成^[19]中得到了广泛的应用。扩散模型的核心思想是一个生成过程,通过对未知分布的图像进行加噪和去噪,学习数据分布作为先验信息,利用扩散后验采样从纯噪声中重建图像^[20]。扩散模型不仅可以用于图像的去噪和生成,也可以用于地震阻抗反演,生成高分辨率的阻抗模型。通过对比各种扩散模型的采样策略,去噪扩散概率模型(Denoising Diffusion Probabilistic Models, DDPM)在捕捉复杂分布方面表现出色,并且能生成高度逼真的图像^[21-23]。由于 DDPM 方法是无条件生成过程,无法求解遵循观测值的反问题,因此需要引入条件,使其能够遵循观测值来求解反问题的方法。可采用迭代潜变量细化^[24]、

扩散后验采样(Diffusion Posterior Sampling, DPS)^[25]以及去噪扩散零空间模型^[26]等方法生成与观测数据一致的反问题结果。其中,DPS 方法由于其出色的解决非线性问题和抗噪能力得到了广泛的关注^[23]。

传统的地震反演方法常依赖于先验信息,如低频模型,难以刻画地下的复杂构造,容易简化地质特征。相比之下,DPS 方法通过观测数据来更新梯度,将学习到的先验信息与物理模型约束动态整合,从而获得遵循观测数据的结果,提高反演结果的可靠性与准确性。本文基于 DPS 方法的阻抗反演策略,通过合成阻抗模型加噪和去噪过程,学习其复杂的数据分布、获得先验信息,通过条件约束后验采样得到反演结果。为了适应阻抗反演的复杂性,增加了低频模型约束、三维横向约束,提高反演结果的地质合理性;引入动量估计^[27],提高梯度更新的稳定性,最终得到一种带有三维横向约束的梯度增强的 DPS 方法(GDPS)。分别在合成数据和实际数据上进行了三维预测,并且与传统方法(最大后验估计方法,MAP)^[28-30]进行了比较。本文方法提出的反演框架减弱了对先验信息依赖,提高了泛化性和可靠性,为求解其他复杂的地球物理反问题提供了新思路。

1 理论方法

1.1 叠后正演模型

地震叠后记录由一系列反射系数与子波进行卷积得到。通常,反射系数序列被建模为白色(不相关)的尖峰序列。子波可以通过声波测井估计,也可以通过假设其相位进行统计估计。该模型假设地震数据经过适当的处理,从而认为子波是平稳且已知的^[31]。在这些假设下,正演模型通常表示如下:

$$\mathbf{y} = \mathbf{G}(\mathbf{x}_0) + \mathbf{n} \quad (1)$$

式中,正演模型 $\mathbf{G}$ 表示从阻抗 $\mathbf{x}_0$ 到反射率的转换,并与已知子波进行卷积。观测值 $\mathbf{y}$ 对应一组地震数据,通常存储为 $y(i, j, k)$, 其中 i 为离散时间索引,对应于 P 波的双程走时, j, k 对应于主测线、纵测线的公共中

心点(CMP)坐标。 $\mathbf{n}$ 表示空间不相干且方差已知的噪声。反射系数 r 的表达式如下:

$$r(i, j, k) = \frac{x_0(i+1, j, k) - x_0(i, j, k)}{x_0(i+1, j, k) + x_0(i, j, k)} \quad (2)$$

1.2 基于DPS方法的阻抗反演技术

扩散模型将生成过程定义为噪声过程的逆过程,能够从训练数据集中捕获先验信息。著名的扩散后验概率模型(DDPM)以离散形式表述,可以证明其与基于评分的生成模型的连续形式等价^[19,32],证明过程详见附录A。这里介绍DDPM的随机微分方程(SDE),并描述如何使用扩散后验采样过程求解非线性逆问题。

Song等人^[33]定义了SDE,将输入的自然图像逐渐转换为纯噪声,即扩散模型的前向(加噪)过程,目标是结合扩散模型的加噪和去噪过程来反演地下的阻抗,阻抗加噪过程可以用以下连续形式描述:

$$d\mathbf{x} = -\frac{\beta(t)}{2}\mathbf{x}dt + \sqrt{\beta(t)}d\mathbf{w} \quad (3)$$

其中, $\beta(t)$ 为过程的噪声分布^[18], $\mathbf{w}$ 表示维纳过程(一种连续时间随机过程,对具有独立正态分布增量的随机噪声进行建模)。当 $t=0$ 时,阻抗分布定义为 $\mathbf{x}_0 \sim P_{A1}$;当 $t=T$ 时,阻抗服从高斯分布,即 $\mathbf{x}_T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ 。前向过程如图1a所示。此外,定义 $\alpha_i = 1 - \beta_i = \beta(t + \Delta t)\Delta t$,其中 $\Delta t = 1/T$ 。定义 $\bar{\alpha}_i = \prod_{j=1}^i \alpha_j$ 表示从 $i=1$ 到 t 所有噪声水平的乘积。 $\mathbf{x}_{t-1}$ 与 $\mathbf{x}_t$ (含噪声)的关系见附录A中的式(A1)。

逆过程的目标是从高斯分布中恢复阻抗分布,即从 $\mathbf{x}_T$ 出发得到 $\mathbf{x}_0$ 。此步骤可以通过逆时间随机微分方程(SDE)实现^[34]。

$$d\mathbf{x} = \left[-\frac{\beta(t)}{2}\mathbf{x} - \beta(t)\nabla_{\mathbf{x}} \log p_t(\mathbf{x}) \right] dt + \sqrt{\beta(t)}d\bar{\mathbf{w}} \quad (4)$$

其中, t 对应于逆时间, $\bar{\mathbf{w}}$ 是 $\mathbf{w}$ 的时间逆过程。换句话说, $d\bar{\mathbf{w}} = \mathbf{w}(t - \Delta t) - \mathbf{w}(t)$ 。符号 $p_t(\mathbf{x})$ 是 $\mathbf{x}$ 在时间 t 的概率分布。 $\mathbf{x}_t$ 和 $\mathbf{x}_{t-1}$ (去噪后)之间的关系如附录A中的式(A8)所示。可以使用去噪神经网络 s_θ ^[35]来近似得分函数 $\nabla_{\mathbf{x}} \log p_t(\mathbf{x}_t)$,方法是最小化以下损失函数:

$$\theta^* = \operatorname{argmin}_{\theta} \|s_\theta(\mathbf{x}_t, t) - \nabla_{\mathbf{x}} \log p_t(\mathbf{x}_t)\|_2^2 \quad (5)$$

一旦从式(5)获得 θ^* ,就可以使用训练好的 $s_{\theta^*}(\mathbf{x}_t, t)$ 作为得分函数的估计值,将 $\nabla_{\mathbf{x}} \log p_t(\mathbf{x})$ 代入式(4),求解式(4)相当于从阻抗分布中进行采样,这是生成模型的目标^[25]。

对于逆问题,目标是根据观测数据 $\mathbf{y}$ 预测阻抗模型参数。然而,式(4)中的原始逆过程仅允许无条件更新^[32,36],这可能会生成与观测数据不匹配的阻抗模型。为了保证反演结果的准确性,需结合贝叶斯准则得到更通用的阻抗反演方法。为了利用扩散模型作为先验知识来求解逆问题,可以直接修改式(4),得到用于从后验采样的逆扩散采样器。

$$d\mathbf{x} = \left[-\frac{\beta(t)}{2}\mathbf{x} - \beta(t)\nabla_{\mathbf{x}} \log p(\mathbf{x}_t|\mathbf{y}) \right] dt + \sqrt{\beta(t)}d\bar{\mathbf{w}} \quad (6)$$

其中, $\nabla_{\mathbf{x}} \log p(\mathbf{x}_t|\mathbf{y})$ 可以根据贝叶斯规则计算。

$$\nabla_{\mathbf{x}} \log p(\mathbf{x}_t|\mathbf{y}) = \nabla_{\mathbf{x}} \log p_t(\mathbf{x}_t) + \nabla_{\mathbf{x}} \log p(\mathbf{y}|\mathbf{x}_t) \quad (7)$$

式(7)中得分函数项可以通过训练好的网络计算得出,第二项 $\nabla_{\mathbf{x}} \log p(\mathbf{y}|\mathbf{x}_t)$ 的闭式方程很难得到,可以使用近似值 $p(\mathbf{y}|\mathbf{x}_t) \approx p(\mathbf{y}|\hat{\mathbf{x}}_0(\mathbf{x}_t))$,似然函数可以写成^[25]:

$$p(\mathbf{y}|\hat{\mathbf{x}}_0(\mathbf{x}_t)) = \frac{1}{\sqrt{(2\pi)^N \sigma^{2N}}} \times \exp \left[-\frac{\|\mathbf{y} - \mathbf{G}(\hat{\mathbf{x}}_0(\mathbf{x}_t))\|_2^2}{2\sigma^2} \right] \quad (8)$$

其中, N 表示观测数据的维度,取似然函数对数的梯度将产生:

$$\nabla_{\mathbf{x}} \log p(\mathbf{y}|\mathbf{x}_t) \approx -\frac{1}{2\sigma^2} \nabla_{\mathbf{x}} \|\mathbf{y} - \mathbf{G}(\hat{\mathbf{x}}_0(\mathbf{x}_t))\|_2^2 \quad (9)$$

通过迭代反向扩散采样器(式(10)),可以从后验分布中生成样本。

$$d\mathbf{x} \approx \left[-\frac{\beta(t)}{2}\mathbf{x} - \beta(t) \left(s_{\theta^*}(\mathbf{x}_t, t) - \frac{1}{2\sigma^2} \nabla_{\mathbf{x}} \|\mathbf{y} - \mathbf{G}(\hat{\mathbf{x}}_0(\mathbf{x}_t))\|_2^2 \right) \right] dt + \sqrt{\beta(t)}d\bar{\mathbf{w}} \quad (10)$$

为了方便起见,将 $\hat{\mathbf{x}}_0(\mathbf{x}_t)$ 记为 $\hat{\mathbf{x}}_0$ 。有关如何根据 $\mathbf{x}_t$ 估计 $\hat{\mathbf{x}}_0$ 的详细信息,详见附录A。

1.3 三维DPS阻抗反演技术

式(9)右边表示传统反演方法中波形匹配目标函数的梯度。与传统反演类似,可以在扩散模型的条件采样过程中引入更多的先验信息,例如低频模型和横向约束。横向约束将提高反演在空间连续性方面的精度。本文提出的GDPS方法中后验概率的梯度可以表示为:

$$\begin{aligned} \nabla_{x_t} \log p_t(x_t|y) \approx s_{\theta^*}(x_t, t) - \\ l_r(\nabla_{x_t} \|y - G(\hat{x}_0)\|_2^2 + \lambda_1 \nabla_{x_t} \|\hat{x}_0 - \hat{x}_{\text{Low}}\|_2^2 + \lambda_2 \nabla_{x_t} \|D\hat{x}_0\|_2^2) \end{aligned} \quad (11)$$

其中, D 是相邻二维剖面之间沿横线方向(批量大小维度)的一阶导数的一阶差分算子, $\hat{x}_{\text{Low}}$ 是阻抗的低频模型。在训练阶段使用了二维训练方案,如图 1a所示,采样过程使用完整的三维体来生成三维结果,因此,有必要沿横向施加平滑度约束,这样既节省了训练成本,又增强了反演结果的三维可靠性。

为了确保梯度更新过程中的稳定性,引入梯度 ($g_t = \nabla_{x_t} \|y - G(\hat{x}_0)\|_2^2 + \lambda_1 \nabla_{x_t} \|\hat{x}_0 - \hat{x}_{\text{Low}}\|_2^2 + \lambda_2 \nabla_{x_t} \|D\hat{x}_0\|_2^2$)的一阶矩估计(m_t)和二阶矩估计(v_t)定义为:

$$m_t = \beta_1 m_{t+1} + (1 - \beta_1) g_t \quad (12)$$

$$v_t = \beta_2 v_{t+1} + (1 - \beta_2) g_t^2 \quad (13)$$

其中, β_1 和 β_2 是控制矩估计衰减率的参数^[27]。为了校正矩估计中的偏差使用:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^{T-t+1}} \quad (14)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^{T-t+1}} \quad (15)$$

梯度更新由下式给出:

$$\hat{g}_t = \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (16)$$

其中, ϵ 有助于避免数值不稳定,因为它能确保分母不会变得太小或为零。GDPS方法中的后验概率梯度可

以通过以下公式更新:

$$\nabla_{x_t} \log p(x_t|y) \approx s_{\theta^*}(x_t, t) - l_r \cdot \hat{g}_t \quad (17)$$

其中, l_r 表示学习率。

表 1 中比较了DPS和GDPS方法的采样流程, GDPS的输入数据是观测到的地震记录采样初始值为 x_T , 利用学习到的先验信息完成采样过程得到 x_0 。具体过程如图 1b所示, 其中, y 为地震数据, $\hat{x}_{\text{Low}}$ 为阻抗的低频模型, α_t 为噪声水平, x_t 为向阻抗(x_0)添加噪声直至变为纯噪声(x_T)的过程。定义 $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$ 表示从 $i=1$ 到 t 所有噪声水平的乘积, s_{θ^*} 表示网络, 表 2 给出部分主要符号的含义。

1.4 网络结构

本文采用一种简单的U-Net来训练逆过程, 该过程在生成模型的学习阶段对数据去噪。网络主要包括时间嵌入模块、卷积层和采样层。将时间映射到正弦函数和余弦函数中, 并且用线性层和ReLU激活函数处理时间信息。其余与传统U-Net架构相同, 通过下采样逐步降低图像的空间分辨率, 随后上采样逐渐恢复图像分辨率。网络第一层为 64 通道初始卷积层, 再经过多个下采样和上采样模块。时间在每个卷积层上, 嵌入的时间向量会被添加到特征图上, 因此可以利用时间信息, 完成与时间的匹配。下采样通道数依次为 64、128、256。在上采样之后, 特征图会经过 1×1 卷积层生成输出图像。该框架的时间步长控制去噪过程,

表 1 DPS和GDPS方法的采样工作流程比较

Table 1 Comparison of the sampling workflows of the DPS and GDPS methods

Algorithm 1 DPS	Algorithm 2 GDPS
Require: T, y, Σ_t, l_r	Require: $T, y, \Sigma_t, l_r, \lambda_1, \lambda_2, \hat{x}_{\text{Low}}$
1: $x_T \sim \mathcal{N}(0, \mathbf{I})$	1: $x_T \sim \mathcal{N}(0, \mathbf{I}), m_{T+1} = 0, v_{T+1} = 0$
2: for $t = T$ to 1 do	2: for $t = T$ to 1 do
3: $\hat{s} \leftarrow s_{\theta^*}(x_t, t)$	3: $\hat{s} \leftarrow s_{\theta^*}(x_t, t)$
4: $\hat{x}_0 \leftarrow (x_t + (1 - \bar{\alpha}_t)\hat{s}) / \sqrt{\bar{\alpha}_t}$	4: $\hat{x}_0 \leftarrow (x_t + (1 - \bar{\alpha}_t)\hat{s}) / \sqrt{\bar{\alpha}_t}$
5: $z \sim \mathcal{N}(0, \mathbf{I})$	5: $z \sim \mathcal{N}(0, \mathbf{I})$
6: $x'_{t-1} \leftarrow (x_t + (1 - \alpha_t)\hat{s}) / \sqrt{\alpha_t} + \Sigma_t z$	6: $x'_{t-1} \leftarrow (x_t + (1 - \alpha_t)\hat{s}) / \sqrt{\alpha_t} + \Sigma_t z$
7: $x_{t-1} \leftarrow x'_{t-1} - l_r \nabla_{x_t} \ y - G(\hat{x}_0)\ _2^2$	7: $g_t \leftarrow \nabla_{x_t} (y - G(\hat{x}_0))^2 + \lambda_1 \ \hat{x}_0 - \hat{x}_{\text{Low}}\ _2^2 + \lambda_2 \ D\hat{x}_0\ _2^2$
8: return $\hat{x}_0$	8: $\hat{m}_t = (\beta_1 m_{t+1} + (1 - \beta_1) g_t) / (1 - \beta_1^{T-t+1}),$ $\hat{v}_t = \sqrt{(\beta_2 v_{t+1} + (1 - \beta_2) g_t^2) / (1 - \beta_2^{T-t+1})}$
	9: $x_{t-1} \leftarrow x'_{t-1} - l_r \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon)$
	10: return $\hat{x}_0$




图 1 workflow结构示意图

Fig. 1 Schematic diagram of the workflow structure

表 2 主要符号表

Table 2 Main symbols

参数	含义
T	迭代次数
α_t, Σ_t	t 次噪声水平和方差
x_0	原始阻抗
x_T	纯噪声
x_t	x_0 添加噪声直至变为 x_T 的过程
s_{θ^*}	神经网络

而U-Net结构则有助于网络捕捉细节信息,从而生成高质量的图像。因此,该网络有效地结合了时间和空间特征,非常适用于扩散模型。

本研究采用的轻量级网络结构以便兼容大多数GPU处理器,虽然可以通过增加卷积通道数至1024

或加入自注意力机制来提升性能,但这些会大幅增加计算成本。

2 合成数据测试

本文使用Merrifield等人^[37]的模拟方法生成了两组合成阻抗模型。一个大小为 $300 \times 300 \times 800$ (主测线 $\times$ 纵测线 $\times$ 时间) 的数据集,用于在正向过程中构建训练数据集;另一个大小为 $256 \times 256 \times 1024$ (主测线 $\times$ 纵测线 $\times$ 时间) 的数据集,用于在采样过程进行反演测试。从第一个数据集中随机裁剪了5000个大小为 128×128 (道号 $\times$ 时间) 的阻抗剖面图块,如图2所示,采用Adam优化器进行训练,学习率为 $1e-3$,批量大小为128,总共迭代60 000次,参数 T 设置为1000。将训练好的网络应用于第二个合成数据集和真实数据进行后验采样。采用了传统的模型驱动方法和




图 2 用于训练网络的阻抗样本示例

Fig. 2 Examples of impedance samples for training the network

基于物理约束的深度学习方法进行比较。

输入信噪比定义为 $S/N_{in} = 20 \log_{10} \|y - n\|_2 / \|n\|_2$ ，其中 $y - n$ 表示干净的合成轨迹数据， n 表示噪声项。输出信噪比定义为 $S/N_{out} = 20 \log_{10} \|x_{true}\|_2 / \|x_0 - x_{true}\|_2$ ，其中 x_0 表示估计的阻抗， x_{true} 表示真实阻抗。

采样过程中，学习率 η 设置为 0.4，正则化参数 λ_1 、 λ_2 分别设置为 0.4 和 0.2。正则化参数 λ_1 、 λ_2 通过敏感性后选择，以便优化地质合理性和数据拟合度，控制初始模型约束和横向约束的强度。当低频约束太强时，反演结果会过度平滑忽略关键细节；当横向平滑过强时，反演结果出现横向假象问题。此外，学习率的选择也需要适度，较小的学习率会需要更多的迭代次数，导致训练时间更长，较大的学习率可能会导致网络训练不稳定难以收敛。图 3 展示了用于测试地震记录、阻抗模型以及从真实阻抗模型滤波获得的低频模型。采用中心频率为 30 Hz 采样间隔为 2 ms 的 Ricker 子波通过公式 (1) 来得到合成地震记录，并加入不同的噪声水平。

阻抗模型代表湖相页岩沉积，沉积体相对连续，厚度均匀，将参考面校正为 -200 ms。在 400~800 ms 之间，存在连通性良好的砂岩储层，也是研究的重点区间。在中深层，由于盐丘的存在，储层略有抬升，盆地中心表现出较低的阻抗，并且随着砂岩和砾岩含量的增加，阻抗呈放射状向外增大。对于该合成阻抗模型数据，主要目标是表征目标层段中的砂岩储层，特别是连通性良好的层位。

DPS 反演结果如图 4a 所示，可以看出，虽然能够学习先验知识为梯度更新提供有效的校正，但是反演结果的空间连续性较差，无法提供准确的阻抗值。因此，在反向采样过程中引入低频模型约束和横向约束来指导梯度更新，通过梯度的一阶动量估计和二阶动量矩估计来确保梯度的稳定更新。

GDPS 的反演结果如图 4b 所示，其中，输入地震数据的信噪比为 3 dB，低频模型通过对真实阻抗模型应用 5 Hz 滤波器得到。与 DPS 相比，GDPS 保留了有效处理复杂数据分布的能力和噪声数据的鲁棒性，




图3 合成模型参数

Fig. 3 Synthetic model parameters

从而减少了对低频模型的依赖,使得GDPS能够在数据驱动的先验信息和低频模型的使用之间取得平衡,从而获得更准确、更具地质意义的反演结果。

图4给出了两种方法的三维反演结果,从图中可以看出,两种方法在遵循地质原理的前提下都能获得稳定的反演结果,但GDPS方法在构造细节和精度方面均优于MAP方法,具有更强的抗噪能力,降低了对低频模型的依赖。对于目的层段,GDPS能够更准确地刻画砂体展布(图4黑色圆圈),并能更稳定地识别盐丘边界(图4黑色箭头),有利于后续储层预测。但两种方法都无法解决物理模型不准确的问题,在实际数据的反演中面临共同的挑战。此外,由于训练和采样过程中输入规模的不一致,分析了输入规模对GDPS的影响,结果表明,该算法可以处理大于训练窗口的数据,展现了其可扩展性。由于三维数据对内存的要求较高,本次实验未对三维数据进行进一步测试。

3 实际数据测试

对于三维实际数据的预测,无需训练数据或标签,可以直接对实际数据进行预测,消除了深度学习对

签数据集的需求,使该方法更加高效且可扩展。因此,该方法显著提升了深度学习模型的泛化能力,能够更有效地适应实际数据,与依赖标签数据的传统深度学习方法相比展现出更优异的泛化能力。图5a显示了该地区的地震记录,时间范围为3000~4024 ms,采样间隔为2 ms。横向范围为4000~4300道,纵向范围为5000~5256道。该区域构造整体简单,局部见小型褶皱与破碎带该区域包含一口井(1号井),井长为662 ms。基于1号井和地层信息,构建了一个低频模型,如图5b所示。由于3662 ms以外没有测井资料,无法建立有效的低频模型,并且主要储层段为3400~3600 ms。

图6a为模型驱动获得的反演结果,结果表现出良好的连续性和稳定性,然而,当提取单道结果(图7)并将其与测井数据进行比较时,可以识别出一些伪特征。物理引导的数据驱动方法如图6c所示,为了确保比较的公平性,所有方法均未使用带标记的测井数据。虽然无监督学习方法显示出总体稳定的结果,但对比单道结果表明可靠性较低。监督学习方法通常在井附近表现可靠的反演结果,但在较远区域泛化能力较差,因此,未对其进行对比。基于合成数据测试方法,应




图 4 反演结果

Fig. 4 Inversion results





图 5 用于阻抗反演的 3D 实际数据

Fig. 5 3D real data for impedance inversion

用GDPS方法对实际数据进行预测。图 6b 为未引入三维横向约束的GDPS方法的结果, 即预测沿主测线方向进行, 可以看出沿纵测线方向的连续性较差, 存在许多不理想的地质伪影(图 6 中的黑色圆圈)。引入三维横向约束后, GDPS方法的反演结果如图 8d 所示, 横向连续性有所改善(图 6 中的黑色圆圈)。GDPS方

法表现出更好的分辨率, 能够捕捉到更详细的信息(图 6 中的黑色和红色箭头), 而模型驱动方法对细节的刻画较少。通过对比三维时间切片方向, GDPS方法表现出更高的分辨率, 能够更有效地描述甜点区, 为河道识别或砂体预测提供可靠的支持。

为了进一步分析三维横向约束的影响, 图 7 展示



红色圆圈强调 GDPS 提供更高的垂直分辨率和横向连续性；黑色和红色箭头强调 GDPS 提供更高的分辨率

图 6 不同方法的反演结果

Fig. 6 Inversion results of different methods






图 7 用于阻抗反演的 2D 实际数据


Fig. 7 2D real data for impedance inversion




不含三维横向约束的GDPS结果: (a)主测线4083和(e) 纵测线5093



无监督学习的结果: (b)主测线4083和(f) 纵测线5093



含三维横向约束的GDPS结果: (b)主测线4083和(f) 纵测线5093



MAP结果: (d) 主测线4083和(h) 纵测线5093

图 8 不同方法反演结果的比较

Fig. 8 Comparison of inversion results from different methods

了主测线 4083 和纵测线 5093 两个剖面的地震记录以及低频模型(红色虚线表示井 1 的位置)。

图 8 为 GDPS 方法的反演结果, 包括未加横向约束和加横向约束的情况, 并将井 1 投影到剖面上(黑色曲线)。未加横向约束的 GDPS 方法已经显示出较高的分辨率, 但当加入横向约束时, 反演结果的横向连续性和稳定性明显改善。此外, 通过比较红色箭头和圆圈标记的区域, GDPS 方法提供了更可靠且分辨率更高的结果, MAP 在预测这些区域时存在困难。由于测井数据和地层信息有限, 无法构建详细的低频模型。

图 9 比较了 GDPS 和模型驱动预测结果, 通过测

井数据来验证预测的准确性, 其中, 黑色实线为测井数据, 紫色实线为 MAP 反演结果, 青色实线为 GDPS 反演结果, 红色实线为非监督学习反演结果, 黄色虚线为低频模型。从图 9 可以看到, 两种方法都与测井数据具有一定的相关性, GDPS 方法的结果表现出更高的一致性, 尤其是在红色箭头标记的位置, 为储层预测提供了更坚实的基础。计算单道信噪比可知, GDPS 方法的输出信噪比为 23.74 dB, 而模型驱动方法的输出信噪比为 22.56 dB, 这意味着相对于测井数据, GDPS 方法的精度提高了 5%。




图 9 单道反演结果对比

Fig. 9 Comparison of single-trace inversion results

4 结论

1) 本文针对传统的反演方法先验信息不足问题, 提出了一种基于扩散模型的阻抗反演方法, 该模型通过逐步加噪和去噪来学习先验信息, 利用后验采样近似来补偿先验信息的误差, 提高了在噪声环境下阻抗反演的性能。

2) 通过在二维模型上学习训练, 将三维横向约束反演技术和低频信息融入采样过程, 保留了二维训练

的高效性以及三维反演的可靠性, 此外, 梯度动量估计的加入进一步增强了算法的鲁棒性。实验结果表明, 与传统的模型驱动方法相比, 该方法在高信噪比条件下表现相似, 但在低信噪比条件下具有显著优势。与测井数据相比, 通过计算单井的 SNR, 反演精度提高了 5%, 证明了其在噪声环境下的优势, 并降低了对低频模型的依赖。

3) GDPS 方法无需使用对数近似, 适合求解非线性阻抗反演问题。

参考文献

- [1] 张永刚. 地震波阻抗反演技术的现状和发展[J]. 石油物探, 2002, 64(4): 595–621. [Zhang Y G. A review of seismic impedance inversion methods based on physics-informed neural network[J]. Geophysical Prospecting for Petroleum, 2002, 64(4): 595–621.]
- [2] LINES L R, TREITEL S. A review of least - squares inversion and its application to geophysical problems[J]. Geophysical Prospecting, 1984, 32(2): 159–186.
- [3] 孙正心, 金衍, 孟翰, 等. 基于深度学习数据融合的测井数据精细表征[J]. 石油科学通报, 2025, 10(1): 75–86. [SUN Z X, JIN Y, MENG H, et al. Fine characterization of logging data based on the deep learning data fusion[J]. Petroleum Science Bulletin, 2025, 10(1): 75–86.]
- [4] COOKE D A, SCHNEIDER W A. Generalized linear inversion of reflection seismic data[J]. Geophysics, 1983, 48(10): 665–676.
- [5] OLDENBURG D W, Scheuer T, Levy S. Recovery of the acoustic impedance from reflection seismograms[J]. Geophysics, 1983, 48: 1318–1337.
- [6] Walker C, Ulrych T J. Autoregressive recovery of the acoustic impedance[J]. Geophysics, 1983, 48(10): 1338–1350.
- [7] Hamid H, Pidlisecky A. Multitrace impedance inversion with lateral constraints[J]. Geophysics, 2015, 80(6): M101–M111.
- [8] 陈君青, 杨晓斌, 张潇, 等. 页岩力学性质研究中机器学习的应用: 现状、挑战与展望[J]. 石油科学通报, 2025, 10(5): 849–877, 29. [CHEN J Q, YANG X B, ZHANG X, et al. Application of machine learning in the study of shale mechanical properties: Current situation, challenges and prospects[J]. Petroleum Science Bulletin, 2025, 10(5): 849–877, 29.]
- [9] GHOLAMI A. Nonlinear multichannel impedance inversion by total-variation regularization[J]. Geophysics, 2015, 80(5): R217–R224.
- [10] GHOLAMI A. A fast automatic multichannel blind seismic inversion for high-resolution impedance recovery[J]. Geophysics, 2016, 81(5): V357–V364.
- [11] LI C B, Medina M R, Warren M, et al. Seismic super-resolution method: Enhancing reservoir delineation and characterization through high-resolution seismic data[J]. The Leading Edge, 2024, 43(12): 843–851.
- [12] FU L Y. Joint inversion of seismic data for acoustic impedance[J]. Geophysics, 2004, 69(4): 994–1004.
- [13] LIU Z Y, SONG W, CHEN X H, et al. High - resolution reservoir prediction method based on data - driven and model - based approaches[J]. Geophysical Prospecting, 2024, 72(5): 1971–1984.
- [14] 宋磊, 印兴耀, 宗兆云, 等. 基于先验约束的深度学习地震波阻抗反演方法[J]. 石油地球物理勘探, 2021, 56(4): 716–727. [Song L, YIN X Y, ZONG Z Y, et al. Deep learning seismic impedance inversion based on prior constraints[J]. Oil Geophysical Prospecting, 2021, 56(4): 716–727.]
- [15] 王泽峰, 许辉群, 杨梦琼, 等. 应用时域卷积神经网络的地震波阻抗反演方法[J]. 石油地球物理勘探, 2022, 57(2): 279–286, 296. [Wang Z F, Xu H Q, Yang M Q, et al. Seismic impedance inversion method based on temporal convolutional neural network[J]. Oil Geophysical Prospecting, 2022, 57(2): 279–286, 296.]
- [16] 罗功伟, 安小平, 姚卫华, 等. 非常规油气储层测井智能解释应用现状与发展趋势[J]. 石油科学通报, 2025, 10(5): 908–925. [LUO G W, AN X P, YAO W H, et al. Application status and development trends of artificial intelligence in logging interpretation for unconventional oil and gas reservoirs[J]. Petroleum Science Bulletin, 2025, 10(5): 908–925.]
- [17] SOHL-DICKSTEIN J, WEISS E, MAHESWARANATHAN N, et al. Deep unsupervised learning using nonequilibrium thermodynamics[C]. International conference on machine learning, Vancouver, Canada, 2025.
- [18] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[J]. Advances in neural information processing systems, 2020, 33: 6840–6851.
- [19] HO J, SAHARIA C, CHAN W, et al. Cascaded diffusion models for high fidelity image generation[J]. Journal of Machine Learning Research, 2022, 23(47): 1–33.
- [20] DHARIWAL P, NICHOL A. Diffusion models beat gans on image synthesis[J]. Advances in neural information processing systems, 2021, 34: 8780–8794.
- [21] LUO C. Understanding diffusion models: A unified perspective[J/OL]. arXiv preprint arXiv. 2022, 2208.11970. <https://arxiv.org/pdf/2208.11970>
- [22] CHAN S H. Tutorial on diffusion models for imaging and vision[J/OL]. arXiv preprint arXiv.2024, 2403.18103. <https://arxiv.org/pdf/2403.18103>.
- [23] DARAS G, CHUNG H, LAI C H, et al. A survey on diffusion models for inverse problems[J/OL] arXiv preprint arXiv. 2024,2410.00083. <https://arxiv.org/pdf/2410.00083>.
- [24] CHOI J, KIM S, JEONG, Y, et al. ILVR: Conditioning method for denoising diffusion probabilistic models[C].2021 IEEE/CVF International Conference on Computer Vision (ICCV), Montreal, QC, Canada, 2021.

- [25] CHUNG H, KIM J, MCCANN M T, et al. Diffusion posterior sampling for general noisy inverse problems[J/OL]. arXiv preprint arXiv.2022, 2209.14687. <https://arxiv.org/pdf/2209.14687>.
- [26] WANG Y H, YU J W, ZHANG J. Zero-shot image restoration using denoising diffusion null-space model[J/OL]. arXiv preprint arXiv.2022,2212.00490. <https://arxiv.org/pdf/2212.00490>.
- [27] KINGMA D P, BA J. Adam: A method for stochastic optimization[J/OL]. arXiv preprint arXiv:1412.6980.h <https://arxiv.org/pdf/1412.6980>.
- [28] TARANTOLA A. Inverse problem theory and methods for model parameter estimation[M]. Philadelphia, PA: Society for industrial and applied mathematics,2005.
- [29] 撒利明, 杨午阳, 姚逢昌, 等. 地震反演技术回顾与展望[J]. 石油地球物理勘探, 2015, 50(1): 184–202,20. [SA L M, YANG W Y, YAO F C, et al. Past, present, and future of geophysical inversion[J]. Oil Geophysical Prospecting, 2015, 50(1): 184–202,20.]
- [30] 卢占武, 韩立国. 波阻抗反演技术研究进展[J]. 世界地质, 2002, 21(4): 372–377. [LU Z W, HAN L G. The Development of the Research of the Wave Impedance Inversion Technique[J]. Global Geology, 2002, 21(4): 372–377.]
- [31] YILMAZ Ö. Seismic data analysis: processing, inversion and interpretation of seismic data[M]. Tulsa: Society of Exploration Geophysicists,2001.
- [32] SONG J M, MENG C L, ERMON S. Denoising diffusion implicit models[J/OL]. arXiv preprint arXiv. 2020, 2010.02502. <https://arxiv.org/pdf/2010.02502>.
- [33] SONG Y, ERMON S. Generative modeling by estimating gradients of the data distribution[C]. Advances in Neural Information Processing Systems, Vancouver, BC, Canada, 2019.
- [34] FRIEDMAN A. Stochastic differential equations and applications[M]. Berlin, Heidelberg: Springer Berlin Heidelberg, 1975.
- [35] VINCENT P. A connection between score matching and denoising autoencoders[J]. Neural Computation, 2011, 23(7): 1661–1674.
- [36] CHUNG H, RYU D, SIM B, et al. Improving diffusion models for inverse problems using manifold constraints[C]. Advances in Neural Information Processing Systems, New Orleans, Louisiana, USA, 2022.
- [37] MERRIFIELD T P, GRIFFITH D P, ZAMANIAN S A, et al. Synthetic seismic data for training deep learning networks[J]. Interpretation, 2022, 10(3): SE31–SE39.

(编辑 付娟娟)

第一作者: 刘泽洋(1996年—), 博士研究生, 主要从事深度学习与地震反演与地震信号处理等方面的研究, lzyllq123@126.com。

通信作者: 陈小宏(1962年—), 博士, 教授, 主要从事地震反演、地震资料处理和时移地震油藏监测技术等方面的研究工作, chenxh@cup.edu.cn。

附录A 扩散模型后验抽样

对于去噪扩散概率模型(DDPM)在 $t=1, 2, \dots, T$ 时的正向迭代可以表示为^[22]

$$\mathbf{x}_t = \sqrt{\alpha_t} \mathbf{x}_{t-1} + \sqrt{1-\alpha_t} \boldsymbol{\varepsilon}_{t-1}, \boldsymbol{\varepsilon}_{t-1} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}) \quad (\text{A1})$$

其中, α_t 表示噪声水平。由此, 得到DDPM中 $\mathbf{x}_t$ 和 $\mathbf{x}_{t-1}$ 之间添加噪声的过渡, 与公式3相同。利用高斯分布的闭合性, 得到 $\mathbf{x}_t$ 和 $\mathbf{x}_0$ 之间的关系

$$\mathbf{x}_t = \sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1-\bar{\alpha}_t} \boldsymbol{\varepsilon}_0, \mathbf{x}_t \sim \mathcal{N}(\mathbf{x}_t; \sqrt{\bar{\alpha}_t} \mathbf{x}_0, (1-\bar{\alpha}_t) \mathbf{I}) \quad (\text{A2})$$

其中, 将 $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$ 定义为从 $i=1$ 到 t 所有噪声水平的乘积。还可以得到

$$\mathbf{x}_0 = (\mathbf{x}_t - \sqrt{1-\bar{\alpha}_t} \boldsymbol{\varepsilon}_0) / \sqrt{\bar{\alpha}_t} \quad (\text{A3})$$

利用 Tweedie 公式^[25]可以得出:

$$\hat{\mathbf{x}}_0 = (\mathbf{x}_t + (1-\bar{\alpha}_t) \nabla_{\mathbf{x}_t} \log p_t(\mathbf{x}_t)) / \sqrt{\bar{\alpha}_t} \quad (\text{A4})$$

通过比较公式(A3)和(A4), 得到

$$\boldsymbol{\varepsilon}_0 = -\sqrt{1-\bar{\alpha}_t} \nabla_{\mathbf{x}_t} \log p_t(\mathbf{x}_t) \quad (\text{A5})$$

利用贝叶斯定理, 得到

$$\begin{aligned} q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0) &= \frac{q(\mathbf{x}_t|\mathbf{x}_{t-1}, \mathbf{x}_0)q(\mathbf{x}_{t-1}|\mathbf{x}_0)}{q(\mathbf{x}_t|\mathbf{x}_0)} \\ &= \frac{\mathcal{N}(\mathbf{x}_t; \sqrt{\alpha_t} \mathbf{x}_{t-1}, (1-\alpha_t) \mathbf{I}) \mathcal{N}(\mathbf{x}_{t-1}; \sqrt{\bar{\alpha}_{t-1}} \mathbf{x}_0, (1-\bar{\alpha}_{t-1}) \mathbf{I})}{\mathcal{N}(\mathbf{x}_t; \sqrt{\bar{\alpha}_t} \mathbf{x}_0, (1-\bar{\alpha}_t) \mathbf{I})} \end{aligned} \quad (\text{A6})$$

从该方程可以看出, 去噪步骤遵循高斯分布, 其均值($u_q(\mathbf{x}_t, \mathbf{x}_0)$)和方差($\Sigma_q(t)$)如下

$$u_q(\mathbf{x}_t, \mathbf{x}_0) = \frac{\sqrt{\alpha_t}(1-\bar{\alpha}_{t-1})\mathbf{x}_t + \sqrt{\bar{\alpha}_{t-1}}(1-\alpha_t)\mathbf{x}_0}{1-\alpha_t} \quad (\text{A7})$$

$$\Sigma_q^2(t) = \frac{(1-\alpha_t)(1-\bar{\alpha}_{t-1})}{1-\bar{\alpha}_t} \quad (\text{A8})$$

将方程(A4)代入(A6)可得

$$\mathbf{x}_{t-1} = \frac{\sqrt{\alpha_t}(1-\bar{\alpha}_{t-1})\mathbf{x}_t + \sqrt{\bar{\alpha}_{t-1}}(1-\alpha_t)\hat{\mathbf{x}}_0}{1-\bar{\alpha}_t} + \Sigma_q(t)\boldsymbol{\varepsilon} \quad (\text{A9})$$

其中

$$\hat{\mathbf{x}}_0 = (\mathbf{x}_t + (1-\bar{\alpha}_t)\nabla_{\mathbf{x}_t} \log p_t(\mathbf{x}_t)) / \sqrt{\bar{\alpha}_t} \quad (\text{A10})$$

化简后可得

$$\mathbf{x}_{t-1} = (\mathbf{x}_t + (1-\alpha_t)\nabla_{\mathbf{x}_t} \log p_t(\mathbf{x}_t)) / \sqrt{\bar{\alpha}_t} + \Sigma_q(t)\boldsymbol{\varepsilon} \quad (\text{A11})$$

由此, 得到了DDPM中 $\mathbf{x}_{t-1}$ 和 $\mathbf{x}_t$ 之间的去噪步骤, 与公式4相同。

DDPM中的无条件采样步骤可以通过以下步骤实现: (1)利用公式5中训练好的得分函数 $\mathbf{s}_{\theta^*}(\mathbf{x}_t, t)$ 近似 $\nabla_{\mathbf{x}_t} \log p_t(\mathbf{x}_t)$; (2)利用公式A10 计算 $\hat{\mathbf{x}}_0$; (3)利用公式A9 计算 $\mathbf{x}_{t-1}$, 重复步骤(1)~(3)直至 $t=1$ 。