

复杂地下介质下人工智能改进全波形反演： 技术分类、性能对比、工程应用与发展趋势

王承伟，狄婉茹，赵虹阳*

新疆理工职业大学人工智能学院，新疆 草湖

收稿日期：2026年7月29日；录用日期：2026年9月22日；发布日期：2026年9月30日

摘要

全波形反演(Full-Waveform Inversion, FWI)是重建地下高精度速度模型的关键技术，但传统模型驱动FWI在复杂介质中受限于周期跳变、计算成本高昂等固有缺陷。人工智能的引入为解决上述难题提供了全新求解框架。本文系统梳理了人工智能改进全波形反演的三大技术架构：纯数据驱动、两阶段模型-数据耦合及物理信息神经网络一体化方法。文章阐述了端到端直接反演、数据预处理辅助、预训练初值重构、生成对抗网络降阶正则及物理信息神经网络无网格反演等主流技术的原理与地质适用条件，并对比了其在复杂地层、盐体、断块等场景下的客观数值约束条件。综述覆盖了油气勘探、深部地质、地下碳封存监测及城市地震危险性定量评估四大应用领域，剖析了当前技术在泛化能力、CYCLE与工程化落地等方面的共性技术约束，并展望了无监督学习、多物理场耦合PINN及多模态联合反演等前沿发展方向。

关键词

全波形反演，复杂地下介质，深度学习，物理信息神经网络，模型驱动，数据驱动

Improvement of Full Waveform Inversion with Artificial Intelligence in Complex Subsurface Media: Technical Classification, Performance Comparison, Engineering Applications and Development Trends

Chengwei Wang, Wanru Di, Hongyang Zhao*

*通讯作者。

文章引用：王承伟，狄婉茹，赵虹阳. 复杂地下介质下人工智能改进全波形反演：技术分类、性能对比、工程应用与发展趋势[J]. 地球科学前沿, 2026, 16(9): 1386-1397. DOI: 10.12677/ag.2026.169123

Abstract

Full-waveform inversion (FWI) serves as a critical technique for acquiring high-precision subsurface velocity models. Nevertheless, conventional model-driven approaches suffer from inherent bottlenecks such as cycle jump and excessive computational cost when applied to complex media. The adoption of artificial intelligence offers an innovative paradigm to tackle the aforementioned challenges. This paper systematically sorts out three major technical frameworks for AI-enhanced full-waveform inversion, namely pure data-driven schemes, two-stage model-data integration strategies, and unified physics-informed neural network (PINN) approaches. It elaborates on the principles and applicable scenarios of mainstream technologies including end-to-end direct inversion, data pre-processing assistance, initial model reconstruction via pre-training, dimension reduction regularization using generative adversarial networks, and meshless inversion based on PINNs. Moreover, the performance and limitations of these technologies are compared across geological settings such as complex strata, salt bodies and fault blocks. This review encompasses four major application fields: oil and gas exploration, deep geology, underground carbon storage, and seismic hazard assessment. It analyzes core existing drawbacks concerning generalization capacity, depth of physical constraint integration, and 3D industrial deployment. Finally, cutting-edge research trends are prospected, including unsupervised learning, multi-physics coupled PINNs, and joint inversion with multi-modal data.

Keywords

Full-Waveform Inversion, Complex Subsurface Media, Deep Learning, Physics-Informed Neural Network, Model-Driven, Data-Driven

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

全波形反演(FWI)通过最小化观测与模拟波场残差,利用全波场信息重建地下介质参数,是当前精度最高的定量成像方法[1]。然而,传统模型驱动 FWI 高度依赖初始模型,在盐丘、逆冲断层等复杂介质中,因目标函数强非线性易收敛至局部极小解,产生周期跳变伪影[2][3]。同时,其抗噪性能较差、计算成本高昂且难以自适应融入地质先验,严重制约了该技术在油气勘探、深部探测及碳封存监测等领域的工程应用[4][5]。

深度学习凭借强大的非线性表征与高速推理能力,为突破 FWI 瓶颈提供了新路径[6]。现有人工智能 - 全波形反演方法可依据物理约束程度分为三类:纯数据驱动方法完全舍弃波动方程迭代流程,实现地震数据到速度场的直接映射;两阶段融合方法采用“网络预建模 + 传统 FWI 精修”的分步求解架构;物理信息神经网络(PINN)则将波动方程嵌入网络损失函数,实现物理约束与数据驱动的同步优化[7]。本文旨在系统分类归纳上述方法,剖析其在复杂介质下的性能优劣与核心痛点,并展望未来发展方向,旨在为构建高精度、稳健、高效的人工智能 - 全波形反演技术体系提供参考。

2. 传统模型驱动全波形反演基础与复杂介质固有缺陷

2.1. 传统 FWI 核心理论体系

经典模型驱动 FWI 以最小二乘准则构建目标泛函, 依托伴随状态法高效求取模型梯度, 迭代更新速度、密度、各向异性等地下介质物性参数[8][9]。其核心流程分为三步: ① 正演模拟, 基于声波/弹性波动方程完成震源波场正向延拓, 生成理论合成地震道集; ② 残差逆传, 将观测与模拟数据残差作为伴随震源残差反向延拓得到伴随波场; ③ 梯度更新, 通过正传波场与伴随波场时空相关得到模型修正量, 结合共轭梯度、L-BFGS 等优化算法迭代更新模型参数[10][11]。

为缓解复杂介质下非线性与不适定性问题, 现有传统改进策略主要包含四类: 一是多尺度频率分层反演, 先低频重建大尺度背景速度, 再高频细化地层细节, 降低局部极小影响; 二是鲁棒目标函数替换, 采用 L_1 范数、Huber 准则替代 L_2 范数, 提升噪声与振幅异常适应性[12]; 三是层析、包络反演预构建初始模型, 缩小初始模型与真实地层偏差[2]; 四是 TV (全变分正则) 正则、稀疏约束引入地质先验, 抑制反演病态畸变[9]。

2.2. 复杂地下介质中传统 FWI 关键瓶颈

传统模型驱动全波形反演在复杂地下介质条件下存在多重固有缺陷: 盐丘、强变速逆冲地层会造成地震波形相位大幅偏移, 若观测数据缺失低频成分, 目标函数全局最优解的吸引域范围狭窄, 单纯依靠迭代优化极易收敛至局部极小值, 最终得到畸变的速度模型[2]; 野外实测地震数据常伴随高斯随机噪声、振幅畸变、空间道缺失与低频信息缺失等问题, L_2 范数对异常数据敏感, 常规插值、去噪算法易损伤有效反射波信号, 进一步放大反演误差[12][13]; 断层、薄互层、盐体边界、深部弱反射地层等精细构造界面难以依靠传统正则化手段精准恢复, 反演成果普遍存在边界模糊、成像伪影、细节缺失等缺陷[5]。各类传统改进策略仅能小幅削弱上述固有缺陷, 无法从根本上破除迭代优化、网格数值正演、人工先验约束的固有框架, 基于深度学习的人工智能算法由此成为突破该系列数值约束的核心技术途径。

3. 人工智能改进全波形反演的技术演进: 从数据驱动到物理深度融合

人工智能改进全波形反演的发展历程, 本质上是不断在“计算效率”与“物理真实性”之间寻求平衡的过程。针对传统 FWI 在复杂介质中面临的周期跳跃与计算瓶颈, 研究者们首先提出了纯数据驱动方法, 试图通过端到端映射彻底规避迭代难题; 然而, 由于缺乏物理方程约束, 该方法在泛化能力上存在短板, 进而催生了结合传统波动方程优势的两阶段融合方法; 随着对物理机制理解的深入, 为了实现数据与物理的深度耦合, 物理信息神经网络(PINN)应运而生。本节将按照这一技术演进脉络, 系统阐述三类方法的原理及其在不同应用场景下的适配性。

3.1. 第一阶段: 以效率为核心的纯数据驱动方法——规避周期跳跃的尝试

面对传统 FWI 极易陷入局部极小值(周期跳跃)的痛点, 研究者最先尝试利用深度学习强大的非线性拟合能力, 建立从地震数据到速度模型的直接映射。这类方法完全抛弃波动方程迭代, 旨在实现秒级成像。该类方法完全舍弃传统 FWI 迭代正演 - 梯度更新流程, 仅依托地震 - 速度配对标注样本完成神经网络, 分为端到端直接速度建模、深度学习预处理辅助 FWI 两个分支, 网络推理阶段无需波动方程参与, 计算效率极高。

3.1.1. 端到端地震数据至速度场直接映射方法

以 U 型编码器 - 解码器全卷积网络为核心架构, 构建多炮地震记录输入、地下速度模型标签输出的

监督学习映射关系, 预测阶段仅执行网络前向传播, 无需初始速度模型, 从根源规避周期跳跃问题。Richardson 等人[14]、Zhu 等人[5]、Ulyanov 等人[15]围绕该基础架构从网络结构、约束条件、观测场景三个维度递进改进研究。

Richardson 等人[14]率先搭建改进 FCN 对称 U 型基础网络, 依托分层地层、SEAM 盐体合成样本完成训练, 可在纯净、含高斯噪声、缺失低频等多类数据条件下清晰还原地层与盐体形态, 单模型前向推理耗时仅数秒量级, 成像精度可与传统模型驱动 FWI 达到同一水平, 但基础 U 型网络未引入地质边界正则约束, 成像精度受训练集地质样本分布约束, 无法直接外推至野外未参与训练的地质构造, 为此文中提出利用生成网络扩充样本、拓展实际数据应用的改进思路。在此基础上, Wu 等人[16]提出 InversionNet 框架, 在 CNN 编解码主干中引入局部 CRF (条件随机场) 邻域约束, 弥补 Richardson 等人[14]单一 L_1 损失无法刻画断层边界的短板, 层状、曲断层模型测试结果显示其 MAE、相对误差均优于 TV 正则 FWI, 在 15~30 dB 噪声环境下仍保持稳定成像效果, 不过该方法依旧受训练样本分布局限, 作者进一步提出融合波动物理方程、引入贝叶斯不确定性分析的完善方案。针对前两类方法均面向地表地震观测、无法适配井间特殊采集体系的不足, Ulyanov 等人[15]提出了一种在井间采集几何条件下利用图像训练人工神经网络(ANNs)构建速度模型的新方法, 通过将地震数据与速度场之间的非线性映射转化为图像到图像的深度学习任务, 该方法不仅克服了传统断层扫描对初始模型的强依赖性, 还显著提升了复杂地下结构的成像精度与反演效率, 但受网络结构与观测系统约束, 对薄互层精细地层的刻画仍存在明显偏差[17]。

此类端到端数据驱动方法统一具备推理效率高、无需初始模型、规避周期跳跃等优势, 但共性短板十分突出: 该类算法存在两项固有数值约束: ① 构建足量标注合成样本的数值模拟与存储成本较高; ② 网络训练过程未嵌入地震波动控制方程, 针对训练集分布外的复杂地质构造, 成像误差会显著上升。

3.1.2. 深度学习预处理辅助 FWI

该类深度学习分支不直接参与地下速度场的反演求解, 仅作为前置预处理模块完成地震数据降噪、缺失道插值、断层自动分割等加工工作, 通过优化输入数据品质间接改善复杂介质条件下传统 FWI 的反演稳定性, 现有相关研究分别围绕噪声压制、缺失道重建、断层识别、散射波场校正四大处理需求形成完整技术方案。

在随机噪声压制方面, Saad 等人[12]构建 DDAE (深度去噪自编码器), 采用合成样本监督预训练、野外实测数据无监督相关系数损失微调的两步迁移学习方案, 可在低信噪比地震剖面中实现随机噪声的有效压制, 规避 $f-x$ 域传统降噪算法破坏有效反射波特征的问题, 适配深部地层、地下碳封存工区低品质观测资料预处理场景。针对地震道缺失引发的空间混叠问题, Karimpouli 等人[13]类比图像超分辨率任务搭建 8 层残差卷积网络实现地震数据去混叠插值, 可消除道缺失造成的 FK 频谱畸变、完整恢复地层同相轴并生成高密度道集, 有效优化盐丘、复杂断块工区 FWI 基础数据质量, 但模型泛化能力受训练集道间距、地层结构特征约束。面向复杂构造先验信息自动提取需求, Wu 等人[18]提出轻量化 3D U-Net 网络 FaultSeg3D, 将三维断层识别转化像素级二值分割问题, 引入平衡交叉熵损失缓解断层像素样本不平衡难题; 仿真数据与多套海外野外三维地震资料测试证实该网络可精准识别弯曲、密集弱反射断层, 能够自动为 FWI 提供断层地质先验约束, 但其训练样本仅覆盖平面断层, 对逆冲、铲状特殊断层的识别精度存在明显不足。针对深部地层多重散射干扰难题, Sun 等人[19]设计 ScaDec U-Net 散射重建框架, 以复场实虚部双通道特征作为输入快速重建地下介电常数分布, 强散射介质成像无块状伪影, 推理效率显著优于传统迭代散射反演算法, 可应用于深部复杂散射地层的预处理流程。如图 1 所示为深度学习预处理辅助 FWI 方法。




Figure 1. Deep-learning-aided preprocessing for FWI (Ref. [19])

图 1. 深度学习预处理辅助 FWI (引自文献 19)

尽管纯数据驱动方法在推理速度上具有绝对优势，且从根本上规避了周期跳跃，但其“黑盒”特性导致物理约束缺失。在训练数据覆盖不到的复杂地质场景(如未知构造)中，其预测结果往往缺乏地质合理性。为了解决这一“物理真实性”不足的问题，两阶段融合方法应运而生。

3.2. 第二阶段：兼顾效率与物理的两阶段融合方法——从“黑盒”走向“灰盒”

为了弥补纯数据驱动方法缺乏物理约束的短板，同时保留其快速建模的优势，研究者提出了“网络预测 + 传统 FWI 精修”的两阶段策略。这种“灰盒”模式利用神经网络提供高质量初始模型或正则化约束，将反演问题拉入全局最优解的吸引域，随后交由波动方程进行物理约束下的精细反演。该类方法兼顾深度学习快速建模优势与波动方程完备物理约束，采用网络预测、波动迭代分步执行的解耦架构，两段流程相互独立、损失函数不统一耦合，仅依靠网络输出结果作为传统 FWI 的输入先验，实现难度更低、工程落地性更强。依据网络在反演链路中的作用，可分为网络前置生成初始速度场、网络全程嵌入迭代循环两条技术路线。

3.2.1. 网络前置生成初始速度场

该类方法将深度学习作为独立前置模块，仅在反演启动阶段单次输出背景速度模型，后续迭代过程不再调用网络，完全依托波动方程完成精细更新，核心目标是解决传统 FWI 对高精度初始模型的强依赖性、迭代易陷入局部极小的固有缺陷。

He 等人[4]提出 DNN-FWI 重参数化反演框架，将整个流程划分为网络预训练拟合平滑速度模型、波形残差驱动网络权重梯度优化两个阶段，依托 32 层链式卷积网络对速度场施加隐式正则约束；在 BP 盐丘、Marmousi2 模型测试中，该方法可大幅减少迭代次数，地层界面成像效果优于 TV 正则 FWI，算法短板在于成像质量仍受预训练样本品质制约。

在此基础上，Chen 等人[20]提出 HML 混合机器学习求解框架，引入 CAE (卷积自编码器)自编码器对高维地震数据降维至低维隐空间，以隐空间残差构建目标函数，并借助自动微分技术连通网络与波动方程的梯度求解链路；通过多尺度策略分别提取走时运动学信息与波形动力学特征，仅依靠均质简易初始模型即可逐级重建高低波数速度结构，同时将观测数据存储量压缩百倍，收敛稳定性显著提升，更适配深部地壳广角复杂介质反演场景。

针对常规深度学习反演训练集分布偏差、难以同步更新深浅层构造的问题，Wu 等人[21]设计 CNN-RWI 内外双循环自适应反馈架构，融合 U-Net 与 RTM(逆时偏移)偏移图像联合预测速度模型，并利用分层 K-means 聚类动态生成训练样本，持续修正样本与真实地层的分布偏差，实现深浅层速度与地层界面同步更新；若将网络输出结果作为 CG (共轭梯度)-FWI 的初始模型开展二次迭代反演，能够进一步优化盐体、断层的成像精度，更贴合油气勘探复杂构造工区的应用需求。这种策略在油气勘探中尤为适用，

因为油气工区通常具备一定的井数据作为网络训练基础，且对盐丘边界的物理准确性要求极高，两阶段法恰好平衡了这两点需求。如图 2 所示为网络前置生成初始速度场方法。




Figure 2. Generation of initial velocity field by network prior (Ref. [20])

图 2. 网络前置生成初始速度场(引自文献 20)

3.2.2. 网络嵌入完整迭代循环

与前置生成初值的模式不同，该类方法将训练完备的生成网络作为恒定参数化算子嵌入全部迭代流程，以低维隐变量替代海量网格节点作为优化变量，依靠生成网络内置的地质空间先验实现隐式正则约束，包含 NNFWI、FWIGAN 两类代表性算法。

Zhu 等人[5]提出 NNFWI 融合反演方法，以生成网络实现地下速度场隐式重参数化，无需大规模标注速度样本；将网络输出叠加基础速度模型作为波动方程输入，结合 Dropout 蒙特卡洛采样实现反演结果不确定性定量评估。数值测试证实，含噪声盐体模型下该方法成像质量优于常规 FWI 与 TV 正则 FWI，计算资源增量可控，对常规地表地震观测体系具备良好通用性。Richardson 等人[14]提出降阶反演框架，采用 DCGAN 完成地质速度模型的隐空间表征，整体分为生成网络预训练、隐变量迭代优化两个解耦阶段。第一阶段构建涵盖层状地层、盐丘构造的合成样本集完成生成器训练，并在损失函数中增设介质速度值域约束，保障生成模型符合沉积地质规律；第二阶段固定生成网络全部权重，仅对低维隐向量实施迭代更新，将波形残差梯度反向传播至隐变量，无需直接优化网格速度参数。SEAM 二维盐体模型试验表明，该方法可显著削减正演模拟总次数，盐体边界地质合理性优于传统 L-BFGS FWI；该算法存在 GAN 模式崩溃、生成模型空间尺度固定、迭代收敛结果对初始隐变量高度敏感等数值约束，后续可联合层析成像构建初始隐向量、采用分块拼接策略拓展至三维大规模油气、地下碳封存评价工区。如图 3 所示为网络嵌入完整迭代循环的方法。




Figure 3. Network embedded in the complete iterative loop (Ref. [5])

图 3. 网络嵌入完整迭代循环(引自文献 5)

虽然两阶段方法有效解决了初始模型依赖问题，但网络预测与波场迭代在本质上是解耦的，物理信息未能真正渗透到网络训练的內部。为了追求数据驱动与物理方程的“深度耦合”，实现真正的无网格与一体化反演，物理信息神经网络(PINN)成为了最新的研究前沿。

3.3. 第三阶段：追求深度耦合的 PINN 一体化方法——物理与数据的终极统一

不同于前两阶段的拼接或辅助模式，PINN 将波动方程直接嵌入神经网络的损失函数中，实现了物理约束与数据驱动的同步优化。这是 AI-FWI 从“辅助工具”向“物理驱动”转变的关键一步。区别于两阶段拼接方法，PINN 将声波/弹性波动控制方程、地表自由边界条件、初值条件、观测地震数据残差共同纳入网络复合损失函数，网络同时近似波场与地下速度场，实现物理约束与数据驱动同步训练，无需依赖传统结构化网格离散，属于一体化融合人工智能背景下的全波形反演范式。

Operto 等人[7]完整梳理 PINN 基础理论体系，对比其与有限元方法的无网格求解特性，依托自动微分求解偏微分方程残差，可同步实现地震正演与速度反演；相较于传统数值模拟手段，PINN 不受网格离散约束，适配高维、观测数据稀缺场景，该类网络优化目标为非凸泛函，迭代过程易收敛至局部极小解；配点采样策略、损失项权重分配方案直接决定复杂断块构造的成像质量。

在 PINN 理论基础之上，Karimpouli 等人[13]开展横向对比研究，分析高斯过程(GP)与 PINN 两类无网格算法在地震波动方程反演中的优劣：GP 天然具备贝叶斯不确定性量化能力，但随着样本数量提升，协方差矩阵求逆带来的计算开销会急剧上升；无论有无噪声干扰，PINN 重建速度场的精度均优于 GP，且更易拓展至弹性多参数联合反演，适合深部地质、地下碳封存等观测资料匮乏的工区。PINN 的无网格和小样本特性，使其在深部地质探测或城市地下空间等观测数据稀缺、难以获取大量标注样本的场景下展现出巨大潜力。它不再依赖海量数据“暴力”训练，而是依靠物理方程的归纳偏置来约束反演结果。

Table 1. Comparison of three modeling technical systems
表 1. 三类建模技术体系对比表

算法架构	物理约束程度	计算效率 (训练/推理)	初始模型 依赖度	数据需求	模型外推性能	工业化部署 成熟度
纯数据 驱动方法	完全脱离波动方程 迭代，仅通过标注 样本拟合映射关系	训练：严重依赖大 规模、高质量成对 标注样本 推理：端到端 直接输出速度场	无	需大量 地震-速度成对 标注样本，合成 样本构建成本 高昂	受训练集地质 覆盖度约束， 陌生构造下误差 显著放大	以二维理论验证 为主，野外实测 数据适配性不足
两阶段 融合方法	分阶段解耦，后段 依托传统 FWI 实现 波动方程完备约束	训练：前置网络 训练 + 传统 FWI 迭代 反演：可减少 FWI 迭代次数	网络输出作为 高质量初值， 降低对人工 初始模型的 依赖	前置网络需标注 样本，后段 FWI 可适配常规野外 观测数据	后段波动方程 约束保障地质 合理性，泛化性 优于纯数据驱动	可直接嵌入现有 FWI 工作流， 落地门槛低， 为当前工程主流 过渡方案
PINN 一体化 方法	波动方程、边界 条件、初值条件 全程嵌入损失 函数，同步优化	训练：非凸优化 收敛难度大，损失 权重调试繁琐 推理：中无网格 离散，小样本场 景算力消耗低于 传统网格正演	可从零开始 训练，对初始 先验模型依赖 弱	不依赖成对标注 样本，仅需少量 观测数据和物理 方程即可驱动， 适用于小样本、 稀疏观测场景	物理约束保障外 推合理性，复杂 断块构造下仍 存在平滑畸变 问题	多局限于二维 理论模型验证， 三维规模化应用 存在算力与收敛 瓶颈

Rasht-Behesht 等人[22]面向二维声波反演提出双网络 PINN-FWI 专用架构，两套网络分别拟合波场与地下速度场，并通过输入、方程尺度标准化处理保障训练收敛稳定，仅依靠少量地表观测记录与波场

快照就能重建低速异常体、层状地层，还可等效实现吸收边界效果；该架构的局限在于处理复杂断块构造时成像易产生平滑畸变，同时损失权重调试流程繁琐，后续可向多震源联合反演、多地球物理协同成像方向拓展，为地震灾害数值模拟、深部地质轻量化反演提供新路径。

综合上述研究可见，PINN 一体化反演具备无网格正演、小样本训练、全程嵌入物理约束等突出优势，但也存在明显短板：网络训练收敛难度较高，针对三维大规模盐体、逆冲地层等复杂介质建模精度不足，现有 PINN-FWI 研究多局限于二维理论模型验证，面向三维野外工区的规模化工程应用仍存在大量待突破的技术瓶颈。

三类建模技术体系对比如表 1 所示，三类建模技术体系在物理约束机制、计算运行效率及数据依赖程度等核心维度存在显著差异，整体形成优势互补、各有适用场景的技术布局。

纯数据驱动方法无需开展波动方程迭代求解，具备推理速率快、计算成本低的突出优势，同时可从根本上规避迭代过程中的周期跳跃问题。但该方法完全脱离物理规律约束，模型泛化性能高度依赖训练数据集的地质覆盖范围与样本质量，仅适用于数据储备充足、地下构造相对简单的工区，可满足大批量快速建模的工程需求；两阶段融合方法有效结合了深度学习快速建模的优势与波动方程的完备物理约束，工程落地门槛较低，能够直接适配、嵌入现有全波形反演工作流程，是现阶段工程应用中的主流过渡方案。但该方法存在固有局限性，网络预测过程与波场迭代计算相互解耦，物理机制与数据模型的融合深度不足，无法实现数据驱动与物理约束的双向协同优化，模型精度与适配能力存在一定上限；PINN 一体化方法将波动方程约束直接引入神经网络损失函数，具备最为完备的物理约束体系，同时兼具无网格离散建模、小样本场景适配等技术特性。但该方法存在训练收敛难度大、三维场景计算开销极高的问题，目前相关研究与应用仍以二维模型理论验证为主，是未来物理与数据深度融合建模的核心发展方向。

总体而言，三类技术方法各有优劣、无绝对最优方案，实际工区应用中，需结合研究区地质构造复杂程度、观测数据品质、现有计算资源及建模精度需求开展综合选型。

3.4. 从理论到工程：三维规模化应用的尺度壁垒与挑战

上述三类从数据驱动到物理耦合的演进方法，虽然在二维模型中均已验证有效，但在向三维工业化迈进时，均面临着共同的尺度壁垒。前述三类 AI 辅助全波形反演方法在二维模型测试中均表现出良好的反演效果，但该类技术由二维理论研究向三维工业勘探场景推广时，存在显著的尺度壁垒。三维地震数据集的数据量随空间维度呈三次方增长趋势，对存储架构、I/O 吞吐带宽、分布式并行计算资源提出更高工业化要求。本节重点分析三维 AI-FWI 工程落地过程中，在数据存储访问、分布式训练、硬件适配及数值计算方面的核心瓶颈。

3.4.1. 三维数据体系下的存储与 I/O 约束

相较于二维理想模型，三维地质场景的地震数据与速度模型空间维度大幅提升。常规海洋三维拖缆工区单炮数据可达 GB 级，全域数据规模普遍达 TB 至 PB 级别，海量数据带来了突出的存储与读写压力。

数据驱动方法需构建覆盖复杂三维地质特征的大规模标注数据集，存储开销巨大；PINN 方法虽无需成对样本训练，但三维波场快照的存储同样耗费大量硬件资源。训练过程中，GPU 的高性能计算能力常受限于 CPU 与 GPU 间的数据传输效率，传统串行读取模式无法适配三维海量数据的实时加载需求，易造成算力闲置，形成 I/O 瓶颈。现阶段主要通过 Lustre、GPFS 并行文件系统结合数据预加载流水线技术，缓解三维数据的读写压力。

3.4.2. 三维建模的分布式训练架构约束

三维高分辨率反演模型参数量与计算量大幅增加，单卡显存无法满足训练需求，必须依托分布式并

行训练策略提升训练效率、实现模型收敛。当前适配 AI-FWI 体系的并行训练方式主要分为数据并行、模型并行与流水线并行三类。

数据并行通用性强,适用于数据驱动与两阶段融合方法。该方式将三维数据集分批次分配至各计算节点,各节点独立计算梯度后通过 All-Reduce 机制完成全局参数更新,但其通信开销会随集群节点扩容持续增大,成为主要性能限制因素;模型并行主要应用于 PINN、三维 U-Net 等超大参数量网络,通过拆分网络层级并分配至不同计算设备,解决单卡承载不足的问题。该方法在正反传播过程中需频繁交互激活值与梯度信息,对设备间互联带宽依赖度极高;流水线并行融合数据并行与模型并行优势,通过网络分层拆分与数据微批次调度,实现多设备异步协同计算,有效提升集群硬件利用率,是未来三维 AI-FWI 大规模集群训练的主流发展方向。

3.4.3. 工业集群硬件与数值计算瓶颈

以 A100、H100 为核心的工业级 AI 集群可提供高性能算力支撑,但三维 AI-FWI 的工程应用仍受制于显存容量、通信延迟与数值稳定性三大核心问题。

显存资源不足是制约高分辨率三维建模的首要瓶颈。三维卷积生成的高密度特征图占用大量显存,即便采用 80 GB 显存算力设备,开展全域高分辨率三维反演,仍需依靠梯度检查点、混合精度训练等方式优化显存占用;多卡协同训练的通信延迟直接影响模型并行加速效果,GPU 间 NVLink 带宽与节点间 InfiniBand 网络时延决定了梯度同步效率。PINN 方法需频繁求解高阶偏导数,梯度交互数据量更大,不合理的集群拓扑结构会显著降低并行拓展性能;数值精度与计算稳定性的平衡是工业应用的核心难点。FP16、BF16 低精度计算可有效提速并节约显存,但在三维复杂介质反演中,易引发波场数值频散、梯度爆炸等问题,需在计算效率与数值稳定性之间寻求最优平衡。

综上,二维理论与三维工业场景的尺度差异,是限制 AI-FWI 技术落地应用的核心壁垒。突破该瓶颈不仅需要算法轻量化优化,更依赖存储、并行计算与硬件体系的协同适配。解决三维数据读写、分布式训练与数值计算的工程难题,是推动 AI 辅助全波形反演技术从理论研究走向油气勘探、深部探测等工业应用的关键。

4. 人工智能背景下的全波形反演在复杂地下介质多领域工程应用

油气勘探、深部地壳探测、地下碳封存监测、城市地震灾害评估是人工智能背景下的全波形反演四大典型工程应用场景,四类场景因地质复杂度、观测条件与成像需求不同,对人工智能-全波形反演技术路线的适配性存在显著差异。

油气勘探是人工智能辅助 FWI 工业化验证最为充分的应用领域;油气工区普遍发育盐丘、逆冲断裂、薄层互层、气云等强横向变速地质体,传统模型驱动 FWI 易产生周期跳变、盐丘边界模糊等成像伪影。针对油气储层成像需求,现有技术形成三条适配路径:一是 CNN 前置生成初始速度模型,为传统 FWI 提供高质量初值,从源头缓解周期跳跃问题,DNN-FWI、CNN-RWI 等框架在 BP 盐丘、Marmousi2 模型测试中均证实可显著提升收敛稳定性与成像精度[4] [21];二是 GAN 降阶正则,将生成网络嵌入迭代循环,以低维隐变量替代海量网格节点,依靠生成网络内置的地质空间先验实现隐式正则约束,有效抑制盐体边界畸变与虚假构造[5] [14];三是 FaultSeg3D 等分割网络自动提取断层先验信息并引入 FWI 正则项,优化断块储层界面成像精度[18]。上述方法已在北海 Valhall 油田、SEAM 盐体等多个基准算例中完成验证,网络快速推理特性可显著缩短三维工区建模周期[7] [14],直接服务油气储层定量评价。

面向大陆深部广角地震探测场景,观测数据存在大偏移距、深部反射能量弱、噪声干扰突出、观测站点稀疏等问题,传统迭代 FWI 算力成本高且易收敛至局部极小。针对深部探测的特殊数据条件,两类方案展现出突出适配性:HML 混合机器学习框架通过 CAE 自编码器对高维广角地震数据降维至低维隐

空间,以隐空间残差构建目标函数,可将观测数据存储量压缩百倍,同时依靠多尺度隐空间特征同步反演浅层与深部地壳速度结构,仅依靠均质简易初始模型即可逐级重建高低波数速度结构,收敛稳定性显著提升[20];无网格 PINN 方法则无需依赖传统结构化网格离散,仅利用少量初至波场快照即可恢复莫霍面、近地表低速带等深部构造特征,省去大规模网格正演流程,显著降低深部建模算力消耗[9] [13],尤其适合观测资料匮乏的深部地质工区。

地下碳封存场地评价对反演结果地质合理性与抗噪能力要求严格,核心需求是精准识别盖层完整性、断裂分布及低速渗漏通道,服务地层封闭稳定性定量评估与长期动态监测。针对碳封存监测的特殊要求,人工智能-全波形反演形成“预处理+正则约束”的组合方案:DDAE 深度去噪自编码器、残差插值网络可有效处理低信噪比野外监测地震数据,滤除随机噪声并修复缺失道,避免传统降噪算法损伤有效反射波的缺陷[12];GAN-FWI 的隐式地质正则能够有效避免反演产生虚假渗漏构造,确保反演结果符合沉积地质规律,降低误判风险[5] [14]。依托人工智能-全波形反演的快速建模能力,可实现碳封存场地的长期动态监测,精准识别微小断裂与 CO₂ 注入引发的低速异常,定量评估地层封闭稳定性。

针对城市地下介质地震灾害风险评估,浅层低速层发育、人工构筑物散射干扰强、观测道稀疏缺失等复杂条件严重制约传统建模精度。针对城市近地表场景的特殊性,两类轻量化方案具备显著工程优势:纯数据驱动端到端网络推理阶段仅执行网络前向传播,无需波动方程迭代,可快速重建近地表速度场,尤其适配城市高密度地震台阵数据的批量处理需求[16];轻量化 PINN 的无网格特性使其可灵活适配城市区域不规则观测布局,仅依靠少量观测记录即可恢复浅层速度结构,有效规避传统网格正演对观测系统规整性的强依赖[9] [13]。配合深度学习降噪、插值算法修复残缺观测数据,人工智能-全波形反演输出的精细近地表速度模型可为地震动数值模拟、地下断裂灾害分区提供定量介质参数,有效提升城市地震灾害预测可靠性。

5. 现有 AI 改进 FWI 核心局限与未来发展方向

现有人工智能-全波形反演方法主要面临五大技术瓶颈,且每类瓶颈均对应形成了明确的前沿研究方向,呈现清晰的“问题-对策”映射关系。一是数值约束为数据驱动模型外推性能不足:端到端网络成像精度高度依赖训练集地质样本分布,野外工区地质条件与训练样本偏差较大时,成像误差显著上升;生成对抗网络易出现模式崩溃现象,难以完备表征多类型复杂地质构造[14],对应的优化思路为引入 WGAN-GP、深度图像先验等算法提升网络训练稳定性,联合迁移学习、数据增广策略缩减训练样本与野外工区数据的分布偏移,提升模型对陌生构造的泛化适应能力[15] [23];二是物理融合深度不足,两阶段框架割裂网络预测与波场迭代,PINN 在复杂构造下损失权重难以自适应调整,边界成像易畸变[22],对应发展方向为构建多物理耦合 PINN,引入自适应损失权重调整机制,探索物理约束渐进式注入策略,实现物理约束与数据驱动的深度同步优化[9] [13];三是不确定量化缺失,多数方法仅输出单一确定性模型,贝叶斯等量化手段计算成本高,难以支撑三维定量风险评估[5],对应发展方向为研发轻量化贝叶斯推理与 Dropout 蒙特卡洛采样技术,在可控计算开销下实现反演结果的不确定性定量评估;四是三维工程算力受限,现有算法多基于二维验证,三维计算量呈立方增长,缺乏轻量化并行技术,传统三维频率域 FWI 的高昂计算成本也印证了这一瓶颈[7],对应发展方向为研发三维轻量化网络架构,结合深度可分离卷积、知识蒸馏与多 GPU 分布式并行策略,支撑三维大规模反演任务的工程化落地;五是实测数据适配性差,网络依赖纯净合成数据,无监督及小样本自适应技术尚未成熟,现有去噪等预处理方法虽能部分改善数据品质,但难以从根本上解决合成与实测数据的分布偏差问题[12] [24],对应发展方向为发展无监督与自监督学习方法,研究小样本快速自适应技术,融合地震、重力、电磁等多源地球物理数据构建多物理耦合 PINN 框架,弥补单一地震数据信息不足的缺陷,提升实测数据适配性与深部反演精度。

综合来看, 人工智能 - 全波形反演技术正从二维理论验证向三维工程化应用加速推进, 未来突破点将集中在物理约束深度融合、不确定性量化、三维轻量化计算及实测数据自适应四大方向, 最终实现复杂地下介质下高精度、高效率、高可靠性的全波形反演。

6. 结论

传统迭代式模型驱动全波形反演存在周期跳变、数值计算开销大、地质先验自适应能力不足等固有数值约束, 难以完成盐丘、逆冲断裂等强非均质地层下介质的全波形成像任务。本文依据波动方程物理约束耦合程度, 将人工智能辅助 FWI 划分为纯数据驱动、两阶段数据 - 模型耦合、PINN 一体化同步求解三类算法架构, 系统总结各类算法的数学实现原理、地质适用条件与固有数值约束, 归纳油气勘探、深部地壳探测、地下碳封存监测、城市地震危险性评估四类工程场景的算法选型依据。通过多维度性能对比可得: 纯数据驱动架构前向推理计算效率高, 但未引入波动方程物理约束, 模型外推性能受限; 两阶段耦合架构可直接接入现有工业化 FWI 流程, 部署成本较低, 但数据拟合与物理迭代分步求解, 无法实现物理约束与数据信息深度协同优化; PINN 一体化架构完整嵌入波动控制方程, 具备无网格离散求解优势, 但面向三维大规模工区反演时, 存在算力消耗过高、模型收敛稳定性不足的问题。现阶段人工智能辅助 FWI 算法普遍存在模型外推性能不足、三维工业化部署成本高、野外实测数据适配性较差等共性技术约束。后续研究可围绕多物理场耦合 PINN、无监督小样本深度学习、轻量化分布式并行反演三条核心技术路线展开, 兼顾深度学习快速前向推理优势与地震波动方程的物理严谨性, 推动人工智能辅助 FWI 发展为强非均质地层下介质定量成像的标准化数值工具。

基金项目

新疆理工职业大学 2025 年校长基金项目(XGZDZK202510)。

参考文献

- [1] Virieux, J. and Operto, S. (2009) An Overview of Full-Waveform Inversion in Exploration Geophysics. *Geophysics*, **74**, WCC1-WCC26. <https://doi.org/10.1190/1.3238367>
- [2] Brenders, A.J. and Pratt, R.G. (2007) Full Waveform Tomography for Lithospheric Imaging: Results from a Blind Test in a Realistic Crustal Model. *Geophysical Journal International*, **168**, 133-151. <https://doi.org/10.1111/j.1365-246x.2006.03156.x>
- [3] Bunks, C., Saleck, F.M., Zaleski, S. and Chavent, G. (1995) Multiscale Seismic Waveform Inversion. *Geophysics*, **60**, 1457-1473. <https://doi.org/10.1190/1.1443880>
- [4] He, Q. and Wang, Y. (2020) Reparameterized Full-Waveform Inversion Using Deep Neural Networks. *Geophysics*, **86**, V1-V13. <https://doi.org/10.1190/geo2019-0382.1>
- [5] Zhu, W., Xu, K., Darve, E., Biondi, B. and Beroza, G.C. (2021) Integrating Deep Neural Networks with Full-Waveform Inversion: Reparameterization, Regularization, and Uncertainty Quantification. *Geophysics*, **87**, R93-R109. <https://doi.org/10.1190/geo2020-0933.1>
- [6] LeCun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, **521**, 436-444. <https://doi.org/10.1038/nature14539>
- [7] Operto, S., Miniussi, A., Brossier, R., Combe, L., Métivier, L., Monteiller, V., *et al.* (2015) Efficient 3-D Frequency-Domain Mono-Parameter Full-Waveform Inversion of Ocean-Bottom Cable Data: Application to Valhall in the Visco-Acoustic Vertical Transverse Isotropic Approximation. *Geophysical Journal International*, **202**, 1362-1391. <https://doi.org/10.1093/gji/ggv226>
- [8] Tarantola, A. (1984) Inversion of Seismic Reflection Data in the Acoustic Approximation. *Geophysics*, **49**, 1259-1266. <https://doi.org/10.1190/1.1441754>
- [9] Raissi, M., Perdikaris, P. and Karniadakis, G.E. (2019) Physics-Informed Neural Networks: A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations. *Journal of Computational Physics*, **378**, 686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- [10] Fletcher, R. and Reeves, C.M. (1964) Function Minimization by Conjugate Gradients. *The Computer Journal*, **7**, 149-

154. <https://doi.org/10.1093/comjnl/7.2.149>
- [11] Plessix, R.E. (2006) A Review of the Adjoint-State Method for Computing the Gradient of a Functional with Geophysical Applications. *Geophysical Journal International*, **167**, 495-503. <https://doi.org/10.1111/j.1365-246x.2006.02978.x>
- [12] Saad, O.M. and Chen, Y. (2020) Deep Denoising Autoencoder for Seismic Random Noise Attenuation. *Geophysics*, **85**, V367-V376. <https://doi.org/10.1190/geo2019-0468.1>
- [13] Karimpouli, S. and Tahmasebi, P. (2020) Physics Informed Machine Learning: Seismic Wave Equation. *Geoscience Frontiers*, **11**, 1993-2001. <https://doi.org/10.1016/j.gsf.2020.07.007>
- [14] Richardson, A. (2018) Generative Adversarial Networks for Model Order Reduction in Seismic Full-Waveform Inversion. arXiv: 1806.00828.
- [15] Lempitsky, V., Vedaldi, A. and Ulyanov, D. (2018) Deep Image Prior. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 9446-9454. <https://doi.org/10.1109/cvpr.2018.00984>
- [16] Wu, Y. and Lin, Y. (2020) Inversionnet: An Efficient and Accurate Data-Driven Full Waveform Inversion. *IEEE Transactions on Computational Imaging*, **6**, 419-433. <https://doi.org/10.1109/tci.2019.2956866>
- [17] Wang, W. and Ma, J. (2019) Velocity Model Building in a Crosswell Acquisition Geometry with Image-Trained Artificial Neural Networks. *Geophysics*, **85**, U31-U46. <https://doi.org/10.1190/geo2018-0591.1>
- [18] Wu, X., Liang, L., Shi, Y. and Fomel, S. (2019) Faultseg3d: Using Synthetic Data Sets to Train an End-to-End Convolutional Neural Network for 3D Seismic Fault Segmentation. *Geophysics*, **84**, IM35-IM45. <https://doi.org/10.1190/geo2018-0646.1>
- [19] Sun, Y., Xia, Z. and Kamilov, U.S. (2018) Efficient and Accurate Inversion of Multiple Scattering with Deep Learning. *Optics Express*, **26**, 14678-14688. <https://doi.org/10.1364/oe.26.014678>
- [20] Chen, Y. and Saygin, E. (2021) Seismic Inversion by Hybrid Machine Learning. *Journal of Geophysical Research: Solid Earth*, **126**, e2020JB021589. <https://doi.org/10.1029/2020jb021589>
- [21] Wu, Y., McMechan, G.A. and Wang, Y. (2022) Adaptive Feedback Convolutional-Neural-Network-Based High-Resolution Reflection-Waveform Inversion. *Journal of Geophysical Research: Solid Earth*, **127**, e2022JB024138. <https://doi.org/10.1029/2022jb024138>
- [22] Rasht-Behesht, M., Huber, C., Shukla, K. and Karniadakis, G.E. (2022) Physics-Informed Neural Networks (Pinns) for Wave Propagation and Full Waveform Inversions. *Journal of Geophysical Research: Solid Earth*, **127**, e2021JB023120. <https://doi.org/10.1029/2021jb023120>
- [23] Gulrajani, I., Ahmed, F., Arjovsky, M., et al. (2017) Improved Training of Wasserstein Gans. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, 4-9 December 2017, 5769-5779.
- [24] Yu, S. and Ma, J. (2021) Deep Learning for Geophysics: Current and Future Trends. *Reviews of Geophysics*, **59**, e2021RG000742. <https://doi.org/10.1029/2021rg000742>