2026 年第 41 卷 第 5 期
2026,41(5):2038-2053

地球物理学进展 Progress in Geophysics
http://www.progeophys.cn

ISSN 1004-2903
CN 11-2982/P

方金伟,陈杰,张晓岩,等.2026.长短期记忆网络参数化的全波形反演.地球物理学进展,41(5):2038-2053,doi:10.6038/pg2026JJ0037.

FANG JinWei,CHEN Jie,ZHANG XiaoYan, *et al*. 2026. Long short-term memory network-parameterized full-waveform inversion. *Progress in Geophysics* (in Chinese), 41(5):2038-2053,doi:10.6038/pg2026JJ0037.

长短期记忆网络参数化的全波形反演

Long short-term memory network-parameterized full-waveform inversion

方金伟[1],陈杰[1],张晓岩[1],石颖[2],张少华[3],周辉[4]

FANG JinWei[1],CHEN Jie[1],ZHANG XiaoYan[1],SHI Yin[2],ZHANG ShaoHua[3],ZHOU Hui[4]

1. 中国矿业大学,深地工程智能建造与健康运维全国重点实验室,资源与地球科学学院,江苏徐州 221116
2. 东北石油大学,地球科学学院,黑龙江大庆 163711
3. 中国石油集团东方地球物理勘探有限责任公司,河北涿州 072751
4. 中国石油大学(北京),地球物理学院,北京 102249

1. *National Key Laboratory of Intelligent Construction and Health Operation and Maintenance of Deep Earth Engineering*, *School of Resources and Geosciences*, *China University of Mining and Technology*, *Xuzhou Jiangsu* 221116, *China*
2. *School of Earth Sciences*, *Northeast Petroleum University*, *Daqing Heilongjiang* 163711, *China*
3. *Petrochina Eastern Geophysical Exploration Co., Ltd.*, *Zhuozhou Hebei* 072751, *China*
4. *School of Geophysics*, *China University of Petroleum*, *Beijing*, *Beijing* 102249, *China*

摘 要 将深度学习方法与物理方程约束相结合,是现阶段地震全波形反演的主流发展趋势.目前物理约束型深度学习全波形反演大多基于自动微分框架构建,但该方法在大规模数值模拟场景中,可能存在梯度存储开销大、梯度预处理适配性弱、模型分割计算难等问题,难以满足实用化的地下速度建模.针对上述问题,本文摒弃自动微分梯度求解方式,以传统全波形反演的伴随状态法梯度计算为核心,结合深度学习重参数化技术与网络优化训练策略,构建一种实用性更强的深度学习参数化全波形反演方法.研究依托高性能计算资源完成卷积型目标函数的伴随梯度求解,采用长短期记忆神经网络(LSTM-NN)对地下模型参数进行表征,利用其擅长捕捉长程依赖的特性,建立稳定性更强的参数映射关系,有效改善网络重参数的效果.同时,针对全波形反演的强非线性,本文引入多尺度反演思路,并在不同反演尺度下分别开展独立的 LSTM-NN 参数化训练,让网络逐层表征不同尺度的地下介质信息,有效提升算法的全局收敛能力.数值测试结果证实,相较于传统卷积神经网络参数化反演手段,本文所

Abstract The integration of deep learning methods with physical equation constraints has become a dominant development trend of seismic Full-Waveform Inversion (FWI). At present, physically constrained deep learning-based FWI is mostly implemented based on automatic differentiation frameworks. However, when applied to large-scale numerical simulations, such frameworks suffer from excessive gradient memory consumption, poor adaptability of gradient preprocessing, and difficulties in model segmentation computation, which limit their practical application for subsurface velocity modeling. To address these issues, this study abandons the gradient calculation scheme of automatic differentiation and adopts the adjoint gradient computation of conventional FWI as the core algorithm. Combined with deep learning reparameterization technology and network optimization training strategies, a more practical deep learning parameterized FWI method is proposed. Relying on high-performance computing resources, the adjoint-state gradient of the convolution-based objective function is efficiently solved. A Long Short-Term Memory Neural Network (LSTM-NN) is employed to characterize subsurface model parameters. Leveraging its superior capability in capturing long-range dependencies, the network establishes a more stable parameter mapping relationship and effectively improves the performance of network reparameterization. Furthermore, targeting the strong nonlinearity inherent in FWI, a multi-scale inversion strategy is introduced. Independent LSTM-NN

收稿日期 2026-01-06; **修回日期** 2026-06-26. **投稿网址** http://www.progeophys.cn

基金项目 国家自然科学基金项目(42574166,41930431)和中石油创新基金项目(2024DQ02-0137)联合资助.

第一作者简介 方金伟,男,1991 年生,博士,副教授,主要从事地震资料处理方法研究. E-mail:jinwei_fang_work@163.com

提 LSTM-NN 多尺度反演方法能够清晰刻画地下构造界面、弥补观测照明缺陷,显著提升断层细节识别能力,最终获得精度更高的反演结果,可为高精度地震速度建模的实际应用提供可行的技术方案.

关键词　全波形反演;深度学习重参数化;长短期记忆网络;多尺度反演

中图分类号　P631

文献标识码　A

doi:10.6038/pg2026JJ0037

CSTR:32085.14.pg2026JJ0037

parameterized training is performed at different inversion scales, enabling the network to characterize subsurface medium information layer by layer and effectively enhance the global convergence performance of the algorithm. Numerical test results verify that compared with the conventional convolutional neural network-based parameterized inversion method, the proposed LSTM-NN multi-scale inversion method can clearly delineate subsurface structural interfaces, compensate for the deficiencies of geometry illumination, and significantly improve the identification accuracy of fault details. It ultimately delivers inversion results with higher accuracy, providing a feasible technical solution for the practical application of high-precision seismic velocity modeling.

Keywords　Full waveform inversion; Deep learning reparameterization; Long short-term memory network; Multiscale inversion

0　引　言

地震全波形反演是目前具备最高成像精度的地球物理参数反演方法之一,在地下资源精细勘探中具有重要意义.该方法基于初始的介质参数模型,通过正演模拟获得合成数据,并构建合成数据与观测数据之间波形差异度量的目标函数,再利用迭代优化算法逐步更新模型,最终实现地下未知介质参数的重建(Lailly,1983;Tarantola,1984).自全波形反演提出以来,其相关理论与算法体系得到持续完善,尤其是以伴随状态法为核心的全波形反演技术(Plessix,2006;Mora,1987;Ravaut *et al.*,2004;Sirgue *et al.*,2010)已形成较为成熟的研究体系,并在计算效率和成像精度等方面取得了显著进展(Virieux and Operto,2009;杨顶辉等,2025).总体来看,其发展主要体现在以下几个方面:一是在不同计算域中开展反演,以降低计算成本或减轻反演对初始模型的依赖(Pratt *et al.*,1998;Shin and Ho Cha,2009;李振春等,2016;辛天亮等,2020);二是引入稳健性更强的目标函数及多尺度反演思路(Bunks *et al.*,1995;Sirgue and Pratt,2004;胡光辉和贺伟光,2023;康鹏飞等,2025;刘峰良等,2026),通过增强目标函数凸性、增加正则化手段等来缓解局部极小值问题,并从多尺度、宽波数信息利用角度提升反演精度;三是采用更加符合实际地震波场传播的波动方程开展反演(Fabien-Ouellet *et al.*,2017;刘玉柱等,2019),主要体现在复杂方程的构建与求解、多波信息选择与利用、多参数建模以及反演精度改善等问题;四是计算效率和内存消耗方面,通过改进优化算法(Crase *et al.*,1990)以加快迭代收敛过程;依托高性能计算平台(Trad,2022;冯海新等,2017),同时结合源模拟技术(Zhang *et al.*,2020)、计算域分解策略和高效边界存储方法(王维红等,2013;石颖等,2015;杨瀚等,2024),推动算法向实际应用发展.

近些年来,以深度学习技术来求解全波形反演(Yang and Ma,2019;Zhang and Lin,2020;Geng *et al.*,2022;王彦飞,2026)的方式已如火如荼.在这一背景下,物理约束深度学习全波形反演逐渐成为当前研究的重要方向(Richardson,2018;Raissi *et al.*,2020;Schuster *et al.*,2024),该方法通过引入深度学习优化工具以及深度网络重参数化表征,使反演过程具备高精度成像能力(Wu and McMechan,2019;He and Wang,2021;Jiang *et al.*,2024).物理约束深度学习全波形反演主要可分为两类技术思路:第一类为基于自动微分框架的严格波动方程编码方法(Wang *et al.*,2021;Zhu *et al.*,2022;Sun *et al.*,2023;段友祥等,2023;毛士博等,2026),第二类则是将波动方程作为约束项嵌入目标函数的生成式网络优化方法(Moseley *et al.*,2020;Song *et al.*,2021;Rasht-Behesht *et al.*,2022;邹婧博等,2023;单连璞等,2025).现有相关研究大多依托自动微分框架开展模拟与反演.相较于传统自动微分方案,使用伴随梯度的深度学习反演方法具备更强的工程可拓展性(Zhang *et al.*,2021;Fang *et al.*,2024,2025,2026;Zhao *et al.*,2025).在大规模数值模拟场景中,该方法可有效解决边界重构、梯度预处理、模型分割计算等关键难题,显著提升深度学习反演建模的实用性与落地能力.

深度学习参数化策略的核心思路,是把地下介质物理参数的反演优化转化为深度神经网络权重的迭代更新,通过改善目标函数的凸性来缓解全波形反演多解性问题.不同网络结构对反演效果的提升作用存在明显差异.卷积神经网络(CNN)擅长处理具备空间结构的数据,在地震资料特征提取领域应

用广泛,可充分挖掘地下介质多尺度空间特征(杨晶等,2022;易继东等,2023).但深度学习全波形反演参数化过程,实质上是将物理梯度传递给网络参数梯度,并开展迭代优化.模型梯度分布受观测系统照明条件制约,局部强能量极易掩盖微弱能量信息;仅依靠局部空间幅值特征提取的 CNN 架构,难以向网络传递弱梯度信号,对地层分界面的精细刻画能力存在明显短板.相比之下,长短期记忆(LSTM)神经网络可精准刻画序列深层长期依赖特征(Hochreiter and Schmidhuber,1997;Zhang *et al*.,2023;谢豪和王靖宇,2025;Qiao and Wang,2026).物理梯度向网络参数反向传播时,LSTM 借助门控单元捕捉迭代时序演化特征,精准识别梯度突变对应的地下构造界面,高稳定的生成介质模型参数;同时,其门控结构可缓解梯度消失,保障网络稳定训练.综上,基于 LSTM 神经网络(LSTM-NN)开展全波形反演参数化建模,可同步提升反演稳定性与构造成像分辨率.

基于此,本文提出一种长短期记忆网络参数化全波形反演方法.该方法依托高性能计算与有效边界存储技术,采用伴随状态法求取梯度,以 LSTM-NN 表征模型参数,并结合深度学习优化工具完成反演.此外,高精度的全波形反演需要宽波数重构,虽然经典全波形反演可获得多尺度梯度信息,但单一网络训练难以同时表征不同尺度参数.为此,本文结合多尺度反演思想,在不同尺度下分别进行参数化反演,以实现宽频高分辨率反演.

本文的结构安排如下:引言之后,首先介绍全波形反演的伴随状态法梯度计算、深度学习参数化及优化反演方法;接着,通过数值试验对比 LSTM-NN 与 CNN 参数化反演效果,并验证了多尺度深度学习参数化反演策略的有效性;然后,将所提出的算法应用于实际数据处理,验证该算法在实际工程应用中的能力;最后给出结论与建议.

1 方法原理

1.1 深度网络重参数化

与传统反演不同的是选取深度网络输出速度参数扰动量,通过训练网络参数来实现速度参数的更新.深度神经网络重参数化的方式如下:

$$m = \mathrm{LSTM}_{\theta}(\lambda) + m_{\mathrm{ini}}, \tag{1}$$

其中 m 表示速度模型参数,m_{ini} 表示初始速度模型参数;LSTM_{θ} 是长短期记忆网络模型,θ 表示网络参数,λ 表示随机特征变量.长短期记忆神经网络 LSTM_{θ} 以特征变量 λ 为输入,以速度模型参数扰动量 $\Delta m = \mathrm{LSTM}_{\theta}(\lambda)$ 为输出.完成网络参数化后引入初始模型,依靠初始模型提供低波数背景,网络仅针对中高波数信息开展重构.

1.2 伴随状态法梯度计算

采用具备多尺度反演功能的卷积型目标函数,其形式具体表示为:

$$\chi(m,\boldsymbol{x}) = \left\| \boldsymbol{d}(\boldsymbol{x}_{\mathrm{r}},t) * \boldsymbol{v}(\boldsymbol{x}_{\mathrm{ref}},t;m) - \boldsymbol{v}(\boldsymbol{x}_{\mathrm{r}},t;m) * \boldsymbol{d}(\boldsymbol{x}_{\mathrm{ref}},t) \right\|_2^2, \tag{2}$$

其中,$\boldsymbol{d}(\boldsymbol{x}_{\mathrm{r}},t)$ 和 $\boldsymbol{d}(\boldsymbol{x}_{\mathrm{ref}},t)$ 是观测数据,$\boldsymbol{v}(\boldsymbol{x}_{\mathrm{ref}},t;m)$ 和 $\boldsymbol{v}(\boldsymbol{x}_{\mathrm{r}},t;m)$ 是合成波场数据,$\boldsymbol{x}_{\mathrm{r}}$ 和 $\boldsymbol{x}_{\mathrm{ref}}$ 分别表示检波点位置和参考道的位置,空间坐标 $\boldsymbol{x} = [x,z]$,t 表示时间,$\|\cdot\|_2^2$ 表示二范数.

目标函数中的合成数据采用如下的波动方程生成:

$$\partial_t \boldsymbol{\psi} - \boldsymbol{E}\boldsymbol{\psi} = \boldsymbol{s}, \tag{3}$$

其中,$\boldsymbol{\psi} = [\sigma, \boldsymbol{v}]^{\mathrm{T}}$ 是正传波场变量,σ 是正传波场对应的质点震动应力,$\boldsymbol{v} = [v_x, v_z]$ 表示质点沿着 x 和 z 两个方向的振动速度,$\boldsymbol{s}$ 是源项,∂_t 表示对时间 t 求偏导数,链接矩阵 $\boldsymbol{E}$ 为:

$$\boldsymbol{E} = \begin{bmatrix} 0 & \rho m^2 \partial_x & \rho m^2 \partial_z \\ \dfrac{1}{\rho}\partial_x & 0 & 0 \\ \dfrac{1}{\rho}\partial_z & 0 & 0 \end{bmatrix}, \tag{4}$$

∂_x 和 ∂_z 表示对空间变量 x 和 z 求偏导数,其中 ρ 表示密度,并在反演中视为常数.

基于此目标函数,以波动方程为约束构建其增广目标函数,采用拉格朗日伴随法推导出的伴随方程为,

$$\partial_t \overline{\boldsymbol{\psi}} - \boldsymbol{E}\overline{\boldsymbol{\psi}} = \overline{\boldsymbol{s}}, \tag{5}$$

其中反传波场 $\overline{\boldsymbol{\psi}} = [\overline{\sigma}, \overline{\boldsymbol{v}}]^{\mathrm{T}}$,其中 $\overline{\boldsymbol{v}} = [\overline{v}_x, \overline{v}_z]$,$\overline{\sigma}$ 是反传波场对应的质点震动应力,$\overline{v}_x$ 和 $\overline{v}_z$ 分别表示反传波场对应的质点沿着 x 和 z 两个方向振动速度,伴随源 $\overline{\boldsymbol{s}}(\boldsymbol{x}_{\mathrm{r}},t)$ 为:

$$\overline{\boldsymbol{s}}(\boldsymbol{x}_{\mathrm{r}},t) = [\boldsymbol{v}(\boldsymbol{x}_{\mathrm{ref}},t;m) * \boldsymbol{d}(\boldsymbol{x}_{\mathrm{ref}},t) - \boldsymbol{d}(\boldsymbol{x}_{\mathrm{ref}},t) * \boldsymbol{v}(\boldsymbol{x}_{\mathrm{ref}},t;m)] \otimes \boldsymbol{d}(\boldsymbol{x}_{\mathrm{ref}},t), \tag{6}$$

$*$ 表示卷积运算,$\otimes$ 表示互相关运算.

推导的目标函数对模型参数的梯度 $\nabla\chi_m$ 为:

$$\nabla\chi_m = \int \mathrm{d}t \frac{2}{\rho m^3} \overline{\sigma} \partial_t \sigma. \tag{7}$$

利用伴随状态法求解模型参数梯度时,波动方程采用高阶交错网格有限差分进行离散,边界吸收引入卷积完全匹配吸收边界;算法层面基于 MPI 调度 GPU 实现多节点高性能并行.为削减显存占用,本文采用有效边界存储策略,以适度增加计算开销

来降低内存消耗.

1.3　多尺度深度学习参数化反演

利用伴随状态法求取梯度以更新网络参数. 将由伴随状态法得到的模型参数梯度赋值为网络输出梯度:

$$\nabla(\mathrm{LSTM}_\theta(\lambda)+m_{\mathrm{ini}})=\nabla\chi_m, \tag{8}$$

依据链式求导法则,通过网络反向传播将模型参数梯度转换为网络可训练参数梯度$\nabla\chi_\theta$:

$$\nabla\chi_\theta=\nabla\chi_m\frac{\partial m}{\partial\theta}, \tag{9}$$

得到各网络层参数梯度后,采用迭代优化算法完成网络参数更新,参数更新如下:

$$\theta_{k+1}=\theta_k+\Gamma(\eta,\nabla\chi_\theta), \tag{10}$$

其中,k 表示第 k 次训练次数,η 表示学习率. $\Gamma(\eta,\nabla\chi_\theta)$ 为迭代优化算子,涵盖自适应梯度下降法(Adagrad)、随机梯度下降法(SGD),动量优化算法、自适应学习率优化算法等(Duchi *et al.*, 2011; Rurden,2017),全波形反演可按需选用不同优化器.

为有效契合多尺度反演思想,本文在各尺度对应频带内独立完成模型特征的网络训练,规避多频带连续训练过程中部分尺度地层特征难以精准恢复的缺陷. 多尺度深度学习反演策略具体方案如下:

$$\begin{cases} m=[\mathrm{LSTM}_\theta(\lambda)]_i+m_0 \\ m_0=m_{\mathrm{ini}} \quad (i=1) \\ m_0=m_0+[\mathrm{LSTM}_\theta(\lambda)]_i \quad (i\neq 1) \end{cases}, \tag{11}$$

其中,m_0 表示每个频带开始反演的初始模型;i 代表多尺度反演频带序号,取值依次为 1, 2,…, n,n 为总频带数量;$[\mathrm{LSTM}_\theta(\lambda)]_i$ 表示在第 i 个频带内深度网络重参数化输出. 由此可知,多尺度反演仅首尺度采用给定初始模型,其余各尺度均将前序频带训练得到的网络输出结果叠加,作为自身反演初始模型.

1.4　深度学习多尺度全波形反演流程

在深度学习多尺度全波形反演框架中,神经网络对模型进行重参数化,结合伴随状态法计算模型梯度并反向传播得到网络梯度,依靠优化器迭代更新网络参数、输出更新模型,循环迭代直至完成地下模型反演.

具体实现流程如下:首先引入随机特征变量 λ,通过长短期记忆神经网络 $\mathrm{LSTM}_\theta(\lambda)$ 完成地下速度模型 m 的重参数化表征;依托高性能计算平台,采用伴随状态法求解模型参数梯度$\nabla\chi_m$,将该梯度作为网络输出梯度进行反向传播,进而得到网络参数对应的梯度$\nabla\chi_\theta$. 在此基础上,选定适配的深度学习优化算法并设置合理学习率 η,迭代更新深度神经网络参数 θ,最终映射得到更新后的模型参数.

以更新后的模型参数为新的输入,重复上述梯度计算与网络参数优化流程,持续迭代更新模型参数. 当迭代次数达到最大训练阈值或目标函数收敛至预设精度时,停止迭代,此时神经网络的表征结果即为最终反演所得的地下模型参数. 反演过程中,伴随状态法求解得到的目标函数值可同步反馈至网络,实时监测反演过程的收敛状态,保障反演过程稳定可控. 本文深度学习融合伴随梯度的全波形反演完整计算流程如图 1 所示,并且图 1 给出了 LSTM-NN 和 CNN 网络架构,便于后文深度学习参数化反演的对比测试.

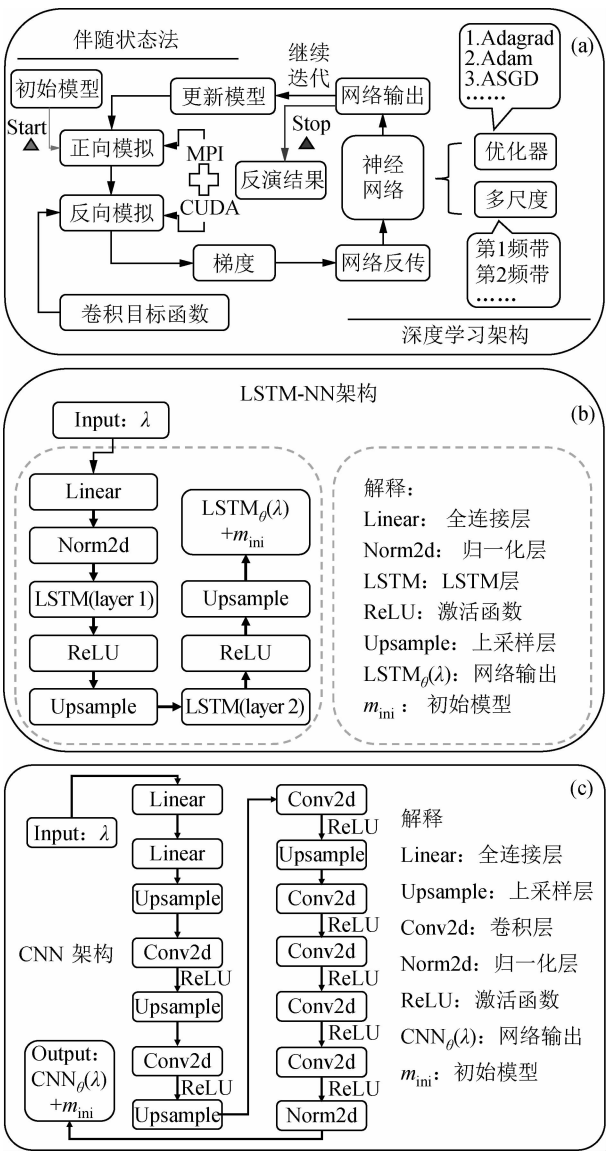


图 1　(a)深度学习融合伴随梯度的全波形反演流程;(b)LSTM-NN 网络架构;(c)CNN 网络架构

Fig. 1　(a) Workflow of full waveform inversion with deep learning integrated adjoint gradient; (b) LSTM-NN network architecture; (c) CNN network architecture

为进一步提升反演精度与成像质量,本文结合多尺度反演思想,将整体迭代训练过程划分为多个频带尺度反演任务,各频带主频按由低到高的顺序依次递增.每个频带尺度均开展独立的网络参数训练,单独学习并表征对应尺度下的地下模型特征信息,充分挖掘不同尺度的地层构造细节.本文所提出的深度学习多尺度全波形反演详细算法如算法 1 所示.

算法 1 深度学习多尺度全波形反演算法

输入:地震观测数据、初始模型参数、多尺度频带序列、每个频带迭代次数、收敛精度阈值、初始学习率
输出:最优反演模型参数、迭代目标函数收敛序列
1. 初始化与参数配置
1)构建深度学习网络,以随机特征变量为输入,建立模型参数深度学习表征映射;
2)配置地震观测系统参数,基于高性能计算平台定义伴随状态法梯度计算函数;
3)初始化网络参数、迭代超参数,设置由低主频到高主频的多尺度频带序列.
2. 多尺度频带循环
for 每个尺度频带 do
3. 单频带迭代训练
while 未达到最大迭代次数且未满足收敛精度 do
(1)初始化网络参数梯度;
(2)调用深度神经网络,表征当前尺度下的模型参数;
(3)融合当前尺度初始模型与网络表征模型,构建实时反演模型;
(4)调用伴随状态法梯度计算函数,求解模型参数梯度与当前目标函数值;
(5)基于链式法则反向传播模型梯度,得到网络参数梯度;
(6)采用深度学习优化算法,结合预设学习率更新网络权重参数;
end while
end for
4. 结果输出
迭代训练结束后,输出各尺度最优网络表征的地下模型参数,同时导出全程迭代过程的目标函数收敛曲线数据,完成多尺度全波形反演.

2 数值试验

为充分验证本文所提长短期记忆网络参数化的全波形反演方法的有效性与适用性,本文设计多组数值模拟实验,并开展实际资料测试.第一部分为 Overthrust 模型测试,对比 LSTM-NN 与 CNN 两种网络框架在单尺度与多尺度反演策略下的成像效果与迭代性能,验证多尺度优化策略的有效性以及不同网络的表征能力差异.第二部分基于 Marmousi 模型,系统对比 LSTM-NN 与 CNN 的多尺度参数化反演效果.第三部分基于 Foothills 模型开展对比实验,对比常规全波形反演与两种深度网络参数化反演效果.最后一部分采用实际地震资料开展反演应用测试,验证算法的实用性与可靠性.

为了定量的评价反演结果的可靠性,量化各模型的反演误差,采用如下公式来度量反演结果 $\tilde{m}$ 的误差:

$$\begin{cases} err_{\mathrm{a}} = \dfrac{1}{nx \times nz}\sum_{j=0}^{nx}\sum_{i=0}^{nz}\left|m_{i,j}-\tilde{m}_{i,j}\right| \\ err_{\mathrm{r}} = \dfrac{1}{nx \times nz}\sum_{j=0}^{nx}\sum_{i=0}^{nz}\left|\dfrac{m_{i,j}-\tilde{m}_{i,j}}{m_{i,j}}\right| \times 100\% \end{cases}, \quad (12)$$

其中 err_{a} 表示绝对误差,err_{r} 表示相对误差,nx 和 nz 分别为模型二维空间横向与纵向离散网格点数,$|\cdot|$为绝对值运算.

2.1 Overthrust 模型

2.1.1 网络参数化的单尺度反演

首先采用 Overthrust 模型开展深度学习参数化的单尺度反演测试.真实速度模型见图 2a,模型尺寸为 11.88 km×2.52 km,空间离散步长为 12.5 m.沿地表均匀布置 43 炮震源,震源子波选用主频 8 Hz 雷克子波;每炮记录 792 道数据,时间采样间隔为 1 ms.反演初始模型见图 2b,该模型由真实速度模型经 150 m×150 m 高斯窗口空间平滑后得到.基于卷积型目标函数,分别构建 CNN、LSTM-NN 两种网

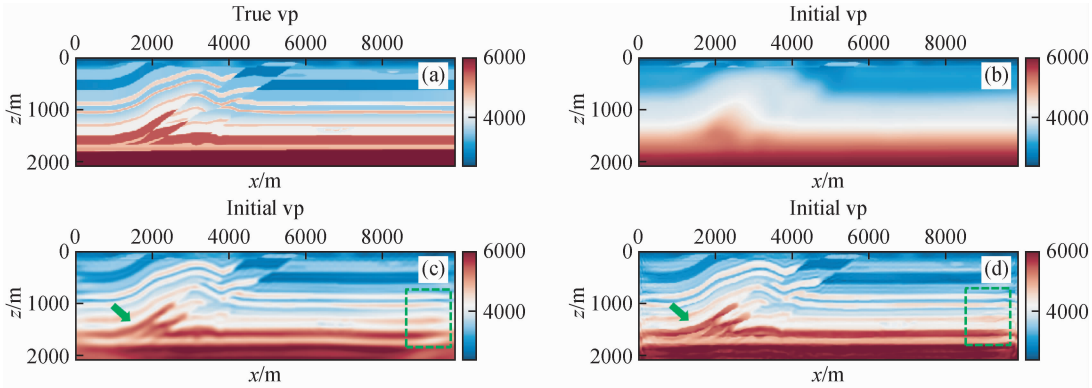


图 2　Overthrust 模型单尺度反演结果对比

(a)真实速度模型;(b)初始模型;(c)CNN 参数化反演结果;(d)LSTM-NN 参数化反演结果.

Fig. 2　Comparison of single-scale inversion results on Overthrust model

(a) True velocity model; (b) Initial model; (c) Parameterized inversion results based on CNN; (d) Parameterized inversion results based on LSTM-NN.

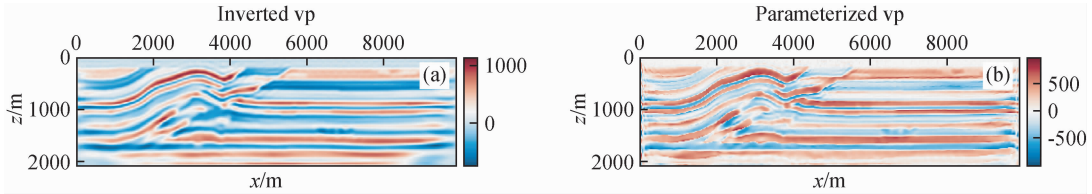


图 3　基于(a)CNN 和(b)LSTM-NN 参数化的网络输出

Fig. 3　Updated amounts of parameterized network outputs based on (a) CNN and (b) LSTM-NN

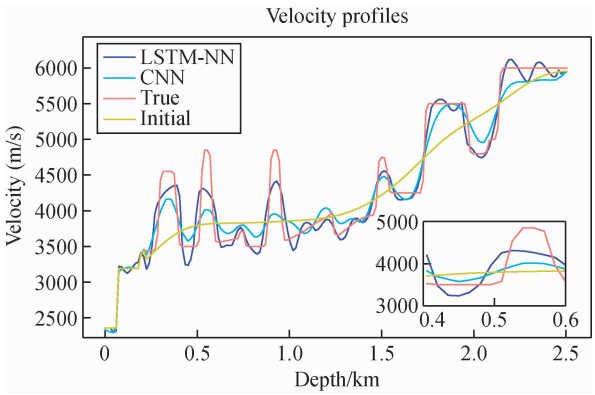


图 4　$x=4.1$ km 处单尺度反演速度剖面对比

Fig. 4　Comparison of single-scale inversion velocity profiles at $x=4.1$ km

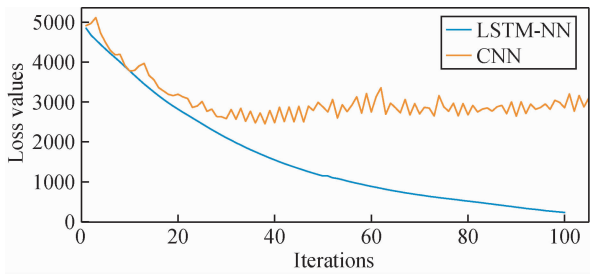


图 5　Overthrust 模型单尺度反演的目标函数下降曲线对比

Fig. 5　Comparison of objective function descent curves of single-scale inversion on Overthrust model

络参数化反演框架开展测试,反演主频为 8 Hz,总迭代步数 120 次;网络参数优化均采用 Adagrad 梯度下降算法.

两组反演结果如图 2 所示,对比 CNN 参数化反演剖面(图 2c)与 LSTM-NN 参数化反演剖面(图 2d)可见,两类网络均可通过参数化训练实现地下速度模型的有效重构. 但二者成像效果存在显著差异:CNN 反演对深部速度场重构能力偏弱,并且地层边界成像模糊;而 LSTM-NN 反演结果在深部地层恢复准确、断层界面和地层边界清晰,反演结果与真实模型吻合度更高,尤其是在图 2 箭头与方框标注区域对比显著.

为了进一步分析反演效果,图 3 展示了参数化网络输出的模型更新量. 对比可见,LSTM-NN 参数化反演方法的更新量边界清晰,并且层速度更加均匀;同时不难发现,CNN 参数化方法的更新量整体表现出光滑的特征,同时在一些薄层反演时,连续性和保幅性较差;并且受到观测系统照明的影响,模型边缘和深部区域更新不足. 同时,速度剖面(图 4)也

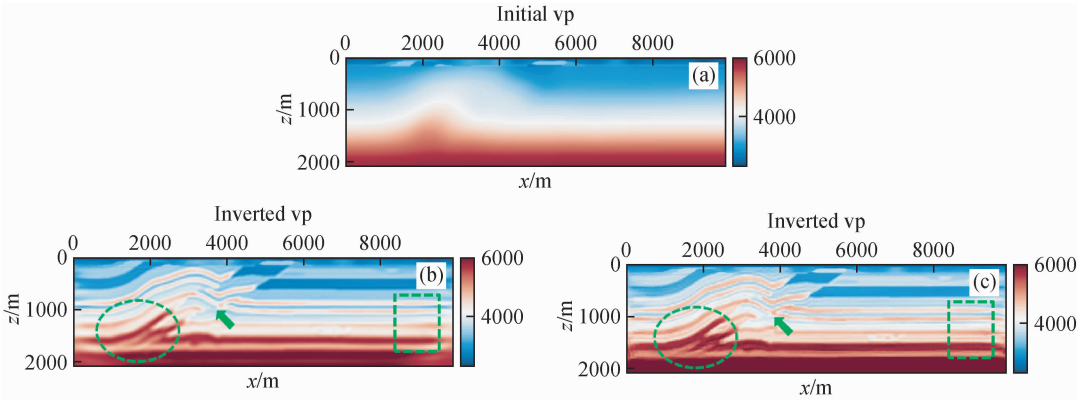


图 6 Overthrust 模型多尺度反演结果对比
(a)初始模型;(b)CNN 参数化反演结果;(c)LSTM-NN 参数化反演结果.
Fig. 6 Comparison of multi-scale inversion results on Overthrust model
(a) Initial model; (b) Parameterized inversion results based on CNN; (c) Parameterized inversion results based on LSTM-NN.

验证了 LSTM-NN 参数化反演速度与真实速度的吻合程度显著优于 CNN 参数化反演. 为了观察反演的稳定性,对比了两种反演方法的目标函数曲线(图 5). 从收敛曲线可知,LSTM-NN 参数化反演的目标函数平稳下降并持续收敛至极小值;CNN 参数化反演曲线出现较为明显的抖动,尽管在迭代后期稳定,但是出现持续抖动,并且目标函数值高于 LSTM-NN 参数化方法,这进一步表明了在单尺度深度学习反演中 LSTM-NN 的鲁棒性优于 CNN.

2.1.2 网络参数化的多尺度反演

接下来,基于 Overthrust 模型开展 LSTM-NN 和 CNN 参数化的多尺度反演测试. 观测系统设置和单尺度反演一致. 使用大小为 225 m×225 m 的高斯光滑窗口平滑真实模型来获得初始模型(图 6a). 相比于单尺度反演使用的初始模型,多尺度反演使用的初始模型更为光滑,会加剧目标函数的收敛难度. 多尺度反演的中心频率分别为 4 Hz、6 Hz、8 Hz、10 Hz 和 13 Hz,每个频带迭代 40 次,总计进行 200 次迭代.

对比两组网络参数化反演剖面可见,LSTM-NN 参数化反演成像(图 6c)整体质量仍显著优于 CNN 反演结果(图 6b). LSTM-NN 重构的速度模型中地层横向连续性更强,高、低速地层速度均一性更好,高陡构造和断层的界面成像分辨率也明显高于 CNN,图 7 纵向速度剖面可进一步印证该结论. 为定量量化两类方法的反演精度,统计了各组反演模型与真实速度场的整体误差,结果如表 1 所列. 误差对比表明,采用 LSTM-NN 开展参数化优化更易收敛至最优解,所得反演模型与真实模型间的误差水平最低.

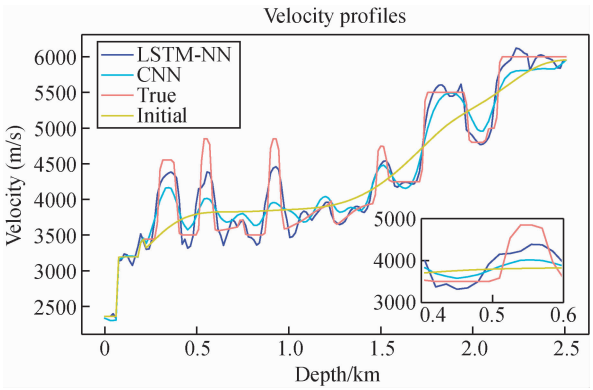


图 7 $x=4.1$ km 处多尺度反演速度剖面对比
Fig. 7 Comparison of multi-scale inversion velocity profiles at $x=4.1$ km

表 1 基于两种神经网络参数化反演以及传统反演的精度对比

Table 1 Accuracy comparison between two neural network parameterized inversions and conventional inversion

反演方法	Overthrust 模型速度误差		Marmousi 模型速度误差		Foothills 模型速度误差	
	相对(%)	绝对(m/s)	相对(%)	绝对(m/s)	相对(%)	绝对(m/s)
LSTM	2.91	121.26	3.28	133.38	1.15	57.76
CNN	3.37	149.30	4.02	137.03	1.22	62.47
传统方法	—	—	—	—	1.47	74.84

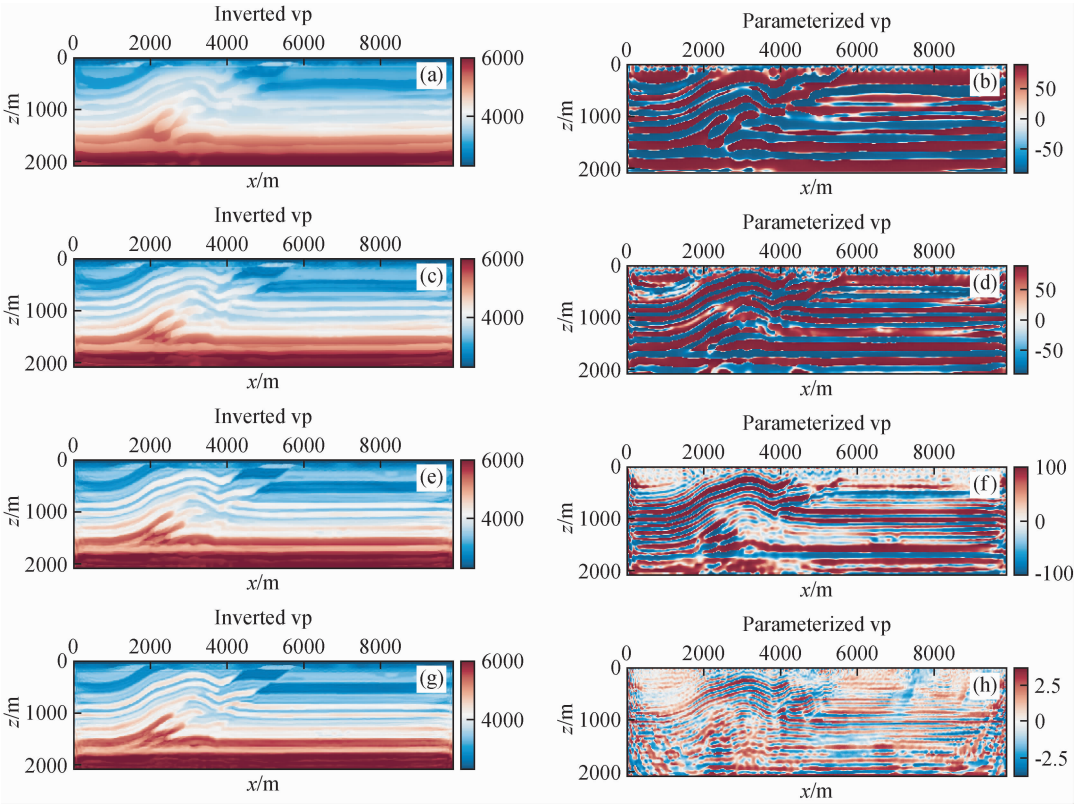


图 8　LSTM-NN 多尺度反演各频带反演结果与网络输出

(a)—(h)分别对应 4 Hz、6 Hz、8 Hz 和 13 Hz 频带的反演速度剖面(左列)及参数化网络输出结果(右列).

Fig. 8　Inversion results and network outputs of each frequency band in LSTM-NN multi-scale inversion

(a)—(h) Represent the inversion velocity profiles (left column) and parameterized network outputs (right column) corresponding to the frequency bands of 4 Hz, 6 Hz, 8 Hz and 13 Hz, respectively.

为进一步分析多尺度反演过程中不同频带内深度学习参数化的成像特点,图 8 依次展示了 LSTM-NN 在各频带的反演速度剖面与网络对应的模型更新量,清晰呈现了多尺度反演的逐步重构过程. 从反演结果可以看出,随着反演频带由低频向高频逐步迭代,速度模型的地层连续性明显改善,整体成像分辨率也得到持续提升. 低频阶段获得的较为可靠的速度结果,能够为后续高频反演提供精度更高的初始模型. 结合多尺度分频带目标函数约束与各频带独立的网络参数学习策略,可有效实现多尺度、高精度的速度反演.

图 9 为两种参数化反演对应的目标函数收敛曲线. 相较于 LSTM-NN,CNN 反演的损失曲线震荡幅度更大,该现象在最高频带迭代阶段尤为突出;尽管损失整体呈下降趋势,但随迭代推进,震荡幅度持续加剧. 与之相反,LSTM-NN 反演的目标函数全程平稳下降,收敛速率更快,至最后一个频带迭代末期损失曲线趋于平缓,说明优化路径稳定收敛至极小值. 该优势源于 LSTM-NN 特有的门控结构,可有效调控网络参数更新过程,从数值迭代层面保障了地震速度反演的整体稳定性.

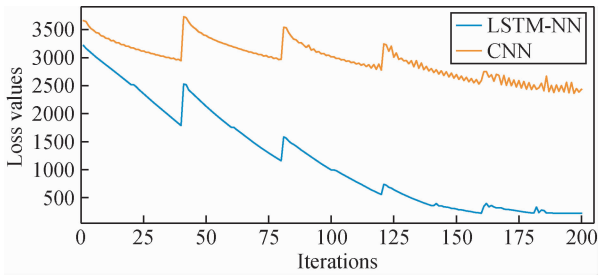


图 9　Overthrust 模型多尺度反演的目标函数下降曲线对比

Fig. 9　Comparison of objective function descent curves of multi-scale inversion on Overthrust model

2.2　Marmousi 模型

选取 Marmousi 模型开展多尺度反演测试,分别采用 LSTM-NN 与 CNN 两种网络完成模型参数化表

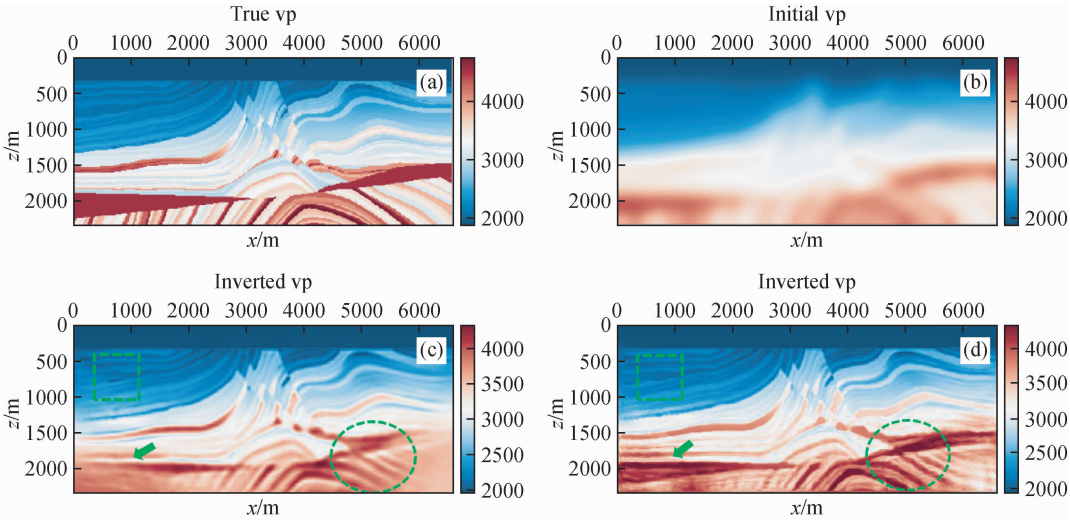


图 10 Marmousi 模型多尺度反演结果对比

(a)真实速度模型;(b)初始速度模型;(c)CNN 参数化反演结果;(d)LSTM-NN 参数化反演结果.

Fig. 10 Comparison of Marmousi model multi-scale inversion results

(a) True velocity model; (b) Initial velocity model; (c) Parameterized inversion results based on CNN; (d) Parameterized inversion results based on LSTM-NN.

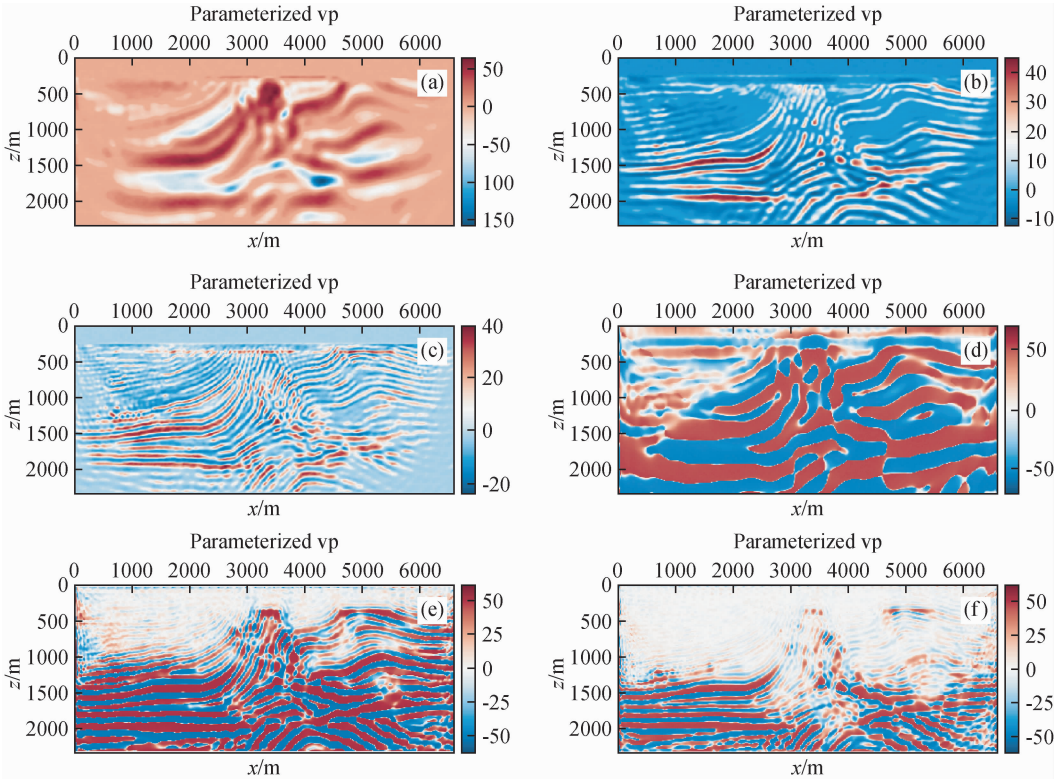


图 11 多尺度反演过程中不同频带的网络参数更新量

(a)—(c)、(d)—(f) 分别为 CNN 和 LSTM-NN 两种方法在 3 Hz、8 Hz、11 Hz 频带下参数化网络的输出更新量.

Fig. 11 Updated amounts of parameterized network outputs of different bands during multi-scale inversion

(a)—(c) CNN, and (d)—(f) LSTM-NN outputs at 3 Hz, 8 Hz and 11 Hz, respectively.

征,对比分析两种神经网络的优劣特征.两组反演均采用 Adagrad 算法完成网络参数的迭代更新.真实速度模型与初始速度模型分别如图 10a、b 所示.模型尺寸为 6.60 km×2.34 km,空间离散网格步长为 10 m,地震观测数据由主频 10 Hz 的雷克子波模拟生成.其中,初始速度模型通过 140 m×140 m 高斯窗口对真实速度模型进行空间光滑处理得到.本次多尺度反演采用分频迭代策略,五个频带的中心频率分别为 3 Hz、5 Hz、8 Hz、11 Hz 和 14 Hz,每个频带独立迭代 40 次,总迭代次数为 200 次.为避免迭代步长过大导致优化过程跳过局部最优解,在各频带迭代后期适当减小更新步长,精细化参数搜索范围,保障算法在全局最优解附近稳定收敛,有效提升速度反演精度.

两种网络参数化的多尺度反演结果如图 10c、d 所示.对比分析可知,LSTM-NN 参数化反演的整体成像精度显著优于 CNN.在大深度、模型边缘区域内,LSTM-NN 反演结果的构造边界轮廓清晰,地层内部速度分布均匀性更好,该优势在图 10 箭头标注区域尤为明显;同时,该方法对大倾角构造的还原效果更为精准,成像质量显著提升,对应图 10 椭圆标注区域.除此之外,在微小层界面、断层断点等精细构造处,LSTM-NN 同样展现出更优异的成像分辨能力,图 10 方框标注区域可清晰印证这一特征;而 CNN 参数化反演结果不仅呈现出构造模糊,还出现了明显的低速异常假象,成像可靠性较差.

图 11 为两种网络的参数化更新量对比结果,可直观反映不同网络的特征学习能力.多尺度迭代过程中,随着输入频带频率不断提高,两类网络均可学习到更高波数信息.对比可知,LSTM-NN 输出的模型更新量集中在中深部,成像层次清晰分明,针对深部速度剧烈变化的构造区域,能够输出更丰富的模型更新信息.CNN 的参数化输出则存在空间层次区分度不足,深部构造更新不足,并且易受观测系统照明影响的问题.基于两类网络差异化的参数学习特征,图 12 展示了两组方法的多尺度递进反演结果.可以看出,随着迭代频带逐级增加,两种方法的反演成像分辨率均得到逐步提升,但 LSTM-NN 参数化反演始终具备更高的成像精度.在深部地层速度重建过程中,LSTM-NN 的重构效果优势尤为显著,这一结果也与两类网络在深部构造区域的参数化更新量差异特征相互印证.

为进一步验证 LSTM-NN 反演方法的迭代稳定性,图 13 展示了两种网络多尺度反演的目标函数收敛曲线.整体来看,CNN 反演的目标函数曲线,在多个频带迭代过程中均出现了大幅度波动,反观 LSTM-NN 的目标函数曲线全程下降趋势平稳,仅在高频迭代阶段出现轻微震荡,进一步说明了 LSTM-NN 参数化反演的迭代稳健性更优.

2.3　Foothills 模型

选取 Foothills 模型开展基于 LSTM-NN 参数化、CNN 参数化以及传统方法的多尺度反演对比测试.其中,传统反演方法未引入神经网络进行模型参数表征,直接依托伴随状态法求取反演梯度,并采用 SGD 算法完成模型参数的迭代更新.Foothills 真实模型与初始模型如图 14 所示,模型尺寸为 8.25 km×5.00 km,空间离散步长为 12.5 m,初始模型通过采用 450 m×450 m 的高斯窗口对真实模型进行空间平滑获得.沿地表均匀布设 46 个震源,结合主频 8 Hz 的雷克子波正演模拟得到地震观测数据.三组反演方法统一采用多尺度分频迭代策略,中心频率依次为 3 Hz、5 Hz、8 Hz、11 Hz 和 14 Hz;每个频带迭代 30 次,总迭代次数为 150 次.

三种方法的多尺度反演成像结果如图 15a—c 所示.整体而言,两类神经网络参数化反演的成像分辨率均明显优于传统反演方法,无论是断层结构刻画、起伏形态还原,还是层速度恢复效果,均表现出更为优异的成像能力.对比三种方案可见,LSTM-NN 参数化反演结果(图 15c)整体精度最高,成像质量优于 CNN(图 15b)与传统反演方法(图 15a).在大深度和模型边缘区域,LSTM-NN 重构的地层内部速度分布更加均匀,构造边界特征清晰,对断层结构的刻画更为精细.尤其是在图 15 箭头标注的区域,该方法的构造形态和地层速度重构方面优势更加显著.图 15d—f 为三种方法对应的反演残差分布图,不难看出 LSTM-NN 反演结果的残差幅值整体最小,反演速度场与真实模型整体一致性较高.相比之下,CNN 与传统反演结果的残差分布范围集中在模型边缘和部分高陡构造,如图中箭头指示区域.同时,表 1 的定量误差统计结果进一步佐证了上述结论,LSTM-NN 参数化反演的绝对误差与相对误差均为三组方法中的最小值,充分说明该方法在复杂构造速度建模中具备更高的反演精度与可靠性.

2.4　实际数据测试

最后,基于 LSTM-NN 参数化多尺度全波形反演方法开展实测地震数据应用测试.实测数据的观测系统沿地表约 11 km 范围内近似均匀布设 60 个震源,各震源对应的地表检波器数量为 348~448 道.

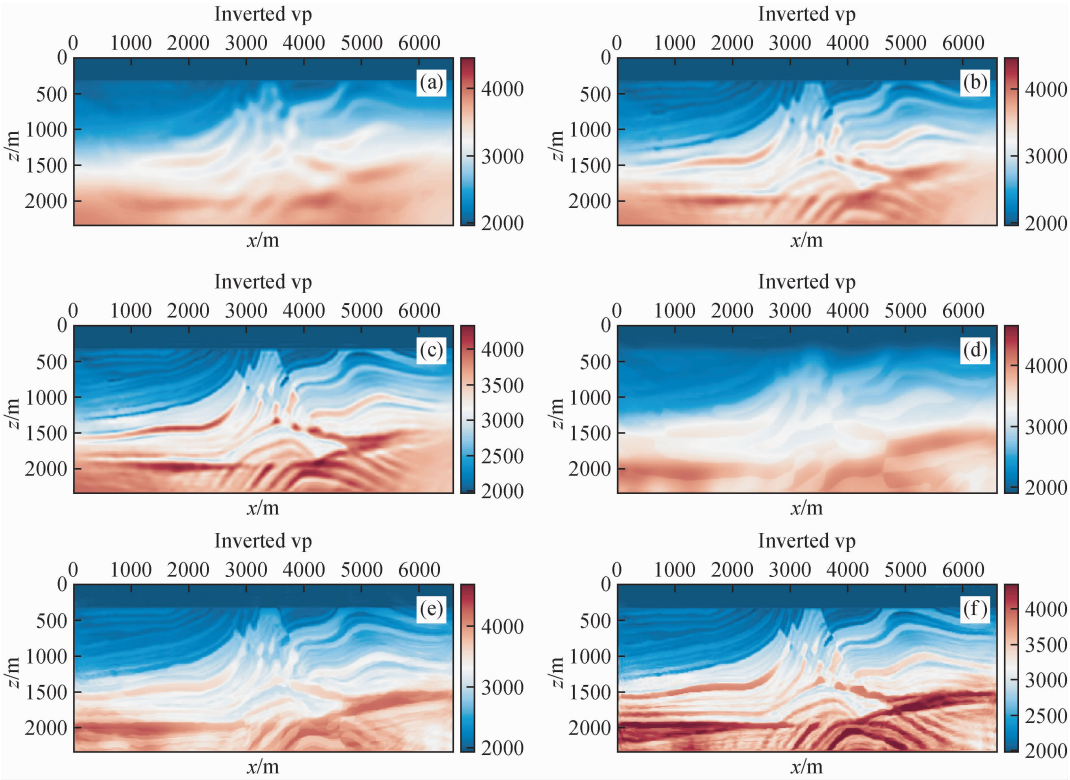


图 12 (a)—(c)、(d)—(f)分别为 CNN 和 LSTM-NN 两种方法在 3 Hz、8 Hz、11 Hz 频带的多尺度反演结果

Fig. 12 Multi-scale inversion results from (a)—(c) CNN, and (d)—(f) LSTM-NN at 3 Hz, 8 Hz and 11 Hz, respectively

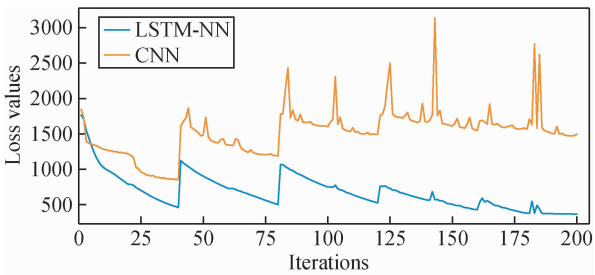


图 13 Marmousi 模型多尺度反演的目标函数下降曲线对比

Fig. 13 Comparison of objective function descent curves of multi-scale inversion on Marmousi model

实测反演所用初始速度模型如图 16a 所示,模型网格点数为 1180×220,空间网格间距 10 m. 地震记录总时长为 4 s,时间采样间隔 1 ms. 多尺度反演的中心频率为 5 Hz、9 Hz、11 Hz 和 14 Hz,每个频带迭代 30 次,总迭代次数为 120 次.

LSTM-NN 参数化方法的实测数据反演结果如图 16b 所示. 可以看出,该方法能够基于平滑的初始速度模型有效重构地下地层结构,清晰刻画地层倾斜特征,尤其在 1.5~1.8 km 关键深度段,层间连续性较好,速度模型的纵向分层界面清晰. 图 17 为基

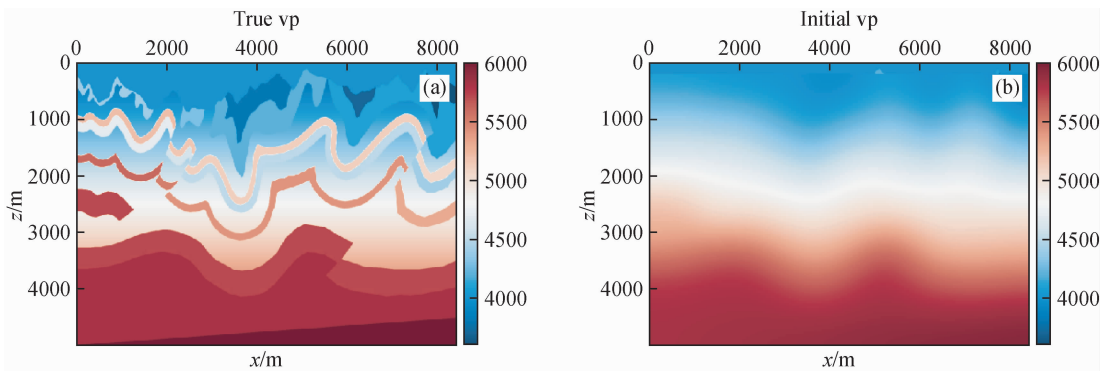


图 14 Foothills 模型(a)真实速度模型与(b)初始速度模型

Fig. 14 Foothills true (a) velocity model and the initial (b) velocity model used in inversion

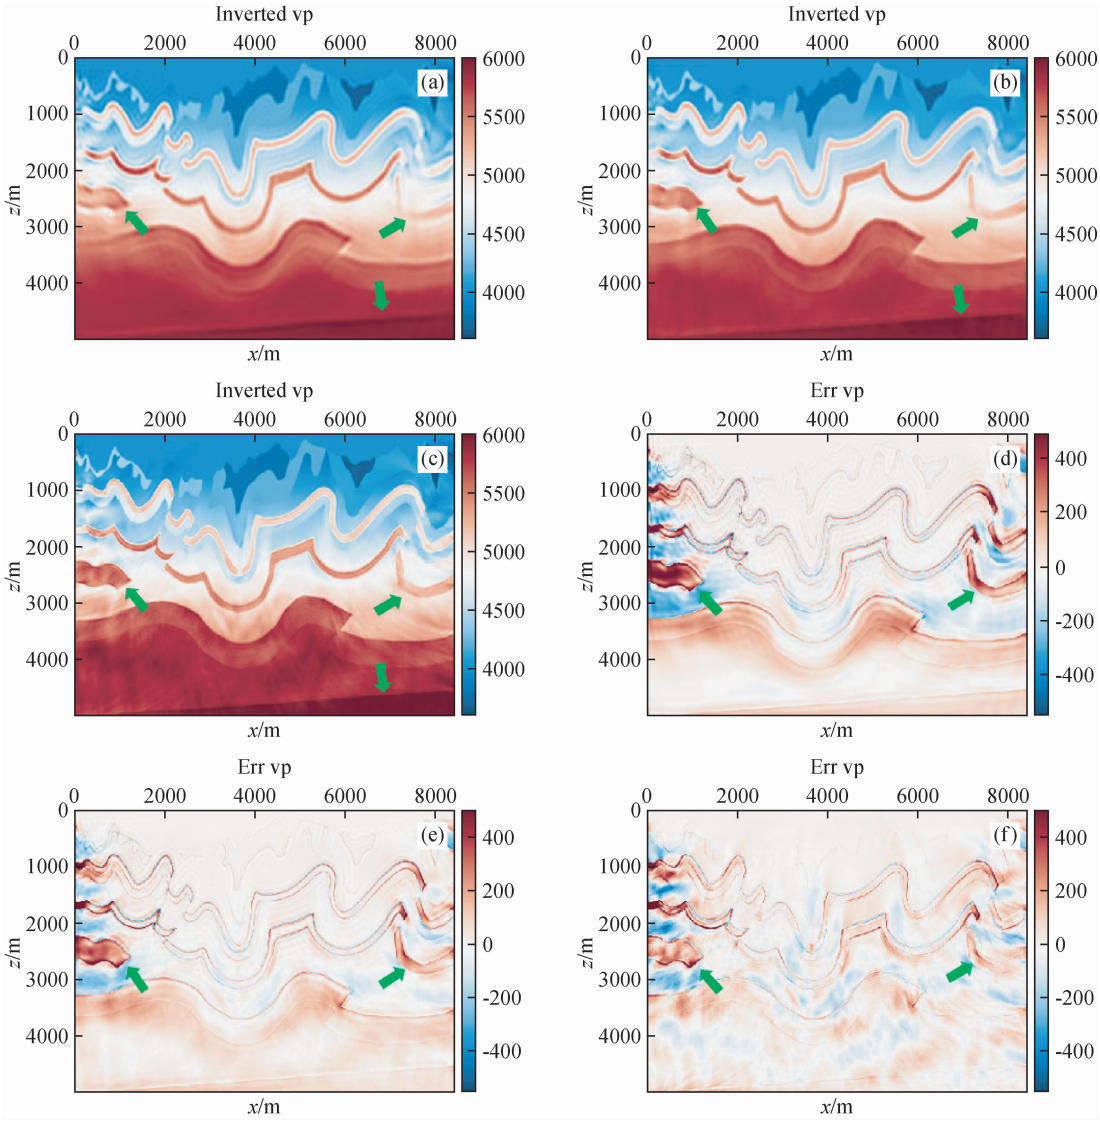


图 15　Foothills 模型反演结果与误差分布对比

(a)传统反演结果;(b)CNN 参数化反演结果;(c)LSTM-NN 参数化反演结果;(d)—(f) 分别为传统反演、CNN 参数化反演、LSTM-NN 参数化反演结果与真实模型的误差分布.

Fig. 15　Comparison of Foothills model inversion results and error distributions

(a) Traditional inversion result; (b) CNN parameterized inversion result; (c) LSTM-NN parameterized inversion result; (d)—(f) Error distributions between the inversion results of traditional method, CNN and LSTM-NN and the true model, respectively.

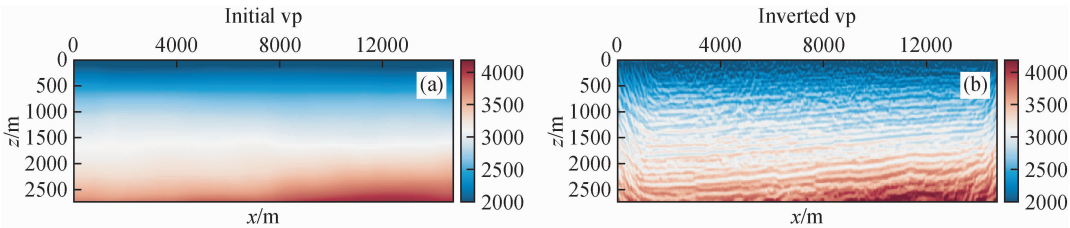


图 16　(a)实际资料反演所用初始模型;(b)LSTM-NN 参数化反演结果

Fig. 16　(a) Initial model used for inversion; (b) Inversion result based on LSTM-NN

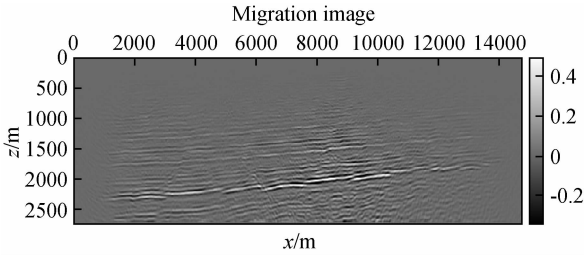


图 17 基于 LSTM-NN 参数化反演结果的偏移成像结果

Fig. 17 Migration image based on the LSTM-NN parameterized inversion result

于反演速度模型得到的地震偏移成像剖面. 由成像结果可知,采用该速度模型进行偏移处理后,地下主要地层反射界面成像清晰,与速度界面的吻合度高,进一步证明了反演速度模型的可靠性. 图 18 选取第 7、29、43 炮道集,对比实测地震数据与反演合成数据的匹配效果. 结果表明,虽然受野外数据噪声、激发能量差异等因素影响,但是关键反射事件的到达时间基本一致,主要反射事件的连续性与变化特征匹配良好,道集拟合效果较为理想. 综上所述,基于 LSTM-NN 参数化的多尺度全波形反演方法在实际地震数据应用中能够重建出较为可靠的速度模型.

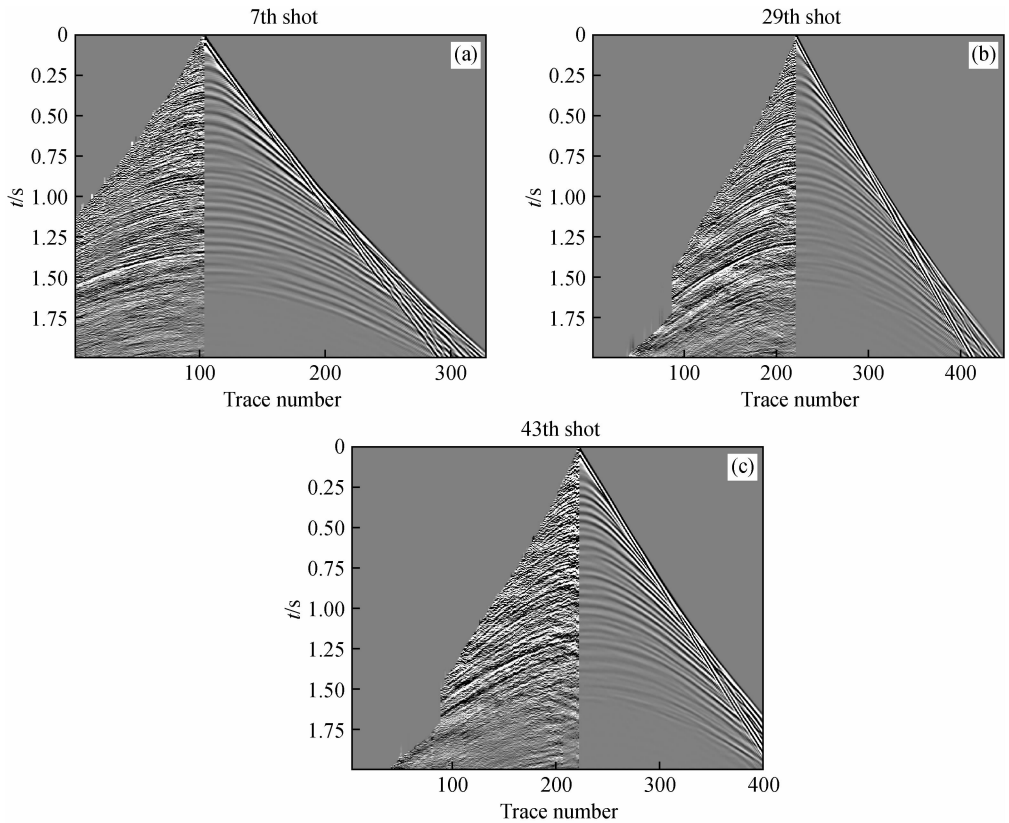


图 18 (a)第 7 炮、(b)第 29 炮、(c)第 43 炮观测数据与合成数据的共炮点道集记录对比

Fig. 18 Comparison of observed and synthetic common-shot gathers for (a) shot 7, (b) shot 29 and (c) shot 43

3 结论与讨论

全波形反演凭借高精度的建模优势,已成为地震速度建模的核心技术手段. 传统全波形反演的实际计算过程注重求解效率,往往需要搭配边界存储策略与多 GPU 并行加速以降低计算成本. 采用深度学习融合伴随梯度的研究思路,可天然适配现有高性能计算架构. 通过神经网络实现模型参数化表征,并依托深度学习优化器完成迭代更新,能够有效提升传统反演成像精度,解决了自动微分反演框架在大规模数值计算中实用性不足的问题.

网络结构的合理选取,是提升全波形反演成像精度与迭代稳定性的关键. 本文分别构建基于 CNN 与 LSTM-NN 参数化的全波形反演框架,基于 Overthrust、Marmousi 和 Foothills 三种模型,开展了单尺度与多尺度速度反演的对比试验. 结果表明,相较于传统反演与 CNN 参数化反演,LSTM-NN 参数化反演可更精准地重构地下速度场,对复杂构造、深部

地层与层状界面的重构能力更为突出.同时,该方法受观测系统照明不足的影响更小,迭代优化过程更加稳健,有效提升了常规全波形反演成像分辨率、增强了反演算法的稳健性.实测地震数据的应用测试进一步证实了该方法的有效性,可稳定重建合理的速度模型.

本文研究仍存在一定局限性,现阶段仅基于卷积型目标函数,完成了基于声波方程的单参数深度学习参数化反演研究.相较于声波方程,弹性波方程以及考虑地下介质衰减吸收的黏滞波动方程,能够更加准确地描述地震波传播规律,后续研究可围绕上述复杂方程开展深度学习参数化全波形反演,结合凸性更好的目标函数,进一步提升多参数的建模精度与算法的适应性,逐步完善深度学习融合伴随梯度的反演理论方法.

致　谢　感谢审稿专家提出的修改意见和编辑部的大力支持!

References

Bunks C, Saleck F M, Zaleski S, *et al*. 1995. Multiscale seismic waveform inversion. Geophysics, 60(5): 1457-1473.

Crase E, Pica A, Noble M, *et al*. 1990. Robust elastic nonlinear waveform inversion: Application to real data. Geophysics, 55(5): 527-538.

Duan Y X, Cui L L, Sun Q F, *et al*. 2023. Deep learning seismic waveform inversion based on the forward modeling guidance of wave equation. Oil Geophysical Prospecting (in Chinese), 58(3): 485-494.

Duchi J, Hazan E, Singer Y. 2011. Adaptive subgradient methods for online learning and stochastic optimization. Journal of Machine Learning Research, 12: 2121-2159.

Fabien-Ouellet G, Gloaguen E, Giroux B. 2017. Time domain viscoelastic full waveform inversion. Geophysical Journal International, 209(3): 1718-1734.

Fang J W, Zhou H, Li Y E, *et al*. 2024. Deep-learning optimization using the gradient of a custom objective function: A full-waveform inversion example study on the convolutional objective function. Geophysics, 89(5): R479-R492.

Fang J W, Wang N, Zhao P, *et al*. 2025. Deep learning reparameterized FWI using a frequency-normalized gradient. IEEE Geoscience and Remote Sensing Letters, 22: 7509905, doi: 10.1109/LGRS.2025.3624703.

Fang J W, Chen J, Wang E Y. 2026. LSTM network reparameterized FWI: robust dual-mechanism source-independent approach. IEEE Geoscience and Remote Sensing Letters, 23: 7500105, doi: 10.1109/LGRS.2025.3631955.

Feng H X, Liu H, Sun J, *et al*. 2017. Hybrid domain full waveform inversion based on GPU/CPU and source random coding technique. Geophysical Prospecting for Petroleum (in Chinese), 56(1): 107-115.

Geng Z C, Zhao Z Y, Shi Y Z, *et al*. 2022. Deep learning for velocity model building with common-image gather volumes. Geophysical Journal International, 228(2): 1054-1070.

He Q L, Wang Y F. 2021. Reparameterized full-waveform inversion using deep neural networks. Geophysics, 86(1): V1-V13.

Hochreiter S, Schmidhuber J. 1997. Long short-term memory. Neural Computation, 9(8): 1735-1780, doi: 10.1162/neco.1997.9.8.1735.

Hu G H, He W G. 2023. Optimal transfer function in full waveform inversion. Geophysical Prospecting for Petroleum (in Chinese), 62(5): 832-849.

Jiang P, Wang Q Y, Ren Y X, *et al*. 2024. Full waveform inversion based on inversion network reparameterized velocity. Geophysical Prospecting, 72(1): 52-67.

Kang P F, Hu Y, Liu R D, *et al*. 2025. Local-scale frequency-wavenumber domain phase inversion. Progress in Geophysics (in Chinese), 40(1): 155-165, doi: 10.6038/pg2025II0034.

Lailly P. 1983. The seismic inverse problem as a sequence of before stack migrations. //Conference on Inverse Scattering: Theory and Application. Philadelphia: SIAM, 206-220.

Li Z C, Li C, Huang J P, *et al*. 2016. Regularized least-squares reverse time migration with prior model. Oil Geophysical Prospecting (in Chinese), 51(4): 738-744.

Liu F L, Zhou H, Wang L Q, *et al*. 2026. Full-waveform inversion method based on exponential regularization constraint. Progress in Geophysics (in Chinese), 41(3): 1099-1110, doi: 10.6038/pg2026JJ0238.

Liu Y Z, Huang X Q, Wan X W, *et al*. 2019. Elastic multi-parameter full-waveform inversion for anisotropic media. Chinese Journal of Geophysics (in Chinese), 62(5): 1809-1823, doi: 10.6038/cjg2019M0176.

Mao S B, Li J, Tong S Y, *et al*. 2026. Full waveform inversion of anisotropic parameters in VTI media based on automatic differentiation. Chinese Journal of Geophysics (in Chinese), 69(1): 292-309, doi: 10.6038/cjg2025S0636.

Mora P. 1987. Nonlinear two-dimensional elastic inversion of multioffset seismic data. Geophysics, 52(9): 1211-1228.

Moseley B, Markham A, Nissen-Meyer T. 2020. Solving the wave equation with physics-informed deep learning. arXiv preprint arXiv: 2006.11894.

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(2): 495-503.

Pratt R G, Shin C, Hick G J. 1998. Gauss-Newton and full Newton methods in frequency-space seismic waveform inversion. Geophysical Journal International, 133(2): 341-362.

Qiao H Q, Wang S C. 2026. A Markov chain Monte Carlo approach based on CNN-LSTM for cross-hole GPR full waveform inversion. Journal of Geophysics and Engineering, 23(1): 188-196.

Raissi M, Yazdani A, Karniadakis G E. 2020. Hidden fluid mechanics: Learning velocity and pressure fields from flow visualizations. Science, 367(6481): 1026-1030.

Rasht-Behesht M, Huber C, Shukla K, *et al*. 2022. Physics-informed neural networks (PINNs) for wave propagation and full waveform inversions. J. Geophys. Res.: Solid Earth, 127(5): e2021JB023120, doi: 10.1029/2021JB023120.

Ravaut C, Operto S, Improta L, *et al*. 2004. Multiscale imaging of complex structures from multifold wide-aperture seismic data by frequency-domain full-waveform tomography: application to a thrust belt. Geophysical Journal International, 159(3): 1032-1056.

Richardson A. 2018. Seismic full-waveform inversion using deep learning tools and techniques. arXiv preprint arXiv: 1801.07232.

Rurden S. 2017. An overview of gradient descent optimization algorithms. arXiv preprint arXiv: 1609.04747.

Schuster G T, Chen Y Q, Feng S H. 2024. Review of physics-informed machine-learning inversion of geophysical data. Geophysics, 89(6): T337-T356.

Shan L P, Yu C X, Wang Y F. 2025. A collocation point sampling

method for solving the Helmholtz equation using physics-informed neural networks. Coal Geology & Exploration (in Chinese), 53(9): 182-190.

Shi Y, Ke X, Zhang Y Y. 2015. Analyzing the boundary conditions and storage strategy for reverse time migration. Progress in Geophysics (in Chinese), 30(2): 581-585, doi: 10.6038/pg20150214.

Shin C, Ho Cha Y. 2009. Waveform inversion in the Laplace-Fourier domain. Geophysical Journal International, 177(3): 1067-1079.

Sirgue L, Pratt R G. 2004. Efficient waveform inversion and imaging: A strategy for selecting temporal frequencies. Geophysics, 69(1): 231-248.

Sirgue L, Barkved O I, Dellinger J, *et al*. 2010. Thematic set: Full waveform inversion: The next leap forward in imaging at Valhall. First Break, 28(4): 65-70.

Song C, Alkhalifah T, Waheed U B. 2021. Solving the frequency-domain acoustic VTI wave equation using physics-informed neural networks. Geophysical Journal International, 225(2): 846-859.

Sun J, Innanen K, Zhang T Z, *et al*. 2023. Implicit seismic full waveform inversion with deep neural representation. Journal Geophysical Research: Solid Earth, 128(3): e2022JB025964, doi: 10.1029/2022JB025964.

Tarantola A. 1984. Inversion of seismic reflection data in the acoustic approximation. Geophysics, 49(8): 1259-1266.

Trad D. 2022. GPU applications for modelling, imaging, inversion and machine learning. //Proceedings of the Geoconvention. Calgary, Canada.

Virieux J, Operto S. 2009. An overview of full-waveform inversion in exploration geophysics. Geophysics, 74(6): WCC1-WCC26.

Wang W H, Ke X, Pei J Y. 2013. Application investigation of perfectly matched layer absorbing boundary condition. Progress in Geophysics (in Chinese), 28(5): 2508-2514, doi: 10.6038/pg20130529.

Wang W L, McMechan G A, Ma J W. 2021. Elastic isotropic and anisotropic full-waveform inversions using automatic differentiation for gradient calculations in a framework of recurrent neural networks. Geophysics, 86(6): R795-R810.

Wang Y F. 2026. Model, data, and knowledge-driven geophysical inverse problems and intelligent computing. Science China Earth Sciences, doi: 10.1007/s11430-025-1868-y.

Wu Y L, McMechan G A. 2019. Parametric convolutional neural network-domain full-waveform inversion. Geophysics, 84(6): R881-R896, doi: 10.1190/geo2018-0224.1.

Xie H, Wang J Y. 2025. Research on tunnel lining disease identification method based on LSTM neural network. Progress in Geophysics (in Chinese), 40(5): 2227-2236, doi: 10.6038/pg2025II0117.

Xin T L, Huang J P, Xie F, *et al*. 2020. Source-independent frequency-domain full waveform inversion based on data similarity. Oil Geophysical Prospecting (in Chinese), 55(2): 341-350.

Yang D H, Dong X P, Huang J D, *et al*. 2025. High-resolution full waveform seismic imaging: Progresses, challenges, and prospects. Science China Earth Sciences, 68(2): 315-342.

Yang F S, Ma J W. 2019. Deep-learning inversion: A next-generation seismic velocity model building method. Geophysics, 84(4): R583-R599.

Yang H, Zhang M K, Sun P Y, *et al*. 2024. Acoustic full waveform inversion method based on local storage strategy. Chinese Journal of Geophysics (in Chinese), 67(6): 2388-2401, doi: 10.6038/cjg2023R0441.

Yang J, Ding R W, Lin N T, *et al*. 2022. Research progress of intelligent identification of seismic faults based on deep learning. Progress in Geophysics (in Chinese), 37(1): 298-311, doi: 10.6038/pg2022FF0233.

Yi J D, Zhang M, Li Z C, *et al*. 2023. Review of deep learning seismic data reconstruction methods. Progress in Geophysics (in Chinese), 38(1): 361-381, doi: 10.6038/pg2023GG0048.

Zhang A, Lipton Z C, Li M, *et al*. 2023. Dive into Deep Learning. Cambridge: Cambridge University Press.

Zhang Q C, Mao W J, Fang J W. 2020. Crosstalk-free simultaneous-source full waveform inversion with normalized seismic data. Computers & Geosciences, 138: 104460, doi: 10.1016/j.cageo.2020.104460.

Zhang W, Gao J H, Gao Z Q, *et al*. 2021. Adjoint-driven deep-learning seismic full-waveform inversion. IEEE Transactions on Geoscience and Remote Sensing, 59(10): 8913-8932.

Zhang Z P, Lin Y Z. 2020. Data-driven seismic waveform inversion: A study on the robustness and generalization. IEEE Transactions on Geoscience and Remote Sensing, 58(10): 6900-6913.

Zhao P, Fang J W, Jie C, *et al*. 2025. Multiscale deep learning reparameterized full waveform inversion with the adjoint method. IEEE Transactions on Geoscience and Remote Sensing, 63: 5908612, doi: 10.1109/TGRS.2025.3553053.

Zhu W Q, Xu K L, Darve E, *et al*. 2022. Integrating deep neural networks with full-waveform inversion: Reparameterization, regularization, and uncertainty quantification. Geophysics, 87(1): R93-R109.

Zou J B, Liu C, Zhao P F. 2023. Research progress of physics-informed neural network in seismic wave modeling. Progress in Geophysics (in Chinese), 38(1): 430-448, doi: 10.6038/pg2023GG0142.

附中文参考文献

段友祥, 崔乐乐, 孙歧峰, 等. 2023. 波动方程正演引导的深度学习地震波形反演. 石油地球物理勘探, 58(3): 485-494.

冯海新, 刘洪, 孙军, 等. 2017. 基于 GPU/CPU 和震源随机编码技术的混合域全波形反演. 石油物探, 56(1): 107-115.

胡光辉, 贺伟光. 2023. 全波形反演中最优化传输函数研究. 石油物探, 62(5): 832-849.

康鹏飞, 胡勇, 刘瑞东, 等. 2025. 局部尺度频率波数域相位反演. 地球物理学进展, 40(1): 155-165, doi: 10.6038/pg2025II0034.

李振春, 李闯, 黄建平, 等. 2016. 基于先验模型约束的最小二乘逆时偏移方法. 石油地球物理勘探, 51(4): 738-744.

刘峰良, 周辉, 王玲谦, 等. 2026. 一种基于指数正则化约束的全波形反演方法. 地球物理学进展, 41(3): 1099-1110, doi: 10.6038/pg2026JJ0238.

刘玉柱, 黄鑫泉, 万先武, 等. 2019. 各向异性介质弹性波多参数全波形反演. 地球物理学报, 62(5): 1809-1823, doi: 10.6038/cjg2019M0176.

毛士博, 李键, 童思友, 等. 2026. 基于自动微分的 VTI 介质各向异性参数全波形反演. 地球物理学报, 69(1): 292-309, doi: 10.6038/cjg2025S0636.

单连璞, 于彩霞, 王彦飞. 2025. 物理信息神经网络求解亥姆霍兹方程的配置点采样方法. 煤田地质与勘探, 53(9): 182-190.

石颖, 柯璇, 张莹莹. 2015. 逆时偏移边界条件与存储策略分析. 地球物理学进展, 30(2): 581-585, doi: 10.6038/pg20150214.

王维红, 柯璇, 裴江云. 2013. 完全匹配层吸收边界条件应用研究. 地球物理学进展, 28(5): 2508-2514, doi: 10.6038/pg20130529.

王彦飞. 2026. 模型、数据与知识驱动的地球物理反问题及智能计算. 中国科学: 地球科学, doi: 10.1360/SSTe-2025-0113.

谢豪, 王靖宇. 2025. 基于 LSTM 神经网络的隧道衬砌病害识别方法研究. 地球物理学进展, 40(5): 2227-2236, doi: 10.6038/

pg2025II0117.

辛天亮, 黄建平, 解飞, 等. 2020. 基于数据相似性的不依赖子波的频率域全波形反演. 石油地球物理勘探, 55(2): 341-350.

杨顶辉, 董兴朋, 黄建东, 等. 2025. 高分辨率全波形地震成像研究——进展、挑战与展望. 中国科学: 地球科学, 55(2): 319-347.

杨瀚, 张明坤, 孙鹏远, 等. 2024. 基于局部存储策略的声波全波形反演方法. 地球物理学报, 67(6): 2388-2401, doi: 10.6038/cjg2023R0441.

杨晶, 丁仁伟, 林年添, 等. 2022. 基于深度学习的地震断层智能识别研究进展. 地球物理学进展, 37(1): 298-311, doi: 10.6038/pg2022FF0233.

易继东, 张敏, 李振春, 等. 2023. 深度学习地震数据重建方法研究综述. 地球物理学进展, 38(1): 361-381, doi: 10.6038/pg2023GG0048.

邹婧博, 刘财, 赵鹏飞. 2023. 地震波正演问题的物理信息神经网络算法研究进展. 地球物理学进展, 38(1): 430-448, doi: 10.6038/pg2023GG0142.