

DOI: 10.11835/j.issn.2096-6717.2026.020



开放科学(资源服务)标识码 OSID:



基于大数据深度学习的地下油管声学探测方法 实验研究

孙海君¹, 刘元雪², 龚宏伟², 郭炜¹, 陈伟¹, 胡荃², 唐传茗²

(1. 军事科学院国防工程研究院, 北京 100850; 2. 联勤保障部队工程大学高原山地环境下设施破坏机制与防护重庆市重点实验室, 重庆 401311)

摘要:在浅层探测中,受复杂地质条件、噪声干扰以及多路径效应等因素的影响,传统地震勘探方法难以获得地下掩埋物的高分辨率图像。通过融合深度神经网络信号去噪方法,采用 DeepDenoiser 进行预训练,构建大数据深度学习模型,设计神经网络架构,提出了一种基于大数据深度学习的全波形反演方法(DNFWI)。为验证该方法在实际探测中的有效性及性能,设计水平剪切波源和垂直源两种电动激振方式,对砂层中的掩埋输油钢管进行声学探测试验,通过分析采集的声信号得到掩埋物传感器传递函数、地面特性、地面波速、地表信号时程曲线及功率谱图,采用 DNFWI 方法对两种激振方式的成像效果进行对比分析。结果表明,水平式激振的深度衰减率约为 20~25 dB/m,垂直式激振的深度衰减率约为 10~20 dB/m,表面波的空间衰减率约为 11 dB/m;因 SH 波与钢制油管剪切波阻抗差异更大,反射信号更强,采用 SH 波反演成像后掩埋物的位置更加清晰,比垂直波反演更能有效定位掩埋油管;DNFWI 比传统 FWI 方法定位精度提升 66.7%,收敛迭代次数减少 59.7%,计算时间减少 60.8%。

关键词:地下油管;声学探测;大数据;深度学习;全波形反演

中图分类号:TU990.3 文献标志码:A 文章编号:2096-6717(XXXX)XX-0001-10

Experimental study of underground pipeline acoustic detection method based on big data deep learning

SUN Haijun¹, LIU Yuanxue², GONG Hongwei², GUO Wei¹, CHEN Wei¹,
HU Quan², TANG Chuanming²

(1. Institute of Defense Engineering, AMS, PLA, Beijing 100850, P. R. China; 2. Chongqing Key Laboratory of Failure Mechanism and Protection of Facility in Plateau and Mountain Environment, PLA Joint Logistics Support Force University of Engineer, Chongqing 401311, P. R. China)

Abstract: In shallow exploration, complex geological conditions, noise interference, and multi-path effects

收稿日期:2025-11-28

基金项目:重庆市自然科学基金院士专项(CSTB2023YSZX-JCX0004);重庆市级人才计划项目(cstc2024ycjh-bgzxm0028)

作者简介:孙海君(1980-),女,正高级工程师,主要从事油料储运设计与研究,E-mail:sunhaijun1980@126.com。

刘元雪(通信作者),男,博士,教授,E-mail:lyuanxue@vip.sina.com。

Received: 2025-11-28

Foundation items: The Academician Special Project of Natural Science Foundation of Chongqing (No. CSTB2023YSZX-JCX0004); The Chongqing Talent Plan Project (No. cstc2024ycjh-bgzxm0028)

Author brief: SUN Haijun (1980-), senior engineer, main research interests: design and research of oil storage and transportation, E-mail: sunhaijun1980@126.com.

LIU Yuanxue (corresponding author), PhD, professor, E-mail: lyuanxue@vip.sina.com.

severely hinder traditional seismic methods from acquiring high-resolution images of underground buried objects. To address this challenge, we propose a data-driven neural network-based full waveform inversion (DNFWI) method, which integrates deep neural network signal denoising with pre-trained DeepDenoiser, coupled with a tailored big data deep learning model and optimized neural network architecture. For validating its effectiveness and performance in practical detection, two electric excitation modes—horizontal shear wave (SH-wave) source and vertical source—were designed, and acoustic detection tests were conducted on buried steel oil pipelines in sand formations. By analyzing the collected acoustic signals, key parameters including the sensor transfer function of buried objects, ground properties, surface wave velocity, surface signal time-histories, and power spectra were derived. The imaging results of the two excitation modes were compared using DNFWI. Our findings indicate that the depth attenuation rate is approximately 20-25 dB/m for horizontal excitation and 10-20 dB/m for vertical excitation, with a spatial attenuation rate of ~ 11 dB/m for surface waves. Notably, SH-wave inversion yields stronger reflected signals due to the larger shear wave impedance contrast with steel pipelines, enabling clearer localization of buried objects and outperforming vertical wave inversion in pipeline positioning. Compared to traditional FWI, DNFWI enhances positioning accuracy by 66.7%, reduces convergence iterations by 59.7%, and shortens computation time by 60.8%.

Keywords: underground oil pipeline; acoustic detection; big data; deep learning; full waveform inversion

探测地下油管的主要目的是确定油管的准确位置、走向、埋深以及可能存在的损坏或泄漏情况,为地下管线的规划、建设、运行与维护提供重要依据^[1]。电磁法^[2]、磁法^[3]、探地雷达法^[4]等传统探测技术在高噪声环境、非金属材料、深层掩埋物等探测方面存在严重受限,声学探测成为复杂环境探测的重要方法^[5]。

大数据和深度学习技术已广泛应用。深度学习通过模拟人脑神经网络的工作方式,能够逐层提取数据的高级结构特征,在处理复杂任务时具有更高的准确性。大数据为深度学习提供了丰富训练资源,使得模型能够学习到更多、更复杂的特征和模式^[6-7]。全波形反演(Full Waveform Inversion,简称FWI)是一种先进的地球物理成像技术,通过地震波的传播、反射重建地下介质的物理特性。FWI直接基于波动方程来描述地震波在地下介质中的传播过程,利用地震波的全部信息获得高分辨率的反演图像。但FWI需要进行大量的波场模拟和迭代计算,计算量巨大,对初始模型过度依赖,容易陷入局部极值^[8-9]。

近年来,深度学习与FWI的融合研究已取得显著进展。物理信息神经网络(Physics-Informed Neural Networks,简称PINN)通过将物理方程嵌入损失函数,实现了物理约束与数据驱动的结合,但该类方法对初始模型依赖性较强,且在高噪声浅层场景中泛化性有限,部分研究采用大数据预训练策略优化FWI,但未针对浅层声学探测的高频、小尺度特性进行适配^[10-12]。

以输油钢管作为地下掩埋物,设计声学探测实

验方案,研究声学探测的不同激振方式和声学定位方法的有效性。提出融合信号去噪与迁移学习的FWI数据预处理流程,适配浅层声学探测的高频、高噪声特性;采用神经网络参数化速度场,通过空间相关性约束与隐式正则化,有效缓解FWI局部极值问题;设计水平剪切(Shear Horizontal,简称SH)源与垂直源对比实验,揭示剪切波在金属管线探测中的优势机理,为工程应用提供技术支撑。采用DeepDenoiser预训练、迁移学习适配与神经网络参数化速度场的三级优化框架,整合大数据深度学习算法和全波形反演声学模型,实验验证了基于大数据深度学习的全波形反演(Data-driven Neural-network-deep-learning Full Waveform Inversion,简称DNFWI)方法的声学成像效果,既解决了浅层探测的噪声干扰问题,又通过隐式正则化缓解了局部极值,同时降低了计算复杂度,形成了针对地下油管探测的专用技术方案。

1 方法原理

为优化FWI方法的数据处理流程,提升反演的效率与精度,使用DeepDenoiser^[13-14]进行预训练。该算法通过迁移学习能够快速适应新的地震数据集,学习并掌握地震信号的复杂特征,在高噪声背景下有效分离信号与噪声,显著提升信噪比。在深度学习框架下提出DNFWI方法,将深度神经网络融入传统FWI流程,通过优化神经网络权重,简化目标函数梯度计算,提升反演过程稳定性和收敛速度。

1.1 数据预处理

数据处理参照 Zhu 等^[15]提出的网络架构进行 DeepDenoiser 预训练,该文献采用 North California Seismic Network(简称 NCED)记录的高宽带信道 30 秒地震图。在信号和噪声数据集中,45 104 个样

本被用作信号训练集,5 576 个样本被用作信号验证集,5 665 个样本被用作信号测试集。对于噪声数据集,143 403 样本用于训练,17 890 个样本用于验证,17 940 个样本用于测试,该方法的数据处理流程如图 1 所示。

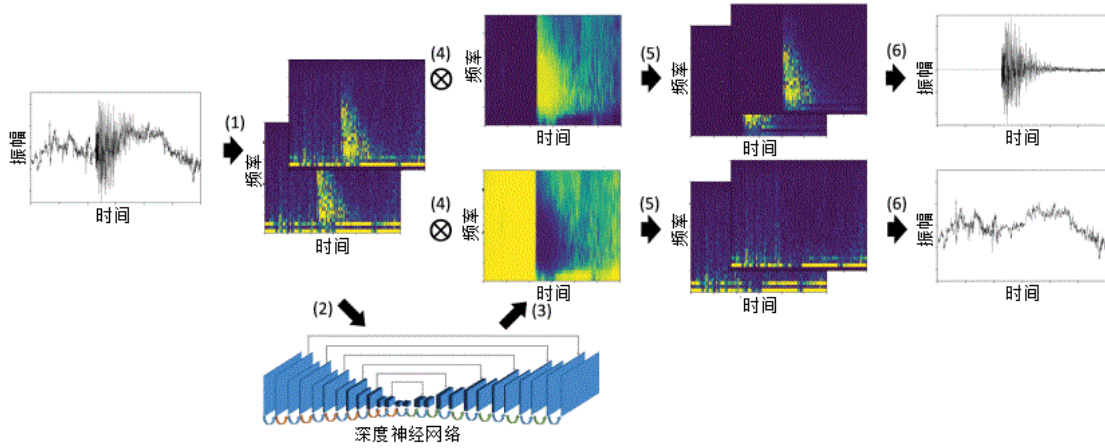


图 1 数据处理流程图^[15]

Fig.1 Chart of data processing flow^[15]

迁移学习采用 STanford Earthquake Dataset(简称 STEAD)数据集进行训练^[16]。采用多次重复迭代信号的方式建立训练集。数据准备阶段,将数据随机分为训练集(85%)、验证集(5%)和测试集(10%)。

NCEDC 与 STEAD 数据集为大尺度地质探测信号,低频信号占比高,覆盖范围广、衰减慢。对于小尺度浅层管线探测,高频信号占比高,信号传播距离短,且噪声特性与 NCEDC 与 STEAD 数据集不同。为此,参考文献^[15]的处理方式进行数据预处理,并将迁移学习预训练模型适配至人工激振产生的高频、小尺度的浅层声学信号,再补充 500 组自主采集的油管探测实测数据针对浅层声学探测场景优化去噪阈值与训练策略,确保模型适配目标场景。试验结果表明,采用 NCEDC 和 STEAD 数据集迁移学习结合自主采集数据训练后,信噪比提升 32.7%,验证了迁移学习策略的有效性。

1.2 深度学习模型

DNFwi 方法的数值预测是波动方程(表示为 $F(\hat{u}, m) = 0$)的解,使用偏微分方法来模拟波动方程^[17],即

$$\frac{\partial^2 u}{\partial t^2} = c^2 \nabla^2 u + f \quad (1)$$

式中: u 为波场; c 为反演波速,此处指速度未知场 m ; f 为震源。估计速度未知场 m 的偏微分方程约束优化问题由式(2)给出。

$$\min D(\hat{u}(x, t, m), u) =$$

$$\sum_{i=1}^I \sum_{j=1}^J \int_0^T \|\hat{u}(x_i, x_j, t, m) - u(x_i, x_j, t)\|_2^2 dt$$

$$s.t. F(\hat{u}, m) = 0 \quad (2)$$

式中: D 为失配函数,即 L2 范数残差; $\{x_i\}_{i=1}^I$ 为激震源的空间离散位置; $\{x_j\}_{j=1}^J$ 为接收器的空间离散位置。

此外,深度神经网络的正则化效应帮助缓解了 FWI 中常见的局部最小值问题。通过在训练过程中应用 dropout、权重衰减等技术,神经网络能够学习到更加泛化的特征,减少对特定数据点的过度拟合,从而在处理噪声数据时表现出更强的鲁棒性。

传统 FWI 易陷入局部极值的本质原因是目标函数的高度非线性与多峰特性,而 DNFwi 通过神经网络的正则化效应从空间相关性约束、隐式正则化抑制过拟合和初始模型优化缓解该问题。首先,对于空间相关性约束,神经网络以空间坐标为输入,输出对应位置的波速值, Tanh 激活函数与全连接层的权重共享机制使相邻坐标点的波速输出具有强相关性,避免速度场出现突变,减少局部极值点数量。其次,对于隐式正则化抑制过拟合,训练过程中引入的权重衰减与 Dropout,约束网络权重的范数,使速度场模型更平滑,避免对噪声数据的过度拟合,降低陷入噪声诱导局部极值的概率。最后,对于初始模型的优化,DNFwi 的初始模型由神经网络生成,该模型通过大数据预训练学习介质空

间分布规律,初始模型与真实模型的相似度高,反演从更接近全局最优的起点开始迭代,显著提升收

敛至全局最优的概率,结合神经网络和地震波偏微分方程的DNFWI流程图如图2所示。

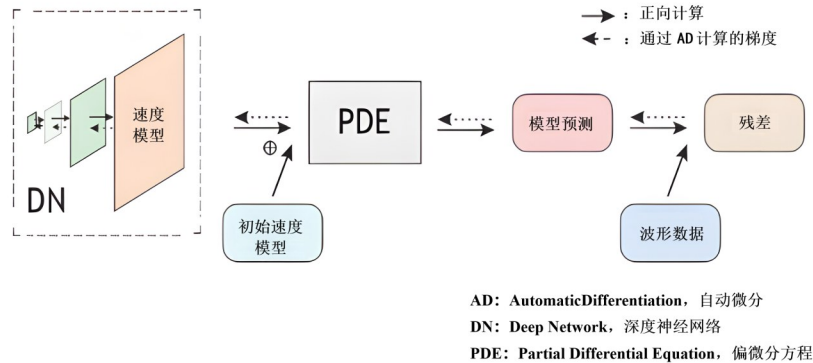


图2 结合神经网络和地震波偏微分方程的DNFWI流程图

Fig.2 DNFWI flow chart of neural network and seismic wave PDE

1.3 神经网络架构

传统FWI方法能够保证反演的收敛性和稳定性,但含有正则化项的失配函数要求较高的算力,正演中量化速度模型的不确定性会导致陷入局部最优解。为解决这些问题,DNFWI方法的处理方式为

$$m = \mathcal{N}(z, \omega) \quad (3)$$

式中: \mathcal{N} 为生成的神经网络; z 为潜在变量; ω 包括神经网络的权重。式(3)通过用神经网络表示速度场 m 来引入速度场的正则化。表1展示了全连接层的神经网络,将潜在变量 z 设置为坐标 x ,因此 $\mathcal{N}(x, \omega)$ 对 m 施加空间相关性,即如果空间坐标 x_1 和 x_2 相似,则 $\mathcal{N}(x_1, \omega)$ 和 $\mathcal{N}(x_2, \omega)$ 也同样近似。

表1 DNFWI中神经网络的架构

Table 1 Neural network architecture of DNFWI

网络类型	DN层类型	网络架构
全连接神经网络	输入层	空间坐标 x
	第1层	全连接层(通道=30)+ Tanh(激活函数)
	第2层	全连接层(30)+ Tanh
	第3层	全连接层(30)+ Tanh
	第4层	全连接层(1)+ Tanh

在表1中,全连接神经网络主要承担速度场参数化与正则化的双重功能,具体应用流程如下:首先,网络输入为地下介质的空间坐标,通过4层全连接层映射输出对应空间位置处的波速,通过遍历所有坐标点形成完整的地下速度场 m ;然后,将速度场 m 输入波动方程正演模块,计算预测波场 u ;最后,基于预测波场和观测波场的残差,通过自动微分更新网络权重 ω ,实现速度场的迭代优化。该设计通过神经网络替代传统FWI的初始模型与正则化模块,解决初始模型依赖问题,降低算力消耗。

在选用Tanh激活函数时,主要考虑了输出范围

约束、梯度特性和平滑性因素。通过归一化处理将波速约束在合理区间,Tanh函数在中间区域梯度较大,利于深层网络的梯度传播,缓解梯度消失问题;Tanh函数的连续可导特性使速度场的空间变化更平滑,符合地下介质的物理连续性,进一步抑制局部极值。

DNFWI深度神经网络训练数据集包括实际地震数据和合成地震数据。除公开数据集外,还通过地震波正演模拟浅层掩埋物的合成地震数据,进一步丰富DNFWI的训练和验证数据集。DNFWI的训练基于Ubuntu18.04(虚拟机)系统环境,并在Tensorflow框架下实现。训练过程中,使用有限差分域方法模拟声波和弹性波形方程,并使用基于深度学习框架的自动微分方法自动计算梯度,使用Adam算法以不同的学习率来优化DNFWI。

2 实验方案

2.1 实验场地

实验在 $4\text{ m} \times 1.5\text{ m} \times 1.5\text{ m}$ 的混凝土水泥池中进行,池中埋填约8 t潮湿压实砂土,如图3(a)所示。砂土的抗震性能与城市浅层土壤、岸滩地基土相似,且砂土颗粒均匀、压实后物理性质稳定,改变掩埋物和掩埋状态时便于修复砂土扰动,可有效控制实验变量,利于获取重复性良好的实验数据,为地下输油管线探测技术的工程化应用提供可控的实验验证环境。

为了防止水泥池边的硬边界反射,影响反演效果,在水泥池四周铺上吸声泡沫作为吸声层,模拟野外环境的开放空间,如图3(b)所示。

2.2 掩埋油管

掩埋目标物为钢制油管,尺寸为接头直径16 cm,管径10 cm,管长45 cm,如图4所示。




图3 实验场地
Fig.3 Experimental site



图4 掩埋物模型
Fig.4 Model of buried objects

2.3 实验设备

实验设备布置如图5所示,输入信号由鼎阳SDG7000A系列任意波形发生器产生并输出到功率放大器,采用江苏东华测试公司的激振器和DH5922D动态信号测试分析系统。其中,功率放大器专为激振器设计,激振器为惯性电磁激振器,最大激振力50N,频率范围10 Hz~2.5 kHz,激振器,频率范围DC~40 kHz。检波器为6个三轴压电式加速度传感器,灵敏度为50 mV·s²/m,采用四芯插座输出,量程100 g、频响2~10 000 Hz,采样频率设置为20 kHz。实时采集检波器接收信号与激振器激振信号。

2.4 实验过程


图6为电动激振器震源。为改善激振器与地面的耦合效果,针对浅层地震尺度的特点,设计了水平剪切波源和垂直源2种激振平台,如图7所示,激振器顶杆通过平台激励地面产生地震波。

实验使用6个三向加速度传感器,其中1个通道用于记录激振器震源的参考信号。传感器测线位于掩埋物中心的正上方,测量间距为0.4 m,总测线长为2 m。测量间距小于最短波长的1/2(约1.1 m),满足奈奎斯特采样定律的空间域采样要求,避免出现空间混叠。激励信号选择频率为50~1200 Hz的线性啁啾信号,如图8所示,通过任意波形发生器,对激振器功放输出加速度啁啾信号,持续时间为1 s,并在1个记录周期内重复10次。

实验中,声源置于地表坐标(0,0)处,如图9所



(a) 实验设备



(b) 实验设备系统框图

图5 实验设备及连接

Fig.5 Experimental equipment and connection





图6 电动激振器

Fig.6 Electric exciter




(a) 垂直式

(b) 水平式

图7 激发平台

Fig.7 Platform of elicitation



(a) 震源子波

(b) 震源子波频谱

图8 震源波形图像

Fig.8 Image of source waveform

示,目标掩埋物几何中心位置为(0.5 m, -0.6 m),并设置不同深度变化(-0.2 m, -0.4 m, -0.6 m,

-0.8 m, -1.0 m), 记录不同点位的加速度时程曲线。采样频率为 40 kHz, 约为输入信号频率上限的 33.2 倍, 在时域中实现精细分辨率。




图9 声源激振现场

Fig.9 Scene of sound sources excitation

3 信号分析

3.1 掩埋物传感器传递函数

掩埋物表面设置 1 个加速度传感器, 通过信号放大器输出到数据采集器, 激振器及平台位于加速度传感器位置上方, 激励波形为 50~2 000 Hz 的线性加速度啁啾信号, 采用水平式激振平台的传递函数如图 10 所示。




图10 水平式传递函数

Fig.10 Horizontal transfer function

在 50~800 Hz 的频率范围内, 每倍频程有大约 4 dB 的衰减。最显著偏差发生在 200 Hz 处, 其中衰减峰值高于一般趋势 10 dB, 因局部不均匀性造成。仅考虑最低频率, 作为深度函数的衰减约 20~25 dB/m。

采用垂直式激振平台的传递函数如图 11 所示, 随着频率增加衰减更接近理想值。衰减估计值为每倍频程 5 dB, 与水平式相比在所有频率下的总衰减仍然较小, 考虑最低频率作为深度函数的衰减约 10~20 dB/m。

3.2 地面特性的表面测量

为测量波沿地面传播衰减, 使用间隔 0.4 m 的检波器测线, 震源位于距离测线末端 0.4 m 的位置。

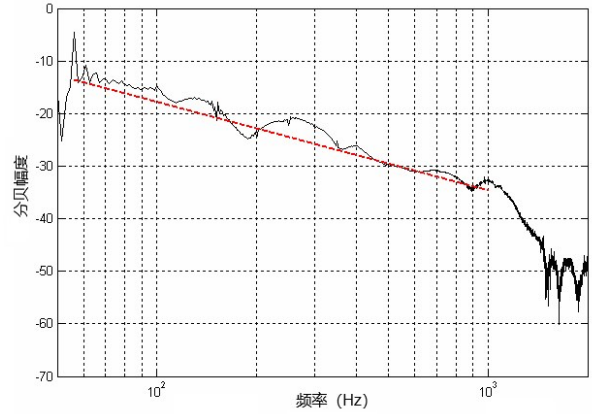


图11 垂直式传递函数

Fig.11 Vertical transfer function

激励信号为 50~1 000 Hz 的啁啾信号, 采用每个检波器输出的均方根值来评估衰减水平。如图 12 所示, 作为距离及其平均值函数的速度 RMS 值曲线图, 速度衰减约为 11 dB/m。最后两个检波器的均方根速度水平相似, 信号从约 1.75 m 处降到噪声下限以下。




图12 速度RMS值

Fig.12 RMS value of velocity

3.3 地面波速测量

为获取波速测量值, 设计了如图 13 所示的实验, 实验设置两条测线, 分别与激励轴平行和垂直, 每条测线上布置 3 个检波器, 6 个检波器处于同一水平面, 并平行于激励轴, 以 0.5 m 等间距分布。在 50~1 000 Hz 范围内使用三阶切比雪夫滤波器^[18], 信号通过滤波器反转后, 再次通过滤波器, 采用相干相减法抵消滤波器的相位失真, 使滤波器的有效阶数加倍。

采用互相关函数^[19]和频域窗口最大限度地减少高频电噪声的影响, 互相关函数最大值为对应两个检波器间的信号延迟, 测量结果如表 2 所示。两条测线方向的表面波速存在差异, 考虑主要原因是压缩方向传播速度大于剪切方向传播速度。




图 13 波速测量实验设置

Fig.13 Experimental setup of wave speed measurement

3.4 地表信号时程曲线及功率谱图

布置间距 0.5 m,测线总长 2.5 m 的 6 个检波器,采用 50~2 000 Hz 线性啁啾信号作为激励信号,采样频率设为 40 kHz。为便于成像,没有将滤波器扩展到输入频率上限,在 50~1 200 Hz 范围内进行了三阶 IIR 切比雪夫滤波,对各信道数据进行切比雪夫滤波、32 点平滑等信号处理。图 14 为掩埋钢管的加速度时程曲线,时程曲线从上到下分别对应检波器 1、4、5、6、2、3。试验刚开始时,试验人员误触

表 2 使用互相关方法测量沿地面的波速

Table 2 Wave speed along the ground measured by the cross correlation method

检波器	波速估计/(m/s)
1 与 2	85
1 与 3	87
2 与 3	83
平均值	75
标准差	1.6
4 与 5	92
4 与 6	91
5 与 6	99
平均值	93
标准差	3.6

检波器 1、4 的接线,导致曲线 1、4 的初期数据出现较大振幅。为避免误触对试验的干扰,在后续数据分析处理时,只使用了 14.941 s 往后的时程曲线。

钢材的密度和弹性模量均较高,波传播衰减小,输油钢管的加速度时程曲线具有较大振幅。钢与砂土的声阻抗差异极大,曲线中呈现出较为尖锐的反射,反射波能量强烈且易于识别。




图 14 输油钢管的时域加速时程曲线

Fig.14 Time-domain acceleration time history curves of oil pipeline

功率谱图是加速度时程曲线在频域上表示信号中不同频率成分的强度分布,不同材质的掩埋物会对地震波的不同频率成分产生不同的衰减或增强作用,从而在功率谱图上形成独特的频率响应特

征。图 15 为输油钢管的地表传感器功率谱曲线,可以看出,输油钢管的功率谱图呈现出较高的频率成分,信号保持了激振源的原始频率特性。功率谱中有明显的高频峰值,对应于输油钢管的固有振动频

率或共振频率。




图 15 输油钢管的功率谱曲线

Fig.15 Power spectral curves of oil pipeline

4 DNFWI 成像分析

4.1 两种声源成像分析

图 16 为两种不同声源对直径 28 cm、高度 7 cm 的掩埋物激振获得的反演图像,掩埋物的位置在反演图像中清晰可见,其中,采用垂直源定位误差为 0.15 m,成像峰值信噪比为 22.3,采用 SH 源定位误差为 0.08 m,成像峰值信噪比为 28.7。从图像上看,SH 波信号更强,反射信息更加丰富,反演成像后掩埋物位置更加清晰。分析两种波掩埋目标与砂土的阻抗比可知,掩埋目标与砂土 SH 波的阻抗比大于压缩波的阻抗比,因此 SH 波的反射系数也将高于压缩波,所以 SH 波的能量更强、信号更强。

4.2 输油管道成像分析

图 17 是埋深为 0.6 m 的输油钢管反演图像,钢管的位置在反演图像中清晰可见。在初次进行反演时,为了提升图像质量,排除了最靠近震源一侧的加速度传感器数据,消除被表面波污染最严重的检波器数据。虽然该方法在所示图像中取得了成功,但在其他具有类似实验设置的反演结果对比中,可见一些伪目标,在另外的情况下形成图像的抛物线有广泛的交叉点。这是反射波的高噪声水平和高表面波振幅导致采集反射波的信噪比太低,对于不同激发位置反演的多个图像合成,不一定能增强反演图像的精度。

为了提高反演精度,需要对多次反演产生的速度模型进行叠加得到反演图像的最大值。在所有

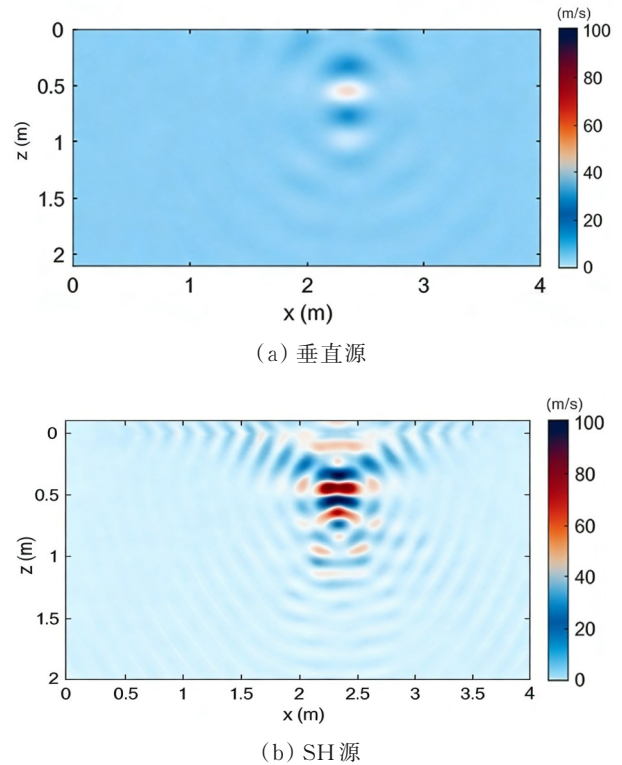


图 16 垂直源和 SH 源反演结果对比

Fig.16 Comparison of vertical and SH source inversion results

激励位置上,钢管中心更靠近激励源,可以预期具有最强反射信号。在评估 DNFWI 方法时,该方法仅在单个平面中形成横截面图像,从该测量平面外反射的能量也将被加速度传感器检测到,并在互相

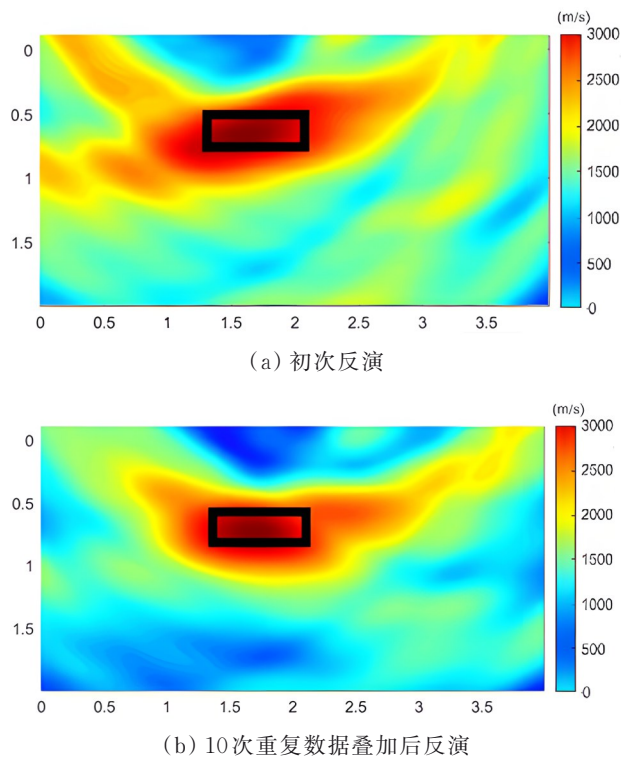


图 17 输油管线反演成像对比

Fig.17 Inversion imaging comparison of oil pipeline

关函数中具有特征,对图像质量具有不利影响。

在处理复杂边界反射时,DNFWI的稳健性主要通过预训练去噪和多数据叠加实现,DeepDenoiser通过大数据训练已学习到边界反射噪声的特征,可有效滤除该类噪声,通过10次实验数据叠加后,随机分布的边界反射噪声被平均抑制,而目标反射波能量叠加增强,伪目标的波速峰值减低,基本消除伪目标干扰。

采用相同的试验数据和建模参数,对比传统FWI与DNFWI两种方法的计算结果,如表3所示。结果表明,相较于传统FWI方法,DNFWI方法的总体定位误差提升66.7%,收敛迭代次数减少59.7%,计算时间减少60.8%,验证了DNFWI方法的有效性。

表 3 传统FWI方法与DNFWI方法的计算结果对比

Table 3 Comparison of calculation results between traditional FWI method and DNFWI method

方法	总体定位误差/m	收敛迭代次数	计算时间/s
FWI	0.21	298	681
DNFWI	0.07	120	267

5 结论

采用SH波与垂直源2种激振方式开展砂层掩埋钢制油管探测试验,通过基于大数据深度学习的全波形反演方法开展输油管线反演成像研究,得出

主要结论如下:

1)在浅层砂土中,水平式激振的深度衰减率约为20~25 dB/m,垂直式激振的深度衰减率约为10~20 dB/m,表面波的空间衰减率约为11 dB/m,掩埋钢质油管的地表加速度时程曲线峰值振幅远高于背景砂土,功率谱图300~600 Hz频段出现显著共振峰,可作为钢制油管的特征指标。

2)在浅层砂土中掩埋钢制油管探测试验中,采用SH源的成像效果优于垂直源。垂直源反演的掩埋物速度峰值与环境背景差距不大,而SH波反演因其与钢制油管剪切波阻抗差异更大,反射信号更强,反演成像后掩埋物的位置更加清晰。

3)相较于传统FWI方法,DNFWI方法总体定位误差提升66.7%,收敛迭代次数减少59.7%,计算时间减少60.8%,DNFWI方法较传统FWI方法有较大提升,为DNFWI方法的应用提供了较好的试验参考。

参考文献

- [1] 陈思静, 胡祥云, 彭荣华. 城市地下管线探测研究进展与发展趋势[J]. 地球物理学进展, 2021, 36(3): 1236-1247.
Chen S J, Hu X Y, Peng R H. Review of urban underground pipeline detection [J]. Progress in Geophysics, 2021, 36(3): 1236-1247. (in Chinese)
- [2] 刘颖, 郭立新. 地下埋藏目标与分层粗糙面复合散射探地雷达回波特性研究[J]. 电波科学学报, 2019, 34(1): 111-118.
Liu Y, Guo L X. Echo characteristics of GPR detecting of multiple buried targets and layered rough interface [J]. Chinese Journal of Radio Science, 2019, 34(1): 111-118. (in Chinese)
- [3] 赵丹丹, 杜坚, 郭智勇, 等. 埋地平行铁质管线磁异常模拟与探测识别[J]. 地下空间与工程学报, 2020, 16(3): 891-896, 932.
Zhao D D, Du J, Guo Z Y, et al. Magnetic anomaly simulation and detection for buried parallel pipelines [J]. Chinese Journal of Underground Space and Engineering, 2020, 16(3): 891-896, 932. (in Chinese)
- [4] 彭建, 杨泽帆, 白洁, 等. 基于探地雷达的地下管线埋深估计方法[J]. 雷达科学与技术, 2022, 20(1): 79-86.
Peng J, Yang Z F, Bai J, et al. Depth estimation of underground pipeline using ground penetrating radar [J]. Radar Science and Technology, 2022, 20(1): 79-86. (in Chinese)
- [5] 刘恩斌, 温耀荣, 郭冰燕, 等. 基于声信号特征分析的燃气管道探测识别方法[J]. 中国安全生产科学技术, 2022, 18(4): 61-68.
Liu E B, Wen Z R, Guo B Y, et al. Detection and

- recognition methods of gas pipelines based on acoustic signal feature analysis [J]. *Journal of Safety Science and Technology*, 2022, 18(4): 61-68. (in Chinese)
- [6] Gvishiani A D, Dobrovolsky M N, Dzeranov B V, et al. Big data in geophysics and other earth sciences [J]. *Izvestiya, Physics of the Solid Earth*, 2022, 58(1): 1226.
- [7] Saad O M, Chen Y F, Savvaidis A, et al. Unsupervised deep learning for single-channel earthquake data denoising and its applications in event detection and fully automatic location [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-10.
- [8] 陈子龙, 王海燕, 郭华, 等. 地震全波形反演研究进展与应用现状综述[J]. *物探与化探*, 2023, 47(3): 628-637. Chen Z L, Wang H Y, Guo H, et al. A review of the research progress and application status of seismic full waveform inversion [J]. *Geophysical and Geochemical Exploration*, 2023, 47(3): 628-637. (in Chinese)
- [9] Yang F S, Ma J W. FWIGAN: Full-waveform inversion via a physics-informed generative adversarial network [J]. *Journal of Geophysical Research: Solid Earth*, 2023, 128(4): e2022JB025493.
- [10] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. *Journal of Computational Physics*, 2019, 378: 686-707.
- [11] 张子龙, 潘秋景, 仇文岗, 等. 基于物理信息神经网络的盾构隧道诱发地表沉降预测[J]. *工程力学*, 2024, 41(4): 161-173. Zhang Z L, Pan Q J, Zhang W G, et al. Prediction of surface settlements induced by shield tunnelling using physics-informed neural networks [J]. *Engineering Mechanics*, 2024, 41(4): 161-173. (in Chinese)
- [12] Li J T, Wu X M, Hu Z X. Deep learning for simultaneous seismic image super-resolution and denoising [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5901611.
- [13] Ivanov T, Kumar A, Sharoukhov D, et al. DeepDenoise: A deep learning model for noise reduction in low SNR imaging conditions [C]//*Applications of Machine Learning 2020*. August 24-28, 2020. Online Only, USA. SPIE, 2020: 6.
- [14] Chen Y M, Ji D F, Ma Q, et al. A novel generative adversarial network for the removal of noise and baseline drift in seismic signals [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5904814.
- [15] Zhu W Q, Mousavi S M, Beroza G C. Seismic signal denoising and decomposition using deep neural networks [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(11): 9476-9488.
- [16] Mousavi S M, Sheng Y X, Zhu W Q, et al. STanford EArthquake dataset (STEAD): A global data set of seismic signals for AI [J]. *IEEE Access*, 2019, 7: 179464-179476.
- [17] Virieux J. P-SV wave propagation in heterogeneous media; Velocity-stress finite-difference method [J]. *Geophysics*, 1986, 51(4): 889-901.
- [18] 邹立志, 苏庆, 罗雪兰, 等. 三阶切比雪夫滤波器分析 [J]. *自动化应用*, 2019, 60(7): 59-61. Zou L Z, Su Q, Luo X L, et al. Analysis of third-order Chebyshev filter [J]. *Automation Application*, 2019, 60(7): 59-61. (in Chinese)
- [19] 黎昌成, 陈晓非. 背景噪声互相关函数多尺度成像研究 [J]. *地球物理学报*, 2023, 66(2): 546-557. Li C C, Chen X F. Multiscale imaging of ambient noise cross correlation function [J]. *Chinese Journal of Geophysics*, 2023, 66(2): 546-557. (in Chinese)

(编辑 XXX)