

基于改良U-Net卷积神经网络的复杂地质构造智能识别

王善高¹, 杨荣伟¹, 王登一^{2,3}, 马富安⁴, 彭铭^{2,3},
刘臻⁵, 石振明^{2,3}, 杨沛权⁶, 黎超尘⁶

(1. 中交佛山投资发展有限公司, 佛山 528000; 2. 同济大学地下建筑与工程系, 上海 200092;
3. 同济大学岩土及地下工程教育部重点实验室, 上海 200092; 4. 广西有色勘察设计研究院, 南宁 530031;
5. 中国科学院武汉岩土力学研究所, 武汉 430071; 6. 广东建科交通工程质量检测中心有限公司, 广州 510599)

摘要: 浅地层中的地质异常体给地下工程带来了极大安全隐患, 可能导致经济和生命损失。浅层地震法是开展施工场地勘察的一种无损高效的手段。但是地震勘探在浅地层问题中面临着信噪比低、信号衰减强、波场复杂等问题, 结果存在多解性和主观性。针对地震勘探问题, 提出了一种改良的卷积神经网络地质速度模型预测模型, 提供了一种无需初始速度模型的浅层地质模型反演方案, 形成了一套完整的浅层地震勘探信号处理处理流程。在训练样本方面, 采用了随机地质模型方法构建多种类地质模型, 并形成了地质模型-地震信号数据库。在传统U-Net卷积神经网络上进行了改良, 以更好的适应浅地层弹性波叠前信号数据的反演任务。结果表明神经网络的反演结果直观准确该模型能够精确的预测出地层分界线、褶皱、起伏、断层滑移线等的位置和大小等参数, 所采用的SSIM和PSNR两个量化评价指标均表示, 所提出的改良神经网络可以实现高精度反演。预测结果与真实模型相比较, 得到的SSIM平均值为0.91, PSNR平均值为39.0。同时该神经网络模型能够向三维问题扩展, 能够极大的提高地震信号处理的效率和解译精度。

关键词: 地震勘探; 速度模型反演; 卷积神经网络; 信号处理

中图分类号: P 642 **文献标识码:** A

Automatic Geological Structure Detection Based on Seismic Method and Improved U-Net CNN

WANG Shangao¹, YANG Rongwei¹, WANG Dengyi^{2,3}, MA Fuan⁴, PENG Ming^{2,3},

LIU Liu⁵, SHI Zhenming^{2,3}, YANG Peiquan⁶, LI Chaochen⁶

(1. CCCC Foshan Investment & Development Co. Ltd, Foshan 528000, Guangdong China;

2. Department of Geotechnical Engineering, Tongji University, Shanghai 200092, China;

3. Ministry of Education Key Laboratory of Geotechnical and Underground Engineering, Tongji university, Shanghai 200092, China;

4. Guangxi Nonferrous Survey & Design Institute, Nanning 530031, China;

5. Academy Institute of Rock and Soil Mechanics, Chinese Academy of Science, Wuhan 430071, China;

6. Guangdong Construction Engineering Quality and Safety Inspection Station Co. Ltd, Guangzhou 510599, China)

Abstract: Geological anomalies in near surface are extremely harmful to engineering. Unexplored structures may lead to construction difficulty, economic losses and even safety problems. Therefore, the investigation of the construction

收稿日期: 2023-09-15

基金项目: 国家自然科学基金(41731283, 41877234, 42071010, 42061160480); 中央高校基础研究基金(22120180538)

作者简介: 王善高(1977-), 男, 硕士, 主要从事地下工程与隧道建设管理及施工研究工作

通信作者: 王登一(1996-), 男, 硕士, 主要从事工程地球物理勘探与无损检测研究

site in near surface is a key procedure before construction. Shallow seismic method is an efficient method to carry out the investigation of the construction site. However, seismic exploration faces problems such as low signal-to-noise ratio, strong signal attenuation, and complex wave field in shallow strata, which requires a lot of human experts' resources to interpret while the results are ambiguous and subjective. Aiming at the problems of shallow seismic exploration. In this paper, an improved convolutional neural network geological velocity model prediction model is proposed for seismic exploration, which provides a shallow geological model inversion scheme. This workflow provides a complete set of near surface seismic exploration signal processing and inversion process scheme without initial velocity model. This paper uses the stochastic geological model method to construct a variety of geological models, and forms a geological model-seismic signal database. An improved U-Net convolutional neural network to better adapt to the inversion task of near surface pre-stack signal data of elastic wave. The results show that the inversion results of the neural network are intuitive and accurate. Two quantitative evaluation indicators of SSIM and PSNR indicate that the improved neural network proposed in this paper can achieve high-precision inversion. The neural network model proposed in this paper can be extended to three-dimensional application, which can greatly improve the efficiency and interpretation accuracy of seismic signal processing.

Key words: Seismic exploration; velocity model building; CNN; signal processing

目前大多数建筑和基础设施的建设都是围绕浅地层开展的,在浅地层中有大量的规模不大,规律复杂,但对工程质量和安全问题能够造成重大影响的异常体,例如溶洞、土洞的发育,断层裂隙造成的基岩不完整等问题,可能会导致快速、剧烈、频繁的地质灾害。不利的地质条件通常会导致地基承载力不足、沉降不均匀、地基滑移和塌陷等问题^[1-3]。而物探方法为探测这些异常提供了很好的途径,可以高效快速低成本的判别浅地层地中潜在问题的存在。

地震方法是利用弹性波在不同介质中的传播特征,弹性波在不同的介质中传播速度不同,且在不同介质的分界面会产生反射以及折射,地震方法利用这些性质在人工震源激发后的对地表或孔中接收到的信号进行分析,以求取地下介质结构特征、介质特征等,地震方法又根据不同的收发形式、利用不同的信号成分、分析不同组分的波的传播,分为若干种方法。地震勘探经历了长时间的研究和充分的实践利用,现已经有部分学者和工程师将油气勘探的理论迁移到工程地质中来,其中有学者就针对浅地层的地震勘探法做出了研究,主要以地下空洞缺陷、岩溶洞室为目标,总结了以地震反射法、地质雷达法、跨孔CT等方法为主的浅地层地震勘探方法^[4-6]。Cook^[7]利用地震反射振幅分析方法探测地下空洞的存在。Steeple等^[8]利用地震反射法探测出了地下盐体(Salt Body)的沉降特征。浅层地震法以地下介质间的波阻抗差异为前提,利用反射波的强度、频谱、相位、波长和旅行时等信息探测桩位溶洞^[3,9]。浅层地震反射波法作为大尺度的工程物探方法,是钻探施工的先行手段。浅层地震法应用效果的好坏通常取决于炮间距、震源频率、频带宽度等因素^[10]。一般情况下用高频、宽频带的震源,小道间距和炮检距接收,有助于提高地震勘探的分辨率。

深度学习方法近年来在地震勘探领域盛行^[11-12]。由于真实地质模型难以获取,通常只能通过钻孔管中窥豹,许多勘探数据是难以获得真实的地下介质信息来验证的。而机器学习方法研究亟需数量大且可验证的数据。在图像识别领域,研究者们常共用标准的数据来进行训练、测试以及评估各新模型的表现。在地球物理研究中,学者们常用标准的数值模型来验证各种新理论方法的可行性。基于标准模型,利用数学物理方程进行数值模拟。这样的标准数值模型在验证偏移成像技术、反演策略等领域获得了较好的效果,通过标准模型,研究者可以直观且量化的评估各种地球物理技术手段。但在机器学习研究中,单个或几个标准模型难以满足神经网络训练、测试、验证的需求。因此,一种能够产生大量数值模型且保证数值模型丰富程度的方法需要被提出。近年来,一些面向机器学习问题的随机地质模型生成方法被提出,例如利用隐式模型进行建模的方法DeepSMNet^[13]可以实现通过控制产状的关键参数建立地质模型,并且利用关键参数的演化来模拟地质构造变化的过程;Wu等^[14]利用含有褶皱、断层、盐体的模型,利用反射系数褶积生成模拟的叠后剖面,并在该剖面中进行地震事件(Seismic Events)的提取和分析。Ren等^[15]在三维情况下生成随机的地质模型,

在地质模型中加入了凸起的盐体, 并在二维的剖面下利用 SeisInvNet^[16]进行神经网络反演. 但是, 目前的研究主要集中于油气勘探尺度、声波假设、叠后剖面的情境中, 在这些假设中信号的信噪比较高, 面波干扰易于抑制, 声波假设也大大降低了波场的复杂程度, 而利用叠后剖面进行研究则更偏重于在既有的成像结果中识别地下构造, 而非利用信号进行地下介质的反演.

综上, 为了探究深度学习方法在复杂地质构造、弹性波假设、叠前地震数据集中的实用效果, 开展了以下研究. 首先, 在工程物探的尺度下, 提出了一种随机地质模型方法. 通过控制地层、起伏、断层、洞室等产状的空间分布, 并且弹性介质参数赋予上述产状中, 实现随机地质模型的建立. 利用该随机地质模型方法和弹性波地震波模拟手段, 生成了一个浅地层地震勘探叠前数据样本集, 将该样本集用于训练卷积神经网络, 并预测新信号的地质模型. 结果表明, 训练后的网络能够有效根据地震信号预测地下介质的速度模型.

1 卷积神经网络反演方法

1.1 地震反演问题

考虑弹性介质中波的传播和激发问题, 包含震源的非齐次二维弹性波方程可表示为:

$$\frac{1}{v^2} \frac{\partial^2 u(x, z, t)}{\partial t^2} = \nabla^2 u(x, z) + s(x, z, t), \quad (1)$$

其中: (x, z) 表示空间位置; t 表示时间; v 表示相应位置的纵波波速; u 表示波振幅; $s(x, z, t)$ 表示源信号, ∇^2 表示拉普拉斯算子.

等式(1)通常由下式表示:

$$u = H(v), \quad (2)$$

其中: 算子 H 表示从纵波速度 v 到信号波幅 u 的映射, 且通常为非线性映射. 经典的反演方法旨在最小化以下目标函数:

$$\hat{v} = \arg \min_v f(v) = \arg \min_v \frac{1}{2} \|H(v) - d\|_2^2, \quad (3)$$

其中: d 表示测量的地震数据; f 表示数据置信度残差.

如果 d 包含全波形信息, 则上式表示传统的全波形反演方法(Full Waveform Inversion, FWI). 由于 Hessian 矩阵的逆 H^{-1} 的非线性特性和地震波观测 d 的不完善性, 求解式(1)通常难以获得精确的解以表示地质模型. 因此, 最小化上述方程一般是一个病态问题, 解不唯一且不稳定. 同时, 采用 FWI 求解上式计算复杂度较高, 需要大量的迭代. 因此, 基于数学优化模型的反演方法存在诸多不足, 难以实现地震波数据实时反演.

1.2 深度学习地震信号反演

所采用的深度学习反演模型框架如图 1 所示. 具体而言, 首先根据实验需求生成速度模型, 再虚拟布设检测点, 通过正演算法数值仿真生成所需的地震波信号, 经过数据清洗、预处理等操作生成深度学习所接受的输入格式. 再划分训练集、测试集, 确定数据文件批量化的读写方式. 将原始速度模型作为标签, 与训练数据一同输入给 U-Net 神经网络模型进行训练, 最终网络实现对速度模型进行预测.

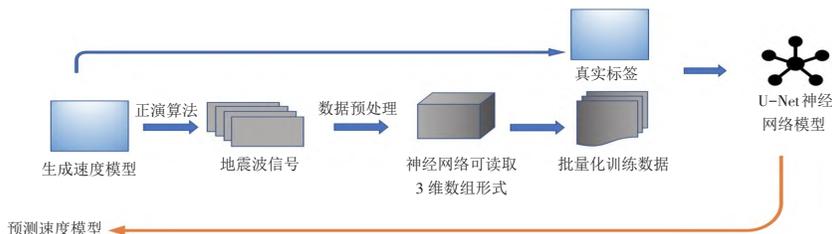


图 1 神经网络反演模型框架

Fig.1 Workflow of DNN inversion

由于目标为将地震波信号直接作为网络输入,该神经网络要实现从数据域 $D(x,t)$ 到模型域 $V(x,z)$ 的映射,即:

$$F(D; \Theta) = V. \tag{4}$$

给定输入-输出数据对,即地震波速度观测 D 和真实速度模型 V ,整个框架的流程包括训练、预测两个阶段.在训练阶段,采用数值仿真的方式人工生成地震波观测序列.具体而言,通过随机速度模型生成方法随机产生大量速度模型作为真实值,每个随机速度模型由随机种子产生相应的地层参数;再通过虚拟布设炮点、接收器,利用时域差分法求解波动方程模拟地震波的传播,即模型正演,由真实的速度模型产生地震信号观测作为训练样本(模型输入).

训练阶段网络的学习过程可由下式的优化问题表示:

$$\bar{\Theta} = \arg \min_{\Theta} \frac{1}{NM} \sum_{n=1}^N \text{Loss}(V_{(n)}, F(D_{(n)}; \Theta)), \tag{5}$$

式中: N 表示样本-输出对个数; M 表示每个图像中所有像素的个数; $\text{Loss}(\cdot)$ 表示损失函数,用来度量模型预测值与真实值(标签)之间的拟合误差,同时也是反向传播优化算法的目标函数.研究中采用的损失函数为均方误差损失(Mean Square Error, MSE)函数,即:

$$\text{MSELoss} = \frac{1}{N} \sum_{n=1}^N (\hat{y}_i - y_i)^2. \tag{6}$$

由此可见,求解此优化问题即参数 Θ 的学习.根据反向传播优化的原理,通常采用梯度下降算法对式(5)进行求解.所采用的优化算法为随机梯度下降类方法的一种:自适应动量估计法(Adaptive Moment Estimation, Adam)优化器进行求解.该算法每一轮迭代计算一个数据批量样本的梯度值进行模型更新,避免一次性读取全部样本而造成的计算资源开销过大的问题;同时,多批量的并行计算方式同样给GPU加速提供了便利.

采用Adam算法的参数更新规则由式(7)给出:

$$\Theta_{t+1} = \Theta_t - \rho \left(\frac{1}{MB} \nabla_{\Theta} \text{MSELoss}_B(V_{(n)}, F(D_{(n)}; \Theta)) \right), \tag{7}$$

式中: ρ 表示学习率,用以控制模型更新速度.

1.3 改进的U-Net神经网络架构

全卷积神经网络模型能够实现从信号到图像的映射.由于需要预测整个速度模型的全部元素,因此若将输入信号与输出速度模型均视为图像,那么需要网络能够处理并预测每个像素值.因此,借鉴计算机视觉中语义分割领域常用的网络架构,采用并改进了U-Net网络^[17].该网络为语义分割任务中常用的全卷积神经网络,能够实现像素级的预测.原始的U-Net网络结构如图2所示.

该网络包括编码器(下采样模块)和解码器(上采样模块)两部分,为对称网络结构.U-Net此特殊的结构以及跳跃连接的方式,使其能够捕提高层次和低层次的信息与特征,从而适用于进行像素级的预测任务.经过多次下采样后的低分辨率信息,能够提供分割目标在整个图像中上下文语义信息,即反映目标像素与环境之间关系的特征.此特征有助于物体的类别判断;同时,U-Net经过合并操作

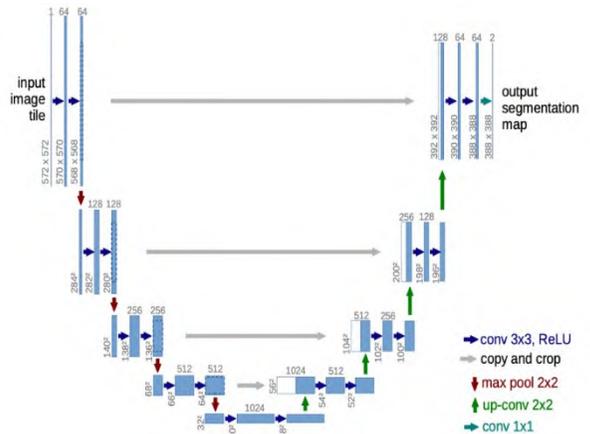


图2 经典U-Net网络架构^[17]

Fig.2 A classic U-Net convolutional network

从编码器直接传递到同高度解码器上的高分辨率信息, 能够为分割提供更加精细的特征, 如梯度等。

在信号域到模型域的映射任务中, 通过下采样模块将三维信号中潜在的高维度特征进行编码并聚合, 再通过上采样模块将特征映射到二维速度模型, 最终计算每个像素的预测值损失。在下采样模块, 通过一系列卷积核大小为 3 的卷积操作和最大池化操作对输入图像进行特征提取, 并使其高、宽减半, 通道数加倍, 高维度特征被储存在通道维度中。相应的, 在解码器模块, 一系列转置卷积(即卷积的转置运算符)进行上采样, 并聚合不同通道的特征映射图。

所采用的改进的 U-Net 网络架构如图 3 所示, 图中数字表示特征映射通道数。

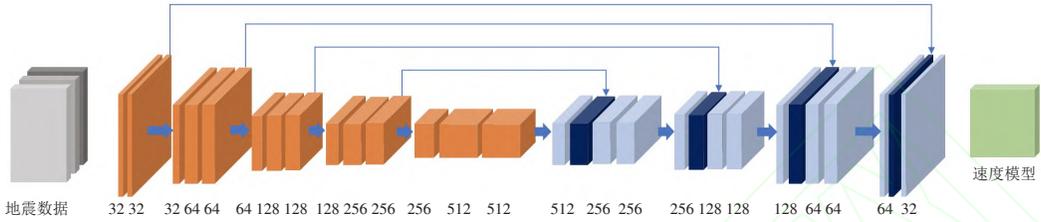


图 3 改进的 U-Net 网络架构

Fig.3 Improved U-Net structure

对原始的 U-Net 进行了三个方面的改进: 第一, 由于原始的 U-Net 在计算机视觉领域被用作处理 RGB 或灰度图像的分割任务, 其原始的输入、输出设计不适用于地震反演任务。至此, 将输入地震信号以 3 维张量 (Tensor) 的形式存储, 其形状为: 时间×位置×炮数, 将通道维度转变为不同的信号炮数, 从而在增加数据冗余性的同时能够联合利用所有的检测数据。第二, 由于模型的最终输出为速度场, 其形状为高×宽的 2 维图像, 而神经网络中间层的输出为 3 维的特征映射图(第 3 维为通道维度), 因此在网络的最后一次添加了卷积核大小为 1 的卷积层进行通道聚合, 即将 32 维的特征图融合到 1 维, 并经过大小裁剪后产生最终的输出。第三, 由于原始的 U-Net 网络参数量较大, 尤其表现在通道数上较多, 而对于地震数据而言过于高的模型复杂度易造成模型过拟合, 因此在该实验中将 U-Net 网络的超参数进行修改, 对应的通道维度数分别改为原始的一半, 即 [32, 64, 128, 256, 512]。

通过生成随机速度模型作为真实值(标签), 交替网格有限差分法求解声波方程模拟地震波正演, 以获得训练与测试数据集。采用改进的 U-Net 神经网络架构, Adam 优化器和批量归一化等方法加速神经网络参数学习和收敛过程。最终即可实现由多炮原始地震波观测信号向纵波速度模型的映射, 再在其基础上对新的速度模型进行预训练-微调的迁移学习, 即可在较少的样本量下获得较好的模型泛化能力(领域适应能力)。

2 数据准备工作

2.1 随机地质模型生成

数值模型建立对于弹性波的数值模拟来说, 就是在模拟波传播的区域内, 给出物质的各物理参数在空间上的分布。对于弹性波数值模拟来说, 主要的五个参数有: 纵波速度 v_p 、横波速度 v_s 、密度 ρ 、拉美常数 μ 和 λ , 并且他们其中存在关系:

$$v_p = \sqrt{\frac{\lambda + 2\mu}{\rho}}, \quad v_s = \sqrt{\frac{\mu}{\rho}}, \quad (8)$$

即需要已知五个参数中的三个, 就可以求出剩下两个参数。因此在数值模型中控制纵波速度 v_p 、横波速度 v_s 、密度 ρ , 然后计算拉美常数。

如图 4 所示, 在本章节中, 将从水平地层开始, 在地质模型中逐渐加入褶皱、起伏和断层, 以实现随机地质模型库的生成。并以这些地质模型进行有限差分弹性波模拟获取地震信号数据。

随机地质模型能够在数值空间中模拟层状地层结构, 并在层状地层的基础上加入地层起伏褶皱和断层等产状。并且能对每个地层(区域)进行物理参数的赋值, 能够实现地质模型的灵活构建, 从而保证了数据样



图4 地质模型生成流程示意图

Fig.4 Geological model generating workflow

本的丰富度. 与真实地层相比, 随机地质模型在地层几何形状上能有较好的模拟效果, 但在现实地震勘探中, 地表往往不具备水平布设接收器阵列的条件, 这也是该地质模型和真实地震数据采集的主要差别之一. 随机地质模型对地面情况进行一定的简化, 但在地质构造、参数选取和波场传播上都进行了合理设置.

2.2 地质模型库生成

利用前一节的随机模型生成方法, 建立了一个20 m深, 30 m宽的随机地质模型区域, 可以得出一个3地层, 1洞室的模型的空间分布, 可以由13个参数控制(如表1所示), 根据各参数的定义给出了其取值范围, 为了不生成极端的模型, 确保数值模拟的稳定, 采取了较为保守的取值范围, 比如将地层层数固定且地层分界面的深度控制在一定范围以保证地层不会相互交叉.

地层由两个参数控制, 其中界面1深度和界面2深度控制了二个地层分界面的深度, 设置了二个参数的取值范围来保证使界面1的深度总小于界面2, 且地层厚度不会过于极端. 褶皱由类型、褶皱纵深、左右位置和褶皱宽度四个参数定义, 褶皱类型是一个分类参数, 0表示无褶皱, 1表示向斜, 2表示背斜褶皱, 这个参数决定了褶皱纵深的正负, 褶皱纵深控制了褶皱下凹或上浮的纵深大小, 左右位置控制了褶皱峰值的横向水平位置, 褶皱宽度参数控制了褶皱的陡峭程度, 此参数并非一个实际尺寸参数, 该参数越小, 褶皱起伏就越平缓, 该参数越大, 褶皱起伏程度越大. 地层起伏由浮动大小、起伏剧烈程度和地层平行定义, 其中起伏剧烈程度分为完全无起伏(0)、轻微起伏(1)和剧烈起伏(2), 地层平行参数分为底层完全平行(0)和地层分界面之间互有差异(1)如图5所示.

表1 地质模型随机参数表

Tab.1 Stochastic parameters in the geological models

参数	控制对象	取值范围	备注	
1	地层	界面深度1	3~8 m	
2		界面深度2	12~17 m	
3	褶皱	褶皱类型	0, 1, 2	分类参数
4		褶皱纵深	0~2 m	
5		左右位置	10~20 m	
6		褶皱宽度	5~10	非实际尺寸
7	地层起伏	浮动大小	0~4 m	
8		起伏剧烈程度	0, 1, 2	分类参数
9		地层平行	0, 1	分类参数
10	断层	断层类型	0, 1, 2	分类参数
11		滑移线斜率	1~2	
12		参考点水平位置	12~18 m	
13		水平断距	1~2 m	

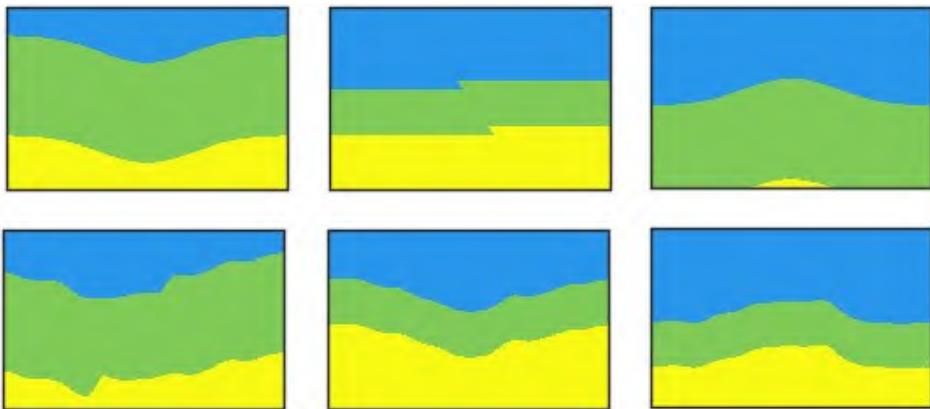


图5 随机模型生产结果

Fig.5 Example of random generalized geological models

断层由断层类型、滑移线斜率、参考点水平位置和水平断距控制, 其中断层类型分为无断层、正断层和逆断层, 滑移线斜率绝对值的取值范围为 1~2 m, 并且根据断层类型来取正值或负值, 固定参考点的深度, 随机选取其在水平上的位置. 水平断距绝对值为 1~2 m, 并且根据断层类型和滑移线的斜率决定其正负值.

由 13 个参数控制的随机模型, 若 9 个连续值参数有 10 个值可选择 (实际远大于 10 个值), 配合上 5 个分类参数, 则至少可以得到 $10^9 \times 3 \times 3 \times 2 \times 3 \times 4 = 2.26 \times 10^{11}$ 个模型.

2.3 有限差分数值模拟方法

为了验证该随机地质模型方法能够产生稳定、丰富的地质模型, 采用数值方法求解弹性波方程^[18], 并通过布设虚拟激发点和接收点获得模拟的地震信号. 虚拟激发点与接收点的布置参照实际物探工作的布设方法, 认为接收点与激发点几乎在同一水平面上. 文本的实验建立了一个宽为 30 m, 深度为 20 m 的二维区域, 上下各设置 8 m 的 PML 的吸收边界 (图 6 和图 7), 左右也各有 8 m 的 PML 吸收边界. 模型中实际用于波传播的区域尺寸为 20 m × 30 m, 该模型用于模拟浅部地层的勘探. 激发点位于埋深为 1 m 的水平位置, 接收器排列埋深 1.1 m, 共设置 151 个接收器以 0.2 m 的间隔均匀排列.

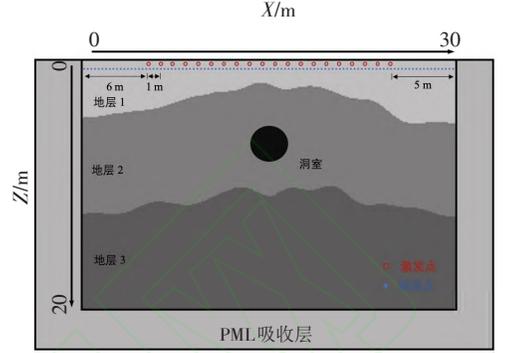


图 6 地层速度模型实例

Fig.6 Geological model example

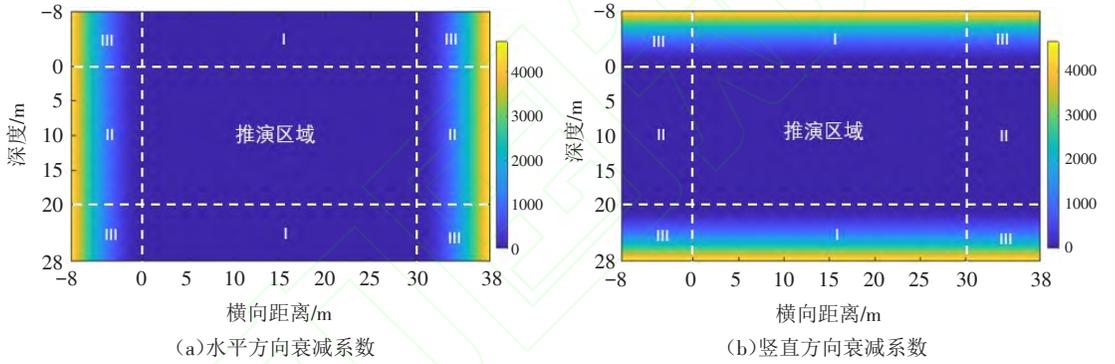


图 7 PML 衰减系数空间分布

Fig.7 PML boundary horizontal attenuation vertical attenuation

模拟信号由时域有限差分数值模拟方法进行地震波的传播与模拟得到, 震源采用雷克子波, 震源频率为 600 Hz, 接收时长 0.05 s. 本实验所采用的是速度-应力弹性波方程交错网格高阶差分解法 (时间采用 2 阶差分, 空间 10 阶差分交错网格). 波动方程为:

$$\begin{aligned}
 \rho \frac{\partial v_x}{\partial t} &= \frac{\partial \sigma_{xx}}{\partial x} + \frac{\partial \sigma_{xz}}{\partial z}, \\
 \rho \frac{\partial v_z}{\partial t} &= \frac{\partial \sigma_{xz}}{\partial x} + \frac{\partial \sigma_{zz}}{\partial z}, \\
 \frac{\partial \sigma_{xx}}{\partial t} &= c_{11} \frac{\partial v_x}{\partial x} + c_{13} \frac{\partial v_z}{\partial z}, \\
 \frac{\partial \sigma_{zz}}{\partial t} &= c_{13} \frac{\partial v_x}{\partial x} + c_{33} \frac{\partial v_z}{\partial z}, \\
 \frac{\partial \sigma_{xz}}{\partial t} &= c_{44} \frac{\partial v_x}{\partial z} + c_{44} \frac{\partial v_z}{\partial x}.
 \end{aligned} \tag{9}$$

其中: v_i 为速度分量; σ_{ij} 为应力; ρ 为密度; c_{ij} 为介质的弹性常数. 在各向同性的情况下, $c_{11} = c_{33} = \lambda + 2\mu$, $c_{13} = \lambda$, $c_{44} = \mu$, λ 和 μ 为介质拉美常数. 波传播模拟过程如图 8 所示.

2.4 数据集划分

经过随机地质模型与数值仿真实验(速度模型生成与地震波正演),可以获取较为多样的地震波——速度模型数据集.共生成1000个速度模型与相应的地震波信号,其中800个样本作为训练集训练神经网络模型,200个用作测试集进行预测验证.测试集中的样本均未在训练集中包含,并且测试集真实速度模型在预测阶段是未知的,仅用于对比预测值与真实值.

3 基于卷积神经网络的速度模型反演

为了验证该随机模型生成方法能够适应地震勘探深度学习研究的要求,将对应的信号作为输入,地质模型作为输出进行训练,训练后的网络应具有根据地震信号预测地下介质模型的非线性跨纬度转换能力.预测部分采用的深度神经网络为U-Net卷积神经网络,该网络已被证实是一个能够根据地震信号准确预测地下介质速度的模型^[19].更进一步地,采用弹性波(而非声波)方程进行模拟,更进一步的接近真实信号的形式,可以认为是一种迁移学习.本章介绍了数据集的组织、神经网络训练的参数设置,讨论预测模型在训练集与测试集中的表现,并且定性和定量的评价了模型预测的结果.

3.1 机器学习方法

3.1.1 批量化数据集读取与存储

一方面,由于完整的数据集规模较大(约3 GB),一次性读取需要占用较大的内存,而深度卷积神经网络的训练开销较大,需要在GPU上进行并行加速,因此需要考虑GPU显存的分配与限度;另一方面,由于随机梯度下降算法需要计算样本的梯度值,若一次性计算全部样本的梯度值不仅造成计算开销过大的问题,还可能会导致梯度更新方向不稳定等数值问题.因此通常采用的解决方案为小批量(Mini-batch)随机梯度下降,即每次迭代读取并计算一小部分样本的梯度值进行模型更新,每一轮读取不同的批量,使得最终能够遍历整个数据集.

目前主流的深度学习框架Pytorch被用以进行神经网络的搭建、数据的读取保存,以及模型的训练.对于数据文件的存储,首先在本地目录下分别建立训练集、测试集文件目录,存放训练与测试样本,排序方式采用数值仿真程序的生成顺序命名并排列.在训练阶段,通过编写训练集迭代器,采用大小为5个样本的批量读取训练数据,生成训练数据迭代器.该迭代器用于循环返回一个批量的训练样本,用于数据的输入.在训练阶段,读取后对训练数据的排列

顺序做随机打乱,以增加随机性避免其他因素的干扰.再把每个样本批量的数据转移到GPU显存,Pytorch框架将会自动调用CUDA(高性能GPU并行计算框架)进行并行计算加速,如图9所示.

在测试阶段,同样通过编写测试集数据迭代次批量化读取测试数据文件,但此时不对样本的顺序进行打乱,只对输入数据进行向前传播,计算与真实值之间的误差.一旦神经网络训练结束,进入测试模式后,网络参数便不再更新,测试集正向传播(即预测)的速度较快.

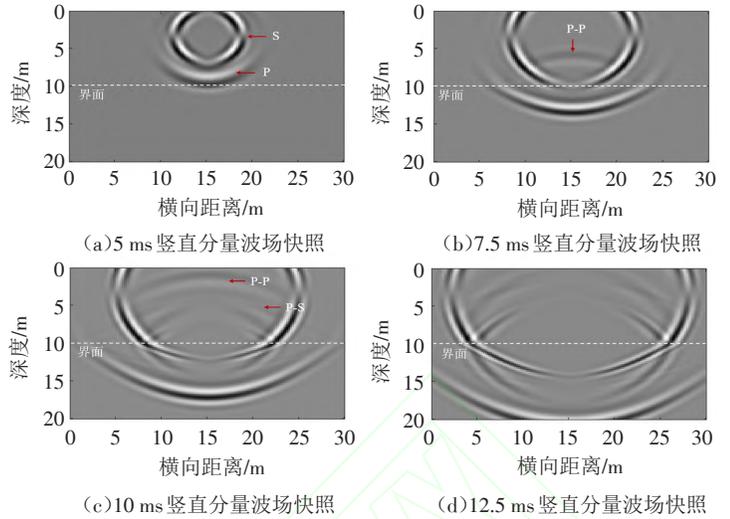


图8 波传播过程中的波场快照

Fig.8 Snapshot in wave propagation

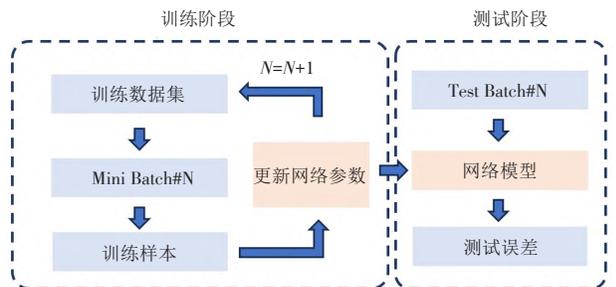


图9 批量化数据训练与测试流程示意图

Fig.9 Mini-batch sized training and test workflow

此外, 由于接收器维度为 151, 而速度模型的宽度网格数为 300 个, 首先对地震信号的时间维度和速度模型的宽度维度进行下采样, 使得地震信号的尺寸缩放到 $20 \times 500 \times 151$, 速度模型的尺寸缩放到 200×151 . 注意, 这里对输入-输出数据作下采样操作. 测试集同样需要做相同比例的下采样.

最终, 每个批量的输入样本尺寸为: 批量数 \times 输入通道数 \times 时间 \times 位置, 即 $5 \times 20 \times 500 \times 151$.

输出样本, 即速度模型的尺寸为: 批量数 \times 输出通道数 \times 深度 \times 宽度, 即 $5 \times 1 \times 200 \times 151$.

3.1.2 评价指标

模型评价主要是指对训练结果好坏的评价, 通过对比预测值与真实值的差距来反映模型拟合效果. 除了通常所采用的误差指标(如均方误差)外, 采用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)以及结构相似性(Structure Similarity Index Measure, SSIM)两个通常用作衡量图像质量的评价指标^[20]. 采用这两个指标的直接作用在于能够衡量两个图像结构与分布之间的信息相似性, 而不仅仅比较整体像素值之间的误差(如 MSE).

灰度图像的 PSNR 的定义为:

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\text{MAX}_I^2}{\text{MSE}} \right), \quad (10)$$

其中: MSE 表示均方误差; MAX_I 表示图片可能的最大像素值, 若每个像素都由 8 位二进制来表示, 那么就为 255. 对于 RGB 图像, 即速度场图, 计算方式为将图片转化为 YCbCr 格式, 然后只计算 Y 分量即亮度分量的 PSNR 值. PSNR 越大, 表示图像失真越少, 预测结果越好.

SSIM 的定义为:

$$\text{SSIM} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (11)$$

其中: μ_x 为 x 的均值; μ_y 为 y 的均值; σ_x^2 为 x 的方差; σ_y^2 为 y 的方差; σ_{xy} 为 x, y 的协方差. c_1 与 c_2 为常数, 避免除零. $c_1 = (k_1L)^2, c_2 = (k_2L)^2, L$ 是像素值的动态范围, $k_1 = 0.01, k_2 = 0.03$.

每次计算时从图片上取一个大小为 $N \times N$ 的窗口, 然后不断滑动窗口进行计算, 最后取平均值作为全局的 SSIM. 结构相似性的范围为 -1 到 1. 当两张图像完全相同时, SSIM 的值等于 1.

3.1.3 超参数设置

神经网络的超参数(Hyper-parameter)是指无法通过从数据中学习的, 需要根据经验和先验知识人工设置的参数, 且这些参数的选取对模型最终的效果有较大的影响. 超参数主要包括优化器、学习率、损失函数、卷积核参数、迭代次数、批量大小等. 损失函数选择为均方误差损失(Mean Square Error, MSE), 优化器选择 Adam, 卷积核采用 U-Net 默认的 3×3 卷积以及步幅为 1, 填充为 1. 具体超参数见表 2.

表 2 神经网络训练超参数

Tab.2 Hyper-parameters used in training

编号	参数名称	取值
1	学习率	$1e-3$
2	批量大小	5
3	迭代轮数	80
4	训练数据大小	450
5	是否进行批量归一化	是
6	优化器	Adam
7	损失函数	MSEloss

3.2 卷积神经网络训练与预测结果

3.2.1 模型训练与超参数调整

模型训练阶段共迭代 80 个轮次, 每个轮次通过数据迭代器遍历所有数据样本, 共进行 10 000 次循环. 每 20 个轮次保存一次模型文件, 每两个迭代轮次输出一组训练集的损失值, 以监控模型训练过程中的性能表现. 注意, 在实验的训练阶段监测训练集损失的变化情况, 测试集误差仅在测试阶段查看并检验.

超参数调整主要用于调整表 5 中的参数使得模型在训练过程中表现较好. 实验调整的超参数主要为学习率以及是否进行批量归一化. 学习率影响模型每次更新的幅度, 较大的学习率可以加速收敛、跳出局部

最优解;但过大的学习率会导致模型训练震荡、损失函数下降困难等问题。同时,学习率的选取与批量大小也紧密相关。较小的批量大小应当选择较大的学习率;反之,批量较大时,应选择较小的学习率以保证数值稳定性。因此,适当的学习率是模型良好训练的基础。经过实验验证,所选取的最优学习率为 $1e-3$ 。

批量归一化层在加速神经网络收敛方面有良好的表现,经实验发现,使用批量归一化层能够节省近一半的迭代轮次,因此所有的实验均采用批量归一化。训练过程的损失函数下降情况见图10所示。

由图10可以发现,神经网络在训练集上学习的效果较好,整体波动较小,在迭代30个轮次左右便基本收敛。因此,在迁移学习实验时可适当减少训练迭代轮次,以节省计算开销。

在GPU上的训练时间总共为80 min。最终在训练集上的损失函数值为 $MSE=326$,即训练集均方误差,在可接受范围内。较为平滑的曲线说明所采用的U-NET模型对于此任务具有较好的表示能力,能够较为准确地捕捉到地震信号到速度模型之间隐含的非线性映射关系;此外,损失函数的下降情况也与所采用的超参数组合策略有关系,进一步验证了所选用超参数(如学习率、优化器)的合理性。

3.2.2 测试集模型验证

在测试集进行模型效果验证,而不是在训练集的目的是检验模型的泛化能力,避免模型过拟合。测试集仅需要将测试集输入数据在网络中进行正向传播,预测速度较快,为3 s左右,能够实现实时反演,这也是深度学习模型的优势所在。一旦训练完成,便可以部署于实际应用中。

测试集的效果检验主要包括定性对比预测值与真实值的速度图像和度量指标的定量比较。图11为背斜断层模型的识别结果,对比真实模型(图11(a)),预测结果(图11(b))在纵波速度的预测上基本吻合真实地层。从结构上来说,预测结果中可以准确地识别模型中存在的三个地层与断层的存在,且断层的基本形态与错断位置基本符合,从预测结果中可以看出该处存在一个上盘(左侧)下沉的断层。但地层边缘的形态存在一定的扭曲与模糊。

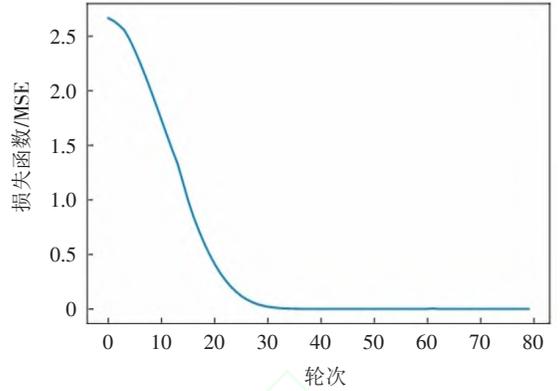


图10 训练损失函数下降曲线

Fig.10 Loss curve in training processing

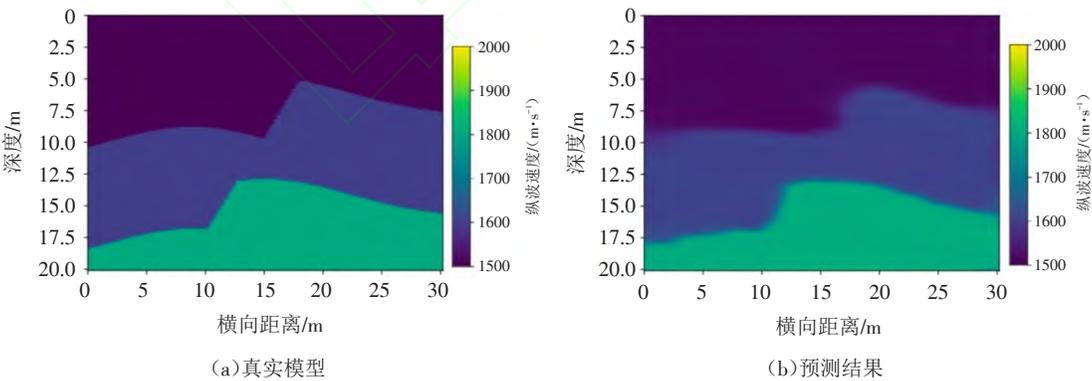


图11 背斜断层模型预测结果

Fig.11 A typical prediction result of anticline-fault model

图12为一个逆冲断层的模型(图12(a)),模型中有三个地层,从浅至深波速依次上升。在模型的中部存在一个断层,其右部的上盘相对上升。在预测结果中(图12(b)),网络输出的地质模型在速度上基本吻合真实模型的速度。从结构上来说,网络预测的模型中也可看出该区域存在一个上盘相对上升的逆断层,其沿断层面滑动的距离也基本预测准确,但在局部地层尖灭位置,形状还原不够准确,较真实模型更加模糊。

从上图的预测结果与真实值的对比可知,模型预测结果具有较高的精度,能够很好的预测出各个地层

的边界线. 其中断层线的位置、断层滑距预测的结果也与真实值较为接近. 对于平行/近于平行地层, 模型的预测效果最佳. 模型的主要误差基本存在于边界细微处像素点预测误差, 以及最大速度地层的速度数值预测误差. 总体而言, 模型的精度较高, 能够满足实际工程应用中对于精准速度模型反演的要求. 由于输入的激发点数(即炮数)20并不能完全包含全部的信息, 因此预测出的地层边界线与真实值相比相对模糊. 为进一步量化模型的预测效果, 计算测试集中的每一个模型的 SSIM 与 PSNR.

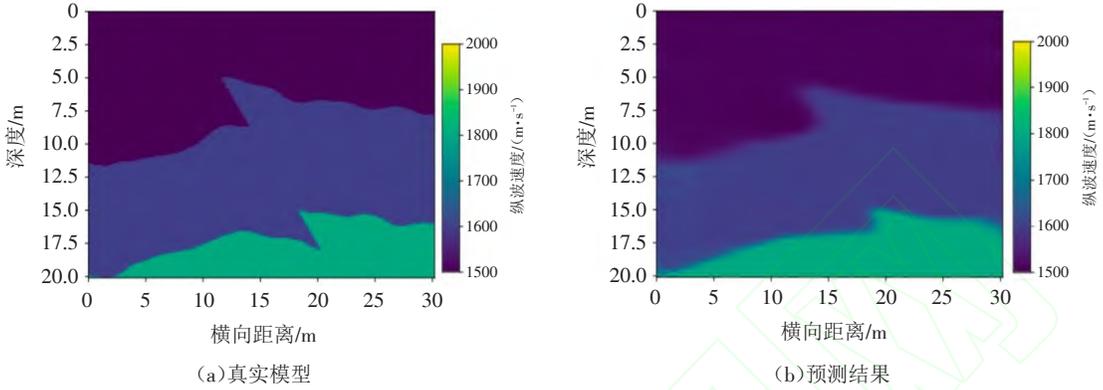


图 12 逆断层模型预测结果

Fig.12 Ground truth models and predicted models

在 SSIM 直方图中(图 13), 横轴表示测试集样本号(共 50 个样本), 纵轴柱状图表示每个测试样本结果的 SSIM 值, 该值越接近于 1, 表示预测模型越接近真实模型. 可以发现, 在测试集上模型预测值的 SSIM 均大于 0.8, 且大部分样本的结果都高于 0.9, 最大值 0.95, 最小值 0.82, 平均值 0.91, 说明模型在测试集的预测效果较为准确. 同时, 也意味着模型具有良好的泛化性, 并没有在训练集上出现过拟合的情况, 这为下文的迁移学习实验打下了良好的基础.

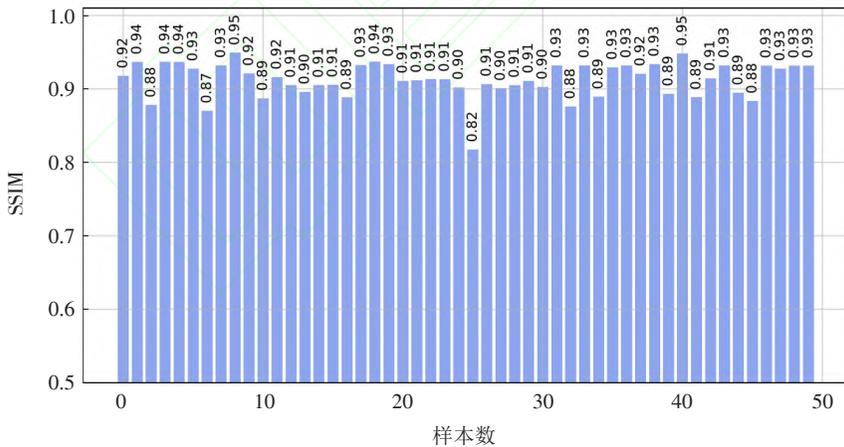


图 13 预测结果 SSIM 值

Fig.13 SSIM of 50 prediction results

在 PSNR 统计直方图(图 14)中, 横轴表示测试集样本号(共 50 个样本), 纵轴柱状图表示每个测试样本结果的 PSNR 值, 该值越大, 表示预测图像中有效值占比越高, 即与原始图像的接近程度越高. 经验表明, 该值大于 30 即表示具有较高的相似度. 大部分样本的结果都高于 35, 最大值 43, 最小值 19, 平均值 39, 说明模型在测试集的预测效果较为准确. 对比图 SSIM 与 PSNR 的结果可以发现, 两个评价指标变化趋势基本相同, 近似成正比, 第 25 号样本的预测效果最差.

为直观的对比模型预测值与真实值的数值对比, 在 $x=15$ m 位置做出一个速度剖面, 对比真实速度与预测速度值, 如图 15 所示. 这里仅给出从测试集中随机选取的四个速度模型的剖面作为示例.

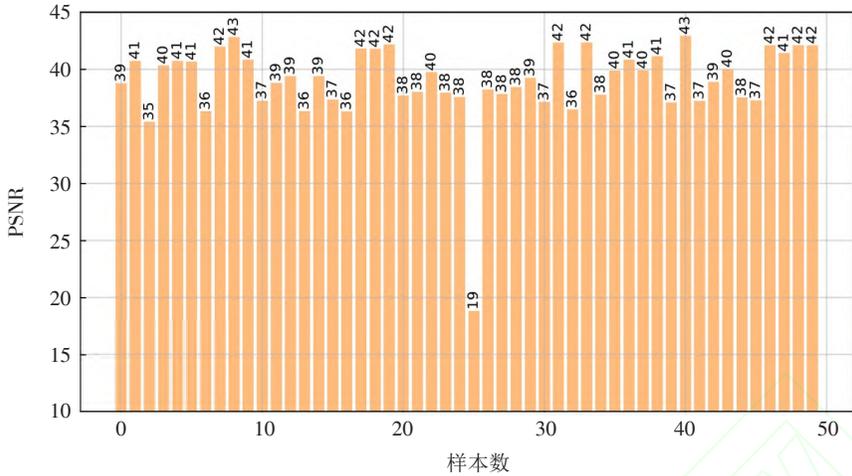


图 14 预测结果 PSNR 值

Fig.14 PSNR of 50 predicted models

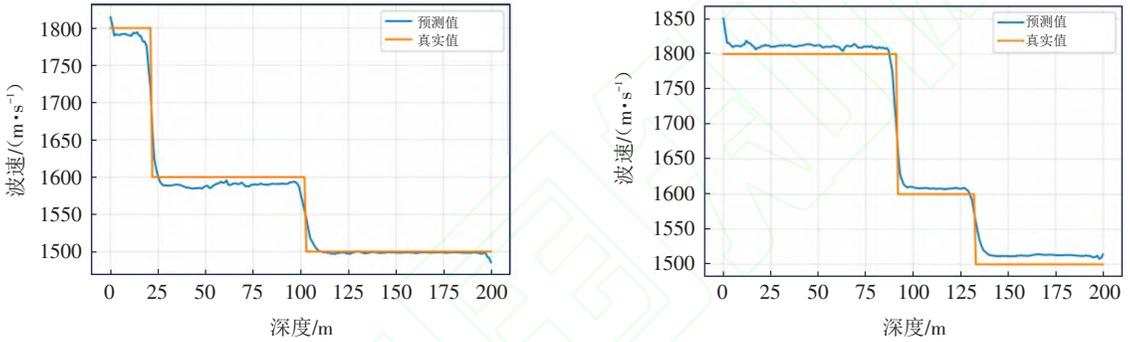


图 15 速度剖面预测值与真实值

Fig.15 P-wave velocity profile of GT models and prediction

可以看出,对于不同位置发生速度突变的剖面,模型总能够准确地预测出突变点位置,且剖面上的速度值与真实值接近程度较高,可以直观的看到模型预测数值的准确性.对于每段速度为常量时,与真实值相比,模型预测的结果在真实值附近产生微小的波动,这说明模型并未完全的“记住”数据,即未产生明显的过拟合现象.

根据本节的实验结果可以得出,一旦神经网络模型训练完成,预测阶段的时间成本可以忽略不计.当地震数据处于复杂地质模型、弹性波假设的情况下,迁移学习训练出的网络仍然可以计算出令人满意的速度剖面.模型的训练与预测几乎不需要人工干预,且不涉及初始速度设置.同时,损失函数是在模型域中测量的,使用网络进行预测时不会生成震波图.此外,不存在跳周期问题.大规模多样化的训练集在监督学习方法中起着重要的作用,因此可以通过增加更加多样化的训练样本提升速度模型的预测效果^[21].

4 结论

采用卷积神经网络,在弹性波的假设下,基于多炮地震数据,进行了复杂地质模型的反演.具体为:构建随机地质模型库,利用有限差分模拟地震波传播并获取信号,使用改进的卷积神经网络U-Net进行数据-模型映射的训练,最后训练出的神经网络通过多炮地震信号重建地下速度模型.试验结果表明,利用改进的卷积神经网络U-Net,可以有效反演复杂构造下的浅地层速度模型.得到的主要结论如下:

1)利用卷积神经网络建立了地震信号与地质速度模型的非线性关系,实现了无需初始速度模型的快速准确速度模型反演.深度学习技术适合于在大量数据中自动地学习到输入-输出之间的映射关系,且无需设置初始速度模型,能够由地震波探测信号直接地、全局地重构速度模型.训练后的网络能够有效精准的预测速度模型,训练完成后预测所花费的时间可忽略不计,在保证反演精度的前提下.极大的提高了速度模型反演的效率.

2) 利用随机地质模型生成方法, 可以生产用于地震数值模拟的, 包括地层、褶皱、起伏、断层等产状的, 可在一定范围内控制随机的浅层地质模型. 采用该随机地质模型, 可以丰富浅层地震问题的研究手段, 并为成像反演方法、深度学习研究提供了研究素材与数据支撑.

3) 改进 U-Net 网络模型能够精确的实现从地震信号到速度模型的跨维度反演任务. 数值试验结果表明, 该模型能够精确的预测出地层分界线、褶皱、起伏、断层滑移线等的位置和大小等. 预测结果与真实模型相比较, 得到的 SSIM 平均值为 0.91, PSNR 平均值为 39.0, 具有较高的反演精度.

4) 随机地质方法可向三维模型拓展, 同时可以考虑将更多的特征加入到随机模型的生成中以适应不同使用场景的需求. 例如断层的滑移面可以设置为曲线, 滑移面间可以增加破碎岩体, 或增加孤石、盐体类的高速地质异常体.

参考文献:

- [1] 薛亚东, 李硕标, 丁文强, 等. 隐伏溶洞对隧道施工安全影响的风险评估体系[J]. 现代隧道技术, 2017, 54(4): 41-47.
- [2] 赵博超, 朱蓓, 王弘元, 等. 浅谈岩溶塌陷的影响因素与模型研究[J]. 中国岩溶, 2015, 34(5): 515-521.
- [3] 刘春生, 石振明, 刘鑫, 等. 复杂岩溶地区桩位岩溶探测方法研究综述[C]//第十五届全国工程物探与岩石工程测试学术大会论文集. 厦门, 2017: 11-17.
- [4] 杨放丹. 地震映像法在溶洞探测中的应用[J]. 西部探矿工程, 2018, 30(1): 120-122.
- [5] 周富隆. 综合物探方法在石灰岩矿岩溶勘察中的应用[J]. 中国非金属矿工业导刊, 2018(3): 17-20.
- [6] 张午阳, 郭都城, 叶东昌, 等. 管波探测法和跨孔弹性波 CT 法在岩溶场地勘察中的联合应用研究[J]. 广州建筑, 2021, 49(1): 3-7.
- [7] COOK J C. Seismic mapping of underground cavities using reflection amplitudes[J]. Geophysics, 1965, 30(4): 527-538.
- [8] STEEPLES D W, KNAPP R W, MCELWEE C D. Seismic reflection investigations of sinkholes beneath Interstate Highway 70 in Kansas[J]. Geophysics, 1986, 51(2): 295-301.
- [9] 曹江涛, 翟伟强, 方勇. 浅层地震反射波法在山区工程勘察中的应用[J]. 工程勘察, 2014, 42(8): 84-88.
- [10] LI S C, ZHOU Z Q, LI L P, et al. Risk assessment of water inrush in karst tunnels based on attribute synthetic evaluation system[J]. Tunnelling and Underground Space Technology, 2013, 38: 50-58.
- [11] YU S W, MA J W. Deep learning for geophysics: Current and future trends[J]. Reviews of Geophysics, 2021, 59(3).
- [12] ARAYA-POLO M, JENNINGS J, ADLER A, et al. Deep-learning tomography[J]. The Leading Edge, 2018, 37(1): 58-66.
- [13] BI Z F, WU X M, LI Z L, et al. DeepISMNet: Three-dimensional implicit structural modeling with convolutional neural network[J]. Geoscientific Model Development, 2022, 15(17): 6841-6861.
- [14] WU X M, GENG Z C, SHI Y Z, et al. Building realistic structure models to train convolutional neural networks for seismic structural interpretation[J]. GEOPHYSICS, 2020, 85(4): WA27-WA39.
- [15] REN Y X, NIE L C, YANG S L, et al. Building complex seismic velocity models for deep learning inversion[J]. IEEE Access, 2021, 9: 63767-63778.
- [16] LI S C, LIU B, REN Y X, et al. Deep-learning inversion of seismic data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(3): 2135-2149.
- [17] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015, 2015: 234-241.
- [18] LIU L, SHI Z M, PENG M, et al. Numerical modeling for karst cavity sonar detection beneath bored cast in situ pile using 3D staggered grid finite difference method[J]. Tunnelling and Underground Space Technology, 2018, 82: 50-65.
- [19] YANG F S, MA J W. Deep-learning inversion: A next-generation seismic velocity model building method[J]. GEOPHYSICS, 2019, 84(4): R583-R599.
- [20] LEWIS W, VIGH D. Deep learning prior models from seismic images for full-waveform inversion[C]. In SEG International Exposition and Annual Meeting. Society of Exploration Geophysicists, 2017.
- [21] ZHENG Y, ZHANG Q, YUSIFOV A, et al. Applications of supervised deep learning for seismic interpretation and inversion[J]. The Leading Edge, 2019, 38(7): 526-533.

(编辑 许军策)