

中国科学技术大学

博士学位论文



基于井震联合的智能储层参数 建模

作者姓名： 闫上升
学科专业： 地球物理学
导师姓名： 伍新明 教授
完成时间： 二〇二一年四月

University of Science and Technology of China
A dissertation for doctor's degree



**Building reservoir models with
seismic and well-log data via
deep learning**

Author: Shangsheng Yan

Speciality: Geophysics

Supervisors: Prof. Xinming Wu

Finished time: April, 2021

中国科学技术大学学位论文原创性声明

本人声明所呈交的学位论文,是本人在导师指导下进行研究工作所取得的成果。除已特别加以标注和致谢的地方外,论文中不包含任何他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的贡献均已在论文中作了明确的说明。

作者签名: _____

签字日期: _____

中国科学技术大学学位论文授权使用声明

作为申请学位的条件之一,学位论文著作权拥有者授权中国科学技术大学拥有学位论文的部分使用权,即:学校有权按有关规定向国家有关部门或机构送交论文的复印件和电子版,允许论文被查阅和借阅,可以将学位论文编入《中国学位论文全文数据库》等有关数据库进行检索,可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。本人提交的电子文档的内容和纸质论文的内容相一致。

保密的学位论文在解密后也遵守此规定。

公开 保密 (____年)

作者签名: _____

导师签名: _____

签字日期: _____

签字日期: _____

摘要

地震层位的提取是地震解释中非常重要的步骤，同时需要花费大量的时间。目前已有的拾取层位的方法在地震数据中同相轴不连续的区域（例如，断层、噪音等），无法自动提取相位一致的精确的地震层位，并且往往由于过度平滑而缺失一些地质结构的细节信息。为了获得更精确的层位，本文提出了基于动态规划的方法，可以有效的解决这个问题，能够有效地拾取正确的地震层位，甚至在地震数据中复杂的不连续区域（例如，断层、噪音等），依然能够准确地自动追踪相位一致的地震层位，能够很好地揭示详细的地质结构信息。在这种方法中，首先使用自动方法、人工拾取或用几个控制点插值来计算一个初始层位。该初始层位可以不准确，只需要符合目标层位的总体趋势即可。然后提取以初始层位为中心的子区域，并根据初始层位使子区域整体拉平。最后，利用动态规划来有效地选择整个子区域中的最优路径，即全局最大或最小振幅值得路径。通过此方式，能够将初始的不准确层位更新为一个更精确的层位，该结果遵循一致的振幅峰值、谷值或零交叉。由于本文提出的方法并不严格依赖于初始层位，因此我们更倾向于直接从有限数量的控制点插值得到初始层位，这比自动或手动提取初始层位时在计算上更有效。此外，本文的方法可以通过编辑或移动控制点时进而实时交互实现更新层位的目的。更重要的是，这些控制点不需要精确的放置在目标的层位上，在其附近即可，这能够大大降低计算成本，节约时间，可以有效且快速地实施人工交互功能。本文利用多个二维和三维的复杂实际数据来验证提出的方法，结果也表明该方法在地震解释中有很好的应用前景。

传统的地震反演方法通常认为是一个不适定问题，而深度学习方法在从地震数据预测声阻抗方面表现出了良好的前景。然而，大多数深度学习方法都是基于易于实现的一维神经网络，但在逐道预测多维阻抗模型时往往会产生一些不合理的横向不连续现象。本文对其进行改善，利用二维卷积网络（CNN）实现基于深度学习的波阻抗预测，并引入初始波阻抗模型的约束到该网络。初始模型可以从几个测井曲线利用地震构造导向的插值方法得到，然后作为低频约束输入到网络当中，从而使 1D 和 2D 的 CNN 网络产生稳定的阻抗预测结果。本文所提出的 2D CNN 的架构非常简单，但是由于我们是无法直接得到一个二维的波阻抗标签，所以准备训练数据集是一个挑战。为了准备二维的训练数据集，本文首先定义一个随机路径可以穿过一定数量的测井位置，然后沿着这个路径去提取一个二维的地震剖面和对应的初始模型剖面作为网络的输入，穿过该路径的所有测井作为波阻抗剖面相对应的部分标签。有了这些随机抽取得到的二维训练数据集，本文利用弱监督的方法训练网络，并定义自适应损失函数，即网

络输出的二维波阻抗模型仅在有井的地方进行验证评估。由于二维的数据训练集是从最原始的三维数据中从各个方向随机选择的，所以利用训练得到的二维网络，可以从沿测线或者垂直测线的方向，预测一个个连续的二维剖面，进而得到相对应的三维波阻抗模型。合成和实际的例子也表明，相对于一维卷积神经网络，本文提出的二维卷积神经网络不仅对噪音的干扰反应更加稳定、能够更好得恢复出薄层，而且在横向上能够产生更加一致的结果。

地质建模在储层预测中扮演着重要的角色，通常需要充分并合理地整合地球物理观测数据和地质上约束，但其仍然是一项具有挑战性的任务。本研究中，我们提出了一套完整工作流程，充分利用地震振幅、测井属性和地震构造特征来建立合理的储层参数模型。以 Volve 区域的数据为例，对其应用整个流程如下：首先，对所提供的 Volve 地区的地震资料、层位和测井曲线进行预处理，在深度域进行异常值去除和井震关系匹配。其次，使用一种基于动态规划的方法来填补层位所缺失的地方，并提升所提供的层位的垂直位置，同时提取更多的层位。然后进一步利用层位面插值得到一个相对地质时间(RGT)体，可以被认为是一个隐含的结构模型，代表地震构造和地层特征。然后，利用提供的测井曲线与得到的 RGT 体，计算出既符合测井特征又符合地震构造和地层特征的储层参数模型。最后，利用深度学习方法结合地震和测井数据预测最终的模型，同时将初始模型作为低频约束引入网络。实验结果表明，本文所提出的工作流程能够产生合理的储层参数模型，而且具有较高的横向连续性和垂直分辨率。

关键词：地震解释；层位提取；井震联合；地震反演；深度学习；储层参数建模；
Volve 数据

ABSTRACT

Horizon can be picked from seismic images by consistently following seismic reflectors, which is a fundamental and crucial step for seismic interpretation but remains a time-consuming task. Although various automatic methods have been developed to extract horizons in seismic images, most of them may fail to pick horizons across discontinuities such as faults and noise. To obtain more accurate horizons, we propose a dynamic programming algorithm to efficiently refine manually or automatically extracted horizons so that these horizons can more accurately track reflectors across discontinuities, follow consistent phases, and reveal more geologic details. In this method, we first compute an initial horizon that may not be accurate and only needs to follow the general trend of the target horizon. Therefore, such an initial horizon can be obtained with an automatic method, manual picking, or interpolation with several control points. Then, we extract a sub-volume of amplitudes centered at the initial horizon and meanwhile flatten the sub-volume according to the initial horizon. We finally use the dynamic programming to efficiently pick the globally optimal path that passes through global maximum or minimum amplitudes in the sub-volume. By doing this, we are able to refine the initial horizon to a more accurate horizon that follows consistent amplitude peaks, troughs, or zero-crossings. As our method does not strictly depend on the initial horizon, we prefer to directly interpolate an initial horizon from a limited number of control points, which is computationally more efficient than automatically or manually picking an initial horizon. In addition, our method is convenient to be interactively implemented to update the horizon while editing or moving the control points. More importantly, these control points are not required to be exactly placed on the target horizon, which makes the human interaction highly convenient and efficient. We demonstrate our method with multiple 2D and 3D field examples that are complicated by noise, faults, and salt bodies.

Deep learning methods have been popularly used in geophysical problems, such as model building, fault interpretation, reservoir prediction, and so on. Many researchers also have introduced the deep learning to predict acoustic impedance from seismic data which is typically considered as an ill-posed problem for traditional inversion methods. Most of the deep learning methods, however, are based on a 1D neural network, which is straightforward to implement but often yields laterally unreasonable discontinuities in predicting a multi-dimensional impedance model trace-by-trace. We improve the

deep learning-based method to predict impedance by implementing it with a 2D convolutional neural network (CNN) and introduce the constraints of an initial impedance model into the network. We first calculate the initial impedance model with interpolation from the impedance logs with the guidance of seismic structures and then the initial model is input to the network to provide a low-frequency trend control. The results show that it is helpful for both the 1D and 2D CNNs to yield stable impedance predictions. The architecture of the proposed 2D CNN is quite simple but training the CNN is not straightforward because a full 2D impedance label is not available. To prepare a 2D training dataset, we first define a random path that passes through multiple well logs. We then follow the path to extract a 2D seismic profile and an initial impedance profile which together form an input to the 2D CNN. The set of well logs (traversed by the path) serves as a partially labeled target. With the randomly extracted 2D training datasets, we train the CNN with weak supervision by using an adaptive loss where the output 2D impedance model is adaptively evaluated at only the well logs in the partially labeled target. As the 2D training datasets are randomly chosen from the original 3D survey in all directions, the trained 2D CNN can predict a consistent 3D impedance model section-by-section in either inline or crossline direction. Synthetic and field examples show that the proposed 2D CNN is more robust to noise, recovers thin layers better, and yields a laterally more consistent impedance model than a 1D CNN with the same network architecture and the same training logs.

Subsurface modeling plays an important role in hydrocarbon exploration but remains a challenging task that typically involves a full and reasonable integration of geophysical observations and geologic constraints. We present a workflow to fully utilize seismic amplitudes, well-log properties, and interpreted seismic structures to build geologically reasonable models. We take the Volve field data as an example and apply our workflow step by step as follows: First, we perform some preprocessing on the provided Volve seismic data, horizons, and well-logs to remove anomalous values and adjust seismic-well ties in depth domain. Second, we use a dynamic programming based method to fill the holes and refine the vertical positions of the provided horizons and efficiently pick more horizons. We further use the horizon surfaces to interpolate a relative geologic time (RGT) volume which can be considered as an implicit structural model representing seismic structural and stratigraphic features. Third, we integrate the provided well-logs and the computed RGT volume to compute a subsurface model that conforms to both well-log properties and seismic structural and stratigraphic features.

Finally, we predict a final model with deep learning using seismic and well-log data and meanwhile introduce the initial model as low-frequency constraints into the network. The results show that our workflow is able to produce geologically reasonable subsurface models with high lateral continuity and vertical resolution.

Key Words: Seismic interpretation; Horizon extraction; Seismic data and well logs; Seismic inversion; Deep learning; Building reservoir models; Volve field data.

Abstract

目 录

第 1 章 绪 论.....	1
1.1 研究意义.....	1
1.2 研究现状和进展.....	2
1.2.1 地震层位的提取.....	2
1.2.2 地震反演.....	3
1.2.3 井震联合建模.....	5
1.3 本文研究内容.....	5
第 2 章 基于动态规划算法的地震层位提取.....	7
2.1 引言.....	7
2.2 传统的层位提取方法.....	7
2.2.1 人工提取层位.....	7
2.2.2 基于斜率/倾角的自动方法.....	9
2.2.3 基于斜率和多重网格互相关的方法.....	12
2.3 基于动态规划方法.....	14
2.3.1 二维层位提取.....	14
2.3.2 三维层位提取.....	17
2.4 三维实例应用.....	20
2.5 本章小结.....	24
2.5.1 讨论.....	24
2.5.2 结论.....	30
第 3 章 相对地质年代体引导的储层参数建模.....	31
3.1 引言.....	31
3.2 方法理论.....	31
3.2.1 地震构造导向的插值方法.....	31
3.2.2 RGT 引导的插值方法.....	32
3.3 实例应用.....	34
3.3.1 层位的提取.....	34
3.3.2 RGT 的计算.....	34
3.3.3 RGT 导向建模.....	34
3.4 本章小结.....	40

第 4 章 井震联合的智能储层参数建模.....	41
4.1 引言.....	41
4.2 方法理论.....	45
4.2.1 数据集.....	45
4.2.2 1D CNN	45
4.2.3 2D CNN	51
4.3 实例应用.....	55
4.4 与传统方法的对比.....	61
4.4.1 与约束稀疏脉冲反演方法的对比结果.....	61
4.4.2 与基于模型反演方法的对比结果.....	62
4.5 本章小结.....	64
第 5 章 实例应用：Volve 数据	67
5.1 引言.....	67
5.2 层位.....	69
5.2.1 层位的更新和提取.....	69
5.2.2 RGT 的计算.....	71
5.3 测井.....	71
5.4 储层参数建模.....	76
5.4.1 RGT 导向插值的初始模型.....	77
5.4.2 基于深度学习的最终模型.....	79
5.5 本章小结.....	86
第 6 章 结论和展望.....	87
6.1 结论.....	87
6.2 展望.....	88
参 考 文 献.....	91
致 谢.....	103
在读期间发表的学术论文与取得的其他研究成果.....	107

第1章 绪论

1.1 研究意义

油气勘探与国家资源问题有着重要的联系，这就要求我们提高勘探的精度，加大勘探开发程度，提升油气资源储量。地震勘探技术是油气勘探的重要手段之一，从地震数据体中提取和挖掘多种地质信息（包括层位、断层、裂缝、孔洞等）并确定油气储层和岩石属性是地震勘探和开发的重要目标。当前地震资料处理和解释周期长，解释结果因人而异，不断重复采集、重复处理和解释地震资料的现状，造成给油气上游开发造成成本高和效率低的严重问题。特别是我国地震勘探数据采集环境复杂、油气目标体越来越深、地震数据信噪比低，导致地震资料的地质解释比其它许多国家面临更大挑战。因此，地震数据中地质信息提取与解释走向自动化和智能化是加速我国石油工业发展的当务之急。

地震层位的提取是地震解释的基础步骤，人工拾取需要耗费大量的人力和时间，而且在复杂的三维数据体中的解释存在很大的难度。自动提取层位信息的方法的出现在一定程度上提高了精度和效率，但有的方法对噪声敏感，局限于简单的地质构造 (Lacaze and Valding, 2009; Dorn, 2011)，有的缺少细节，得到的结果比较平滑 (Stark, 2005; Wu and Zhong, 2012)。近年来也有也有一些研究者提出新的基于深度学习的算法 (Geng et al., 2019; Wu et al., 2019; Shi et al., 2020)。这些方法各有优缺点，仍然面临很多需要解决的实际问题。因此针对存在的问题，本文提出新的提取层位的方法，以快速获得更加准确的层位面，节省大量的时间，为后续的构造解释和岩性的划分提供可靠的依据。

地震反演是油气勘探中储层预测的关键技术，具体指利用地表观测地震资料，以已知地质规律和钻井、测井资料为约束、对地下岩层空间结构和物理性质进行成像（求解）的过程。而波阻抗反演是极其重要的方法，可以有助于解决确定岩性、储层等问题，将波阻抗反演得到的物性分析结果与地震属性分析得到的结果作综合分析，可以有效的为进一步的储层预测给出参考意见 (Latimer et al., 2000)。近年来，基于机器学习的储层反演方法逐渐改善了传统反演方法所面临的问题，但是目前大多数基于深度学习的反演是在一维条件下（单道）进行反演外推的，反演结果存在连续性较差，反演不稳定，存在部分假象。另外，目前的基于深度学习的叠前、叠后反演方法由于测井数据有限且稀疏，用于训练的样本对有限导致缺少结构信息的约束，影响反演的精确度。因此，本文针对以上反演方法所面临的问题，构建更加优化的深度学习网络并结合层序-构造信息和测井资料的约

束来进一步提高储层参数预测的精确度和可靠性,提高数据集的融合能力,为加强含油气区域储层预测提供依据。

1.2 研究现状和进展

1.2.1 地震层位的提取

从地震图像中提取层位是地球物理解释的基本步骤之一。地震层位被认为与恒定地质时间的地层面相匹配,代表地质上的同一时期面 (Vail et al., 1977)。因此,地震层位可以用来构建年代地层模型 (Labrunye et al., 2009, 2015)。层位对于识别构造和地层特征也非常重要 (Qayyum et al., 2018), 因为层位的不连续点或终止处一般会代表断层 (Wang et al., 2014b,a), 河道 (Hale, 2009), 不整合面 (Bugge et al., 2018), 盐丘体边界 (Wang et al., 2015c; Shafiq et al., 2015, 2016) 等构造。层位也可以用来分析古代沉积环境和地貌特征 (Posamentier et al., 2007)。此外,高密度的层位序列,通常被称为层位立方体 (de Groot et al., 2010), 对于生成 Wheeler 图也有重要意义 (Qayyum et al., 2015, 2017), 这是层序地层解释的关键方法之一 (Qayyum et al., 2012)。

由于地震成像的数据可能非常巨大和复杂的(特别是 3D 数据), 所以手动提取地震层位非常耗时。为了解决这一问题, 学者们研究出了多种自动或半自动的方法去解释地震层位。一类方法是基于波形相似性 (Borgos et al., 2003; Lacaze et al., 2009), 他们利用相邻道之间的相干性或相关性来跟踪层位。这些方法通常遵循比较小的结构变化, 选取局部最优解, 因此可以有效地揭示一些详细的构造。然而, 这些方法在通过一些不连续点(比如噪声和断层)时可能无法提取一致的层位 (Dorn, 2011)。

另一类方法是通过一定的方法计算相对地质时间 (RGT), 然后提取 RGT 等高线来获得层位 (Stark, 2005a; Wu et al., 2012)。这类方法虽然是全局最优的, 但通常生成的层位比较平滑, 缺乏详细的地质信息。此外, 在处理地震不连续性(包括断层和不整合)时, 需要大量的人为参与工作。

最常用的一类方法是基于斜率的方法 (Parks, 2010; Fomel, 2010; Di et al., 2018; Lou et al., 2019) 或地震反射轴的法向量 (Luo et al., 2013)。地震反射斜率可以通过计算结构张量 (Bakker et al., 1999; Bakker, 2002; Fehmers et al., 2003; Hale, 2009; Morelatto et al., 2013) 或使用平面波破坏法 (Fomel, 2002; Phillips et al., 2016) 得到。这类基于斜率的方法对于噪声具有鲁棒性, 但是由于对局部特征的平均化效应使得它不能揭示详细的地质结构。其他一些基于斜率的方法, 比如使用相似性扫描 (Marfurt et al., 1998; Marfurt, 2006)、动态图像变形 (Hale, 2013;

Arias, 2016) 和二维 log-Gabor 滤波 (Yu et al., 2013), 只有在反射轴横向连续时才有效。

然而, 由于斜率在穿过断层的位置无法追踪正确的反射轴信息, 所以许多基于斜率的方法无法在经过断层的位置提取正确的层位 (Lomask et al., 2006; Parks, 2010; Zinck et al., 2013; Wu et al., 2013, 2015; Monniron et al., 2016)。为了解决这个问题, 一些方法在提取层位之前从地震图像中去除断层 (Luo et al., 2013; Wu et al., 2016), 或通过使用添加人工控制点 (通常放置在断层的两侧) 作为约束条件来提取层位 (Wu et al., 2015)。另外一些方法在不移除断层的情况下提取层位, 通过计算多重网格互相关 (Wu et al., 2018a) 和地震道之间的非局部匹配 (Bugge et al., 2019) 来帮助追踪经过断层位置时对应一致的反射轴。还有一些其它的方法将层位提取问题转化为以断层为内部边界的非齐次各向异性泊松方程的求解问题 (Wang et al., 2015b,a)。

1.2.2 地震反演

地震反演是指对地震勘探采集得到的数据进行处理和解释, 从而反演得到地层构造和储层参数模型。其中波阻抗参数是指示储层分布的一项重要依据, 因为波阻抗可以显示高分辨率的岩石属性, 从而可以指示岩性、孔隙度、孔隙填充度和其他因素 (Latimer et al., 2000), 所以从地震数据中估算波阻抗对于油藏特征的描述非常重要。通常地震反演技术就是指波阻抗反演。

波阻抗反演技术的发展从叠后偏移数据的一维反演开始, 以基于褶积模型的方法(张永刚, 2002; 吴华, 2015)和广义线性反演方法(Cooke et al., 1983)为主。基于一维的反演是最简单的最快的, 但同时也是最受限的, 受子波的影响较大。Russell 等(1991) 和 Latimer (2000)也对这类方法的优缺点及其发展进行了详尽的叙述。为了解决线性反演中存在的问题, 周竹生等(1993)提出了宽带约束反演方法, 考虑使用地质信息、测井数据和地震数据对反演过程进行约束。但是基于单道反演的方法仍受噪音的影响比较大, 为解决这个缺陷, 李宏兵(1996)提出了新的思路, 将宽带约束反演与递推反演相结合。付庆云(2012)在此后进行了改进, 进行了多道反演技术的研究, 并结合多井的信息使反演的结果更加可靠。通常解决地震反演这类病态的问题, 需要引入正则化方法, 可以提升抗噪性和稳定性, 而且可以加入先验的地质知识等信息, 使其结果更加可信准确。最常用的正则化包括 Tikhonov 正则化 (Tikhonov, 1963; Tikhonov et al., 2013), 应用于最小二乘反演 (Marquardt, 1963)、有限带宽反演 (Lindseth, 1979)、广义线性反演 (Cooke et al., 1983) 等技术当中。但是由于 Tikhonov 正则化是求解目标参数的 L_2 范数最小化方程, 所以经常会产生光滑的结果导致分辨率不高, 边界信息不够清楚(Zhang

et al., 2013)。因此，我们在解决反演问题的时候也经常用到另一种基于 L_1 范数的正则化，其常被应用于反褶积，反演，多次波消除等不同的领域 (Levy et al., 1981, Guitton et al., 2004, Zwartjes et al., 2007)。

目前，多种多样的地震反演方法已被提出，用来从叠后或者叠前地震数据中估计声波或弹性波阻抗，包括基于稀疏脉冲的方法 (Oldenburg et al., 1983; Velis, 2008; Zhang et al., 2011; Gholami et al., 2012; Yuan et al., 2015; Wang et al., 2016; Sui et al., 2019)，基于模型约束法 (Smith et al., 1987; Veeken et al., 2004; Fu, 2004; Wu, 2017b)，和地质统计学和随机方法 (Sen et al., 1991; Mallick, 1995; Ma, 2002; Buland et al., 2003; González et al., 2008; Bosch et al., 2010; 高扬 2018)。

这些方法的基本思想是通过匹配合成的和实际的地震数据去估计波阻抗。合成地震数据通常是由地震子波与反射系数进行卷积得到，而反射系数可以由阻抗求得。然而在实际中，用一个简单的卷积模型来描述实际的地震记录很可能是不合适的，也就是说合成数据和实际的记录拟合最佳并不代表一定能够产生一个最佳的波阻抗模型。实际地震数据中潜在的噪声、采集误差和处理误差对反演结果造成了更大的不确定性。此外，在这些方法中模拟合成地震数据需要子波，而子波在实际中往往是很难估计的。而且，具有多解性：可能存在不止一个波阻抗模型转化成反射体后与子波进行卷积，得到的合成记录与实际地震数据能够匹配。因此，除了要匹配地震数据外，大多数方法通常要引入不同的正则化项，合理的初始波阻抗模型和一些先验知识(例如，井数据、空间岩性分布与统计岩石性质)作为约束来解不适定的波阻抗反演问题。这些约束在求取合理的波阻抗模型的过程中有着关键的作用，可以很大程度上提高反演模型的可靠性。

利用机器学习或深度学习 (DL) 来预测地震阻抗的方法已经很普遍了。Hampson et al. (2001) 展示了一个简单的神经网络通过合理选择多种属性 (从井震数据中提取) 作为输入，可以很好地进行波阻抗预测。近年来，更多的深度学习 (Das et al., 2019; Puzyrev et al., 2019; Biswas et al., 2019; Wang et al., 2019; Zheng et al., 2019; Ahmad et al., 2019; Motaz et al., 2019) 已经被提出来，结合测井的信息来训练神经网络，进而用来估算波阻抗。深度学习方法可以直接实现，而不需要与传统的反演方法一样解决复杂优化系统。此外，相比传统的方法，数据驱动的深度学习方法有望提供更好的解决方案去估计从地震数据到阻抗的复杂的非线性映射，而不需要假设一个近似正演模型来从阻抗模拟地震记录。然而，大多数提出的 DL 方法是基于一维神经网络的，因为作为训练标签的测井曲线是一维序列。一维地震网络可能对地震数据中的噪声很敏感，而且在逐道预测多维阻抗模型时往往不能保持横向一致性。在训练记录有限而且岩石性质变化迅速的情况下，这种一维网络尤其不能提供稳定或准确的阻抗估计。

1.2.3 井震联合建模

储层预测是整个油气勘探开发过程中关键的步骤之一,从地震数据和测井数据建立精确的地下模型对储层预测至关重要 (Lemon et al., 2003; Zhu et al., 2012; Wu, 2017a)。地震数据可以提供地层特征和地质构造信息,而测井数据可以提供地震所没有的高分辨率的深度方向的岩石属性信息。然而,由于井的数量有限,从稀疏的测井数据中获得一个合理的地下模型仍然是一个挑战。

传统方法使用地震结构和测井测量值来建立模型。其中一些方法以几个层位和主要断层作为地下构造的约束条件来建模 (Mallet, 2002; Caumon et al., 2009)。其他的一些方法则使用图像引导的插值方法,根据地质信息和测井数据获得地下模型 (Hansen et al., 2008; Hampson et al., 2000; Hale, 2010a; Naeini et al., 2015; Karimi et al., 2017)。此外,有一些学者提出基于体技术的方法,整合层位、断层和不整合面来获得合理的地下模型 (Jayr et al., 2008; Souche et al., 2013; Dorn, 2013; Souche et al., 2014; Mallet, 2014; Labrunye et al., 2015)。

近年来,深度学习 (LeCun et al., 2015) 已经被成功的应用在反演问题上 (Lucas et al., 2018), 也被广泛的应用在地球物理领域,例如地震层位的提取 (Lowell et al., 2018; Shi et al., 2020; Geng et al., 2020; Tschannen et al., 2020), 断层解释 (Lv et al., 2016; He et al., 2017; Saufi et al., 2019; Wu et al., 2019a,b), 地震纹理识别 (Dramschi et al., 2018; Di et al., 2019) 等等。例如,一种被称为支持向量回归的监督学习方法被用来预测孔隙度和渗透率 (Al-Anazi et al., 2012)。卷积神经网络 (CNNs) 常用于建立地下速度模型 (Araya-Polo et al., 2018; Wu et al., 2018b), 预测地震岩性 (Zhang et al., 2018) 或者预测地震波阻抗 (Das et al., 2018)。除此之外,生成对抗网络 (GAN) (Mosser et al., 2020) 和递归神经网络 (RNN) (Richardson, 2018; Alfarraj et al., 2018) 也用于地震反演和岩石物性估计的问题中。

1.3 本文研究内容

根据前面阐述的地震解释和反演中存在的问题,在结合现有技术方法的基础上进行进一步完善,研究内容主要为地震三维层位解释以及地震数据和测井数据联合反演构建三维储层参数模型。具体为:

1. 地震层位的提取

第二章中,介绍了传统的层位提取方法往往需要大量的计算时间或者在不连续的地方无法提取准确的层位等问题。为了解决这些问题,本章通过振幅属性将提取地震层位的问题转化成求全局最优化的问题,采用改进的动态规划算法去提取地震层位。具体的技术路线为:首先利用地震反射轴的法向信息拾取初始地震

层位，然后以初始层位为中心选取合适的窗，并将窗内的地震图像拉平，在拉平在提取的地震数据中用动态规划方法拾取最优(小)路径，最后将提取的最优路径从拉平的空间变换回原始地震数据空间得到更新后的精细地震层位。最后将该方法应用于多个二维和三维的地震数据上，证明了该方法的有效性。而且在计算时间上，由于该方法避免了解非线性方程系统的步骤，节约了大量的时间，在精度和效率上均有提升。

2. 相对地质年代体引导的储层参数建模

第三章中，利用以上的方法提取多个层位，得到大致的地层格架，然后可以根据地层信息和地震图像计算得到整个三维空间的相对地质年代体。相对地质年代体在一定程度上反映了地震图像的构造信息。利用相对地质年代体作为构造导向，结合匹配好的测井数据，采用径向基函数插值方法得到初步的模型，最后利用公开的 Teapot Dome 数据进行示例。

3. 井震联合的智能化储层参数建模

第四章中，由于实际情况中井的分布比较稀疏，所以基于相对地质年代体导向插值得到的模型是缺失细节的。而且由于相对地质年代体有可能出现误差，所以会导致引入错误的插值信息，尤其是远离井的区域，插值得到的模型往往是不准确的。因此将这些信息作为低频约束条件融合到后续的反演过程中，利用二维卷积网络(CNN)实现基于深度学习的波阻抗预测。在准备二维的训练数据集时，首先定义一个随机路径可以穿过一定数量的测井位置，然后沿着这个路径去提取一个二维的地震剖面和对应的初始模型剖面作为网络的输入，穿过该路径的所有测井作为波阻抗剖面相对应的部分标签。最后本章也在公开的 SEAM 和 Teapot Dome 数据上验证了二维 CNN 的效果。

4. 实际资料的应用

第五章中，提出了一套通过利用地震构造、地震振幅属性和测井数据来建立地下模型的完整的工作流程，并将以上研究内容应用到公开的 Volve 油田上，再次说明所提出的方法的有效性。

在第六章中，我们总结了本文研究内容的结论和创新点，并讨论了提出的地震层位提取方法中存在的不足之处和井震联合反演中存在的问题，针对地震解释和地质建模提出下一步的研究方向和改进空间。

第2章 基于动态规划算法的地震层位提取

2.1 引言

地震层位的提取是地震解释中非常重要的步骤，但同时也需要花费大量的时间。目前已有的拾取层位的方法在地震数据中同相轴不连续的区域（例如，断层、噪音等），无法自动提取相位一致的精确的地震层位，并且往往由于过度平滑而缺失一些地质结构的细节信息。为了获得更精确的层位，在本章中提出了一种基于动态规划 (E.Bellman et al., 1962; Cormen et al., 2001) 的方法去有效地从地震图像提取层位。在该方法中，首先通过人工解释方法、或者自动方法、或者根据一些控制点插值方法得到一个初始的层位。该初始层位通常是不够准确的，不能够追踪一致的相位（波峰、波谷、零值点）或者不能在不连续点（断层、噪音）追踪一致的反射轴。然后，在以初始层位为中心选取的深度或时间窗口内通过动态规划算法去搜索全局最优路径（二维）或者全局最优面（三维）。在下面的章节中，首先介绍了传统的层位提取方法，包括人工解释和利用局部斜率的自动算法。同时，展示了一些二维和三维的数据用来说明这些方法中存在的潜在问题。接着文中详细描述了动态规划方法如何优化结果。除此之外，文中也讨论了控制点的数量和位置对结果的影响。最后，为了说明提出的方法的可行性，文中展示了该方法在更多的三维数据中的应用，并比较了利用不同的方法得到的结果，分别包括仅使用斜率的方法、利用局部斜率和多重网格互相关的方法、本文提出的基于动态规划的方法。

2.2 传统的层位提取方法

人工拾取层位不仅需要花费大量的时间和精力，而且由于人为因素使它具有很大的主观性。因此，发展出了不同的自动提取方法，可分为三大类：基于振幅的方法、基于斜率的方法和基于相对地质时间 (RGT) 的方法。其中基于斜率的方法是最常用的，其通过追踪反射轴来提取层位，该方法在本研究被用来与提出的新方法作比较。

2.2.1 人工提取层位

人工解释地震层位非常费时费力，尤其是在三维空间领域。为了节省时间，解释人员通常只在粗网格上稀疏地解释有限数量的纵测线和横测线剖面，然后通

过追踪一致的振幅来拾取其部分层位。然而，这类方法通常是粗糙的，只能追踪到局部的变化，而且当穿过噪声和不连续点时，它具有高度主观性。一种常用的方法是基于自相关法进行插值，逐道跟踪振幅变化。总的来说，人工解释的层位的准确度和分辨率往往是有限的。




图 2.1 (a)来自 Volve 数据的三维地震图像，其中黄色箭头表示经过波谷的目标层位(红

色)。(b)手动解释的层位。(c)在(b)结果的基础上利用本文的方法更新之后的精细化层位,从颜色上可以直观地看出该层位遵循更一致的相位。

如图 2.1 所示,展示了一个名为 Volve 的三维的地震数据的一部分,其大小为(500 [纵测线] \times 330 [横测线] \times 300 [深度]个采样点)。其中图 2.1b 显示了一个手动解释的层位面。Volve 数据采集于北海中部,由挪威国家石油公 Equinor 于 2018 年公开。图 2.1a 中的黄色箭头指示期望提取的层位,位于波谷的位置。在图 2.1b 中,可以观察到人工解释的层位面(来源于公开数据)不遵循一致的相位,颜色明显的变化也表明拾取的层位在波峰和波谷之间来回跳跃。此外,层位面上可以明显地看到一些网格状地图案,这可能是由于稀疏插值造成的假象。这种插值方法通常会使得地质构造模糊,降低精度。为了改进人工解释的结果,使用本文提出的方法进一步更新层位,如图 2.1c 所示,使其能更好地追踪一致的振幅波谷位置。

2.2.2 基于斜率/倾角的自动方法

对于传统的自动提取层位方法,本文中主要介绍最常用的基于斜率的方法。此处的斜率可以用不同的方法求得,例如平面波破坏法 (Fomel, 2002), 结构张量法 (Bakker et al., 1999; Fehmers et al., 2003; Hale, 2009; Morelato et al., 2013), 和相似性扫描法 (Marfurt et al., 1998; Marfurt, 2006) 等。

在本章中,首先利用结构张量 (Hale, 2009; Wu et al., 2018a) 估算地震的法向量 $\mathbf{u}(\mathbf{x})$,其垂直于地震的反射轴。该法向量是单位向量,分别包括垂直分量 $u_1(\mathbf{x})$ 、纵测线分量 $u_2(\mathbf{x})$ 、横测线分量 $u_3(\mathbf{x})$,并利用以下方程计算在纵测线和横测线方向上的斜率:

$$p(x) = -\frac{u_2(x)}{u_1(x)}, \quad q(x) = -\frac{u_3(x)}{u_1(x)} \quad (2.1)$$

然后,利用基于斜率的方法,通过匹配提取层位的斜率和已知的地震反射轴的斜率,用最小二乘法求解目标层位 $z(x)$,具体如下 (Parks, 2010; Wu et al., 2013, 2015):

$$\begin{bmatrix} w(x, z(x)) \frac{\partial z(x)}{\partial x} \\ \mu \frac{\partial^2 z(x)}{\partial x^2} \end{bmatrix} \approx \begin{bmatrix} w(x, z(x)) p(x, z(x)) \\ 0 \end{bmatrix} \quad (2.2)$$

其中, $w(x, z)$ 用来监测计算的反射轴斜率的质量,满足 $0 \leq w(x, z) \leq 1$. 第二个方程作为正则化约束项用来平滑目标层位 $z(x)$ 。 μ 是一个较小的常数用来平衡正则化项和斜率方程,例如 $\mu = 0.001$ 。

对于三维数据，我们可以将方程 2.2 很容易扩展到三维空间内去提取一个层位面 $z(x, y)$ ：

$$\begin{bmatrix} w(x, z(x)) \frac{\partial z(x)}{\partial x} \\ w(x, z(x)) \frac{\partial z(x)}{\partial y} \\ \mu \left(\frac{\partial^2 z(x)}{\partial x^2} + \frac{\partial^2 z(x)}{\partial y^2} \right) \end{bmatrix} \approx \begin{bmatrix} w(x, y, z) p(x, y, z) \\ w(x, y, z) q(x, y, z) \\ 0 \end{bmatrix} \quad (2.3)$$

其中， $p(x, y, z)$ 和 $q(x, y, z)$ 分别表示在层位 $z(x, y)$ 处，预先已知的纵测线和横测线方向的反射轴的斜率。




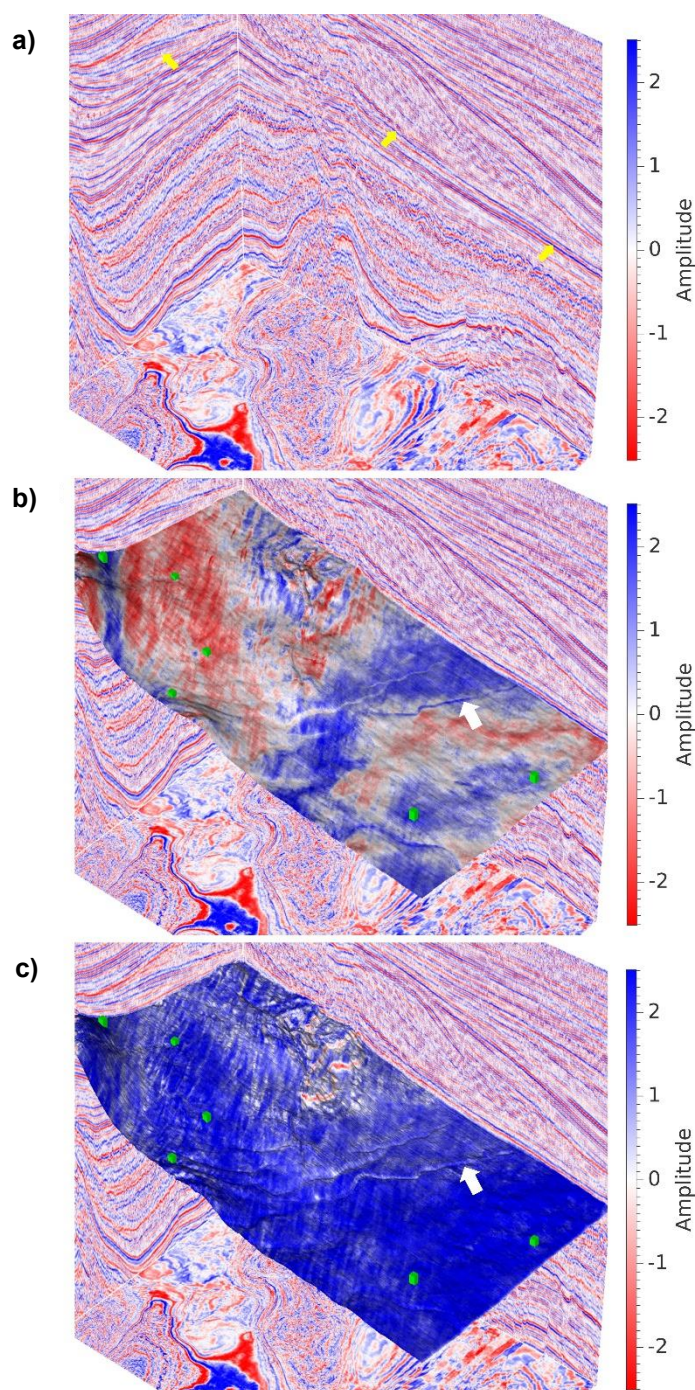
图 2.2 在二维地震图像(a)中，首先通过基于斜率的方法提取一个层位(b)(黄色曲线)，然后使用所提出的动态规划方法进一步改进或细化，得到结果(c)。黄色箭头所表示区域表明，本文的新方法显著改善了结果，使其遵循一致的波峰相位。红色圆圈表示提取层位过程中使用的控制点。

在方程 2.2 和 2.3 中，右侧斜率 p 和 q 取决于层位 $z(x)$ (二维) 或 $z(x, y)$ (三维)，表明这些方程是非线性的。因此，解这类基于斜率的方法需要从初始层位开始，然后不断迭代逐渐更新层位，直到目标层位的斜率与预先计算的地震反射轴斜率相匹配，其中初始层位可以从一些预先定义好的控制点插值出来。如果只有一个控制点，那么初始层位就是通过控制点的水平线（二维）或面（三维）。

图 2.2 是基于一个控制点（红色圆圈）求解方程 2.1 和 2.2 得到的层位，该层位能够遵循大致的结构趋势，但它并不能够追踪一致的相位。当它穿过小断层时，会从高峰跳到低谷（如图 2.2b 中的黄色箭头表示）。为了解决这个问题，本章提出了一种使用动态规划算法去改进图 2.2c 中层位的新方法，使其更符合统一的振幅峰值相位。

在图 2.3 和图 2.4 中进一步展示了一个 3D 示例，其中层位分别通过振幅和时间属性来显示。两个图中的黄色箭头(指示波谷)表示期望提取的标层位。在图 2.3b 中，是基于斜率的方法（公式 2.2）提取的层位，可以观察到明显的颜色变化，表明其在波峰和波谷之间反复跳跃。而且由于该方法的光滑效应，导致该层位上

的地质细节比较模糊。在图 2.3c 中，通过本文的提出的新方法对图 2.3b 的结果改进之后，可以看到改进之后的层位上几乎都呈现蓝色，显示了更加一致的相位



和更详细的结构，比如白色箭头指示的河道。此外，这些细小的构造和河道很容易在时间域的层位上观察得到（图 2.3c）。

图 2.3 在三维地震图像(a)中，黄色箭头指示的目标层位(蓝色)分别由(b)基于斜率的方法和(c)本文的方法提取。可以明显地观察到(c)中的层位几乎到处都是蓝色的，这也表明(c)中提取的层位的相位比(b)中的更一致。此外，(c)中的结果揭示了详细的结构，如

由白色箭头表示的小河道。绿色方块表示提取层位过程中使用的控制点。

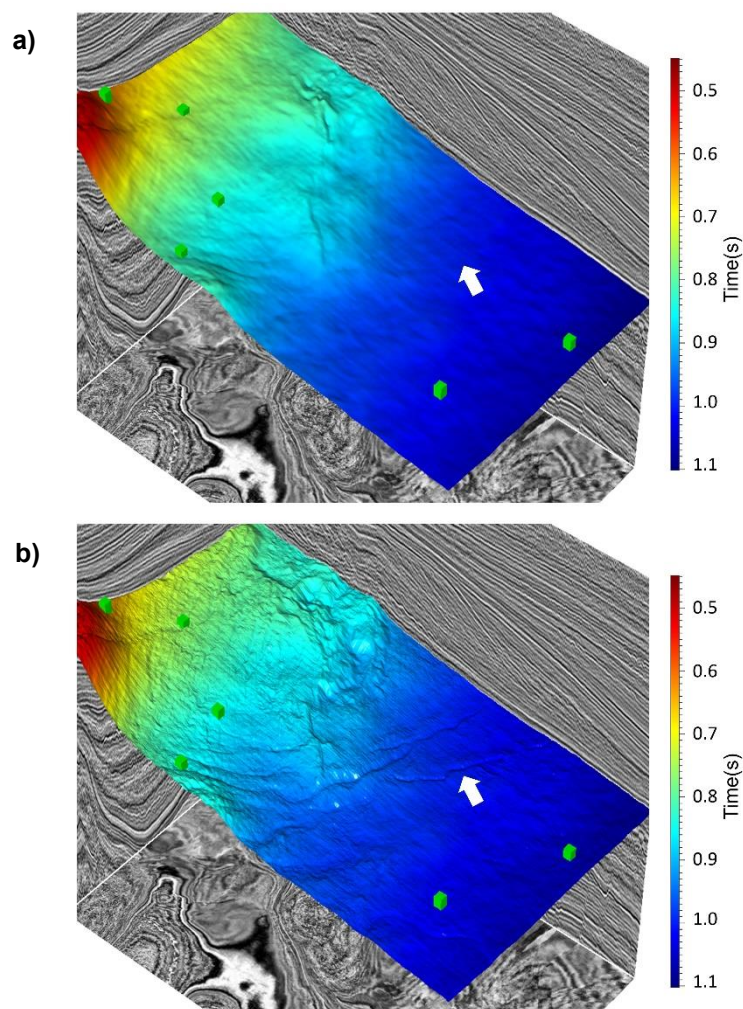


图 2.4 图 2.3b 和 2.3c 中的层位分别在时间域的显示效果如图 a 和 b 所示。同样地，可以观察到，相比于(a)中基于斜率的方法，通过本章提出的方法(b)可以得到更详细的结构，比如白色箭头所指示的河道信息。

2.2.3 基于斜率和多重网格互相关的方法

由于上述的仅考虑斜率的自动方法往往无法在经过不连续区域时准确地追踪一致层位（如图 2.2b 和 2.3b 所示），Wu 和 Fomel (2018) 提出了一种新的改进算法，利用最小二乘法去拟合层位与局部反射斜率和空间上更加全局的整体反射轴的相关性，也就是说考虑加入了空间全局约束。在该方法中，引入了粗网格互相关对方程 2.2 和 2.3 进行附加约束。这个约束有助于在不连续点上跟踪层位，

可以提供用于提取地震层位的多尺度信息。在三维情况下，层位的获取如方程所示：

$$\begin{bmatrix}
 w(x, y, z_i) \frac{\partial z_{i+1}}{\partial x} \\
 w(x, y, z_i) \frac{\partial z_{i+1}}{\partial y} \\
 \lambda w_{k,l}(y, z_i) \frac{z_{i+1}(l,y) - z_{i+1}(k,y)}{l-k} \\
 \lambda w_{c,j}(y, z_i) \frac{z_{i+1}(c,y) - z_{i+1}(j,y)}{j-c} \\
 \lambda w_{k,l}(x, z_i) \frac{z_{i+1}(x,l) - z_{i+1}(x,k)}{l-k} \\
 \lambda w_{c,j}(x, z_i) \frac{z_{i+1}(x,c) - z_{i+1}(x,j)}{j-c} \\
 \mu \left(\frac{\partial^2 z_{i+1}}{\partial x^2} + \frac{\partial^2 z_{i+1}}{\partial y^2} \right)
 \end{bmatrix} \approx \begin{bmatrix}
 w(x, y, z_i) p(x, y, z_i) \\
 w(x, y, z_i) q(x, y, z_i) \\
 \lambda w_{k,l}(y, z_i) p_{k,l}(y, z_i) \\
 \lambda w_{c,j}(y, z_i) p_{c,j}(y, z_i) \\
 \lambda w_{k,l}(x, z_i) q_{k,l}(x, z_i) \\
 \lambda w_{c,j}(x, z_i) q_{c,j}(x, z_i) \\
 0
 \end{bmatrix} \quad (2.4)$$

其中， $z_i(x, y)$ 表示每一次迭代更新之后的层位， $p_{k,l}(y, z_i)$ 和 $q_{k,l}(x, z_i)$ 分别根据横向粗网格对 (j, y) 和 (x, j) 计算得到的在纵测线(inline)和横测线(crossline)方向上的斜率。 $w(x, y, z_i)$ 代表估算反射轴斜率的权重因子。 λ 是用来平衡方程的较小常数值。

在本文的研究中，我们将使用这两种方法(第一种仅仅基于斜率的方法，第二种基于斜率和多重网格互相关的方法)作为基准来证明本文所提出的基于动态规划方法的性能。但值得注意的是，本章提出的新方法并不需要依赖于之前发表的任何方法。

2.3 基于动态规划方法

为了提取更加准确的层位（如图 2.1c, 2.2c, 2.3c, 2.4c 所示），本文提出了一种基于动态规划 (E.Bellman et al., 1962; Cormen et al., 2001; Hale, 2013) 方法去改善结果。在该方法中，首先要有一个初始层位，该初始层位可以由人工解释、基于斜率法、或者插值算法得到。然后利用动态规划算法更新初始值得到更加精确的结果。

2.3.1 二维层位提取

在提取层位的问题中，我们可以假设同一层位会一致地通过波峰、波谷或零值点的位置。因此，我们提取地震层位的问题转换成了在地震图像中寻找全局最小或最大路径（二维）或曲面（三维），并提出了一种基于改进的动态规划算法来解决这一问题。而且动态规划算法在高效地解决全局优化问题中有广泛的应用 (Cormen et al., 2001)。

图 2.5 展示了本文提出的基于动态规划的新方法在提取二维层位时的流程图。在该流程中，首先从一个初始的层位（图 2.5a 的黄色曲线所示）开始。该初始层位是由基于斜率的方法在一个控制点（图 2.5a 的红色圆圈）的约束下计算得到的，它接近于经过波谷（黑色）位置的目标层位，但是它追踪的相位并不足够准确，因此需要进一步的优化，尤其是在层位的右半部分表现更加明显。同时，在本文方法的计算流程中，初始层位只需要靠近目标层位，遵循大致的趋势即可，因此可以通过给定几个控制点，然后用简单的插值或者人工解释的方法轻易获得。在这之后，以初始层位为中心，选取一个较小的竖直窗（如图 2.5a 中的红色竖线表示）得到部分地震数据。同时，为了提高计算效率和准确度，选取的窗口在包含目标层位的前提下要尽可能的窄。图 2.5b 展示了一个以 21 个采样点为竖直窗的大小，选取的部分地震数据以初始层位为中心经拉平之后的效果。

在拉平的图 2.5b 所示的地震数据中，黄色箭头指示即将提取的目标层位。该目标层位从左至右经过最小值位置，即大部分的振幅波谷处，因此我们可以通过求解以下的全局最小值问题来提取目标层位：

$$E1 = \underset{j[i]}{\operatorname{argmin}} \sum_{i=1}^N g[i, j[i]],$$

$$\text{s. t. } |j[i+1] - j[i]| \leq \varepsilon (0 < \varepsilon < 1), \quad (2.5)$$

其中, i 和 j 分别代表水平和垂直方向的坐标轴, $j[i]$ 表示从左至右边的路径, $g[j, i]$ 为地震振幅图像 $a[i, j]$ 的函数, 定义如下:

$$g[i, j] = \begin{cases} a[i, j], & \text{层位位于波谷位置} \\ -a[i, j], & \text{层位位于波峰位置} \\ |a[i, j]|, & \text{层位位于零值位置} \end{cases} \quad (2.6)$$

在该定义下, 能够保证经过波谷、波峰或者零值点位置的层位均为输入图像 $g[i, j]$ 的最小值路径。

目标函数(方程 2.5)的第二部分代表计算路径过程中的斜率约束。在求解这个有约束的最小化问题中, 目的是找到一个目标层位作为全局最小路径, 从而使该路径上的振幅值的总和最小化。在拉平的地震图像中, 目标层应该是平滑的且几乎完全是平的。因此, 通常使用小斜率约束(例如, $\varepsilon = 0.25$)来寻找最优路径。为了解决这个有约束的非线性最小化问题, 本章使用了一种改进的动态规划算法(Hale, 2013), 包括非线性平滑、向前累积和向后跟踪三个步骤。

1. 非线性平滑

如图 2.5b 所示, 输入图像 $g[i, j]$ 中的中要拾取的最小路径并不明显, 很多局部低振幅值位置并不是目标层位的位置, 与期望提取的层位(图 2.5b 中黄色箭头所示)并不符合, 所以拾取最小路径仍然不是件简单的事情。为了进一步突出最小路径, 我们应用非线性平滑进行处理(Hale, 2013)来增强与最小路径对应的低振幅, 同时消除与路径无关的局部低振幅。非线性平滑是将正向和反向的非线性累积作用于输入图像 $g[i, j]$, 在斜率约束下 $|j[i+1] - j[i]| \leq \varepsilon$, 正向累积方程表达如下所示:

$$f[0, j] = g[0, j],$$

$$f[i, j] = g[i, j] + \min \begin{cases} f[i-d, j-1] + \sum_{k=i-d+1}^{i-1} g[k, j-1] \\ f[i-1, j] \\ f[i-d, j+1] + \sum_{k=i-d+1}^{i-1} g[k, j+1] \end{cases}$$

$$\text{for } i=1, 2, \dots, N-1 \quad (2.7)$$

其中, $f[i, j]$ 代表在每个样本在局部窗口中累积最小值的输出。 d 是最接近于 $1/\varepsilon$ 的整数, 决定了在每个样本点上寻找局部最小积累时的横向窗口的大小。类似地,

在斜率约束下 $|j[i-1] - j[i]| \leq \varepsilon$ ，反向累积的计算方程如下所示：

$$b[N-1, j] = g[N-1, j],$$

$$b[i, j] = g[i, j] + \min \begin{cases} b[i+d, j-1] + \sum_{k=i+1}^{i+d-1} g[k, j-1] \\ b[i+1, j] \\ b[i+d, j+1] + \sum_{k=i+1}^{i+d-1} g[k, j+1] \end{cases}$$

$$\text{for } i = N-2, N-3, \dots, 0. \quad (2.8)$$

无论是正向累积还是反向累积都可以看作是 $g[i, j]$ 分别在正向和反向方向上的平滑性效应。结合输入图像的正向和反向累积结果，可以得到一个双边非线性平滑结果，如下所示：

$$s[i, j] = f[i, j] + b[i, j] - g[i, j], \quad (2.9)$$

其中，方程中减去输入图像 $g[i, j]$ 项是因为它在正向和反向累积过程中计算了两遍。经过图 2.5b 中的非线性平滑后，可以得到平滑的输出图像（图 2.5c）其中最小路径（或目标层位）得到了显著增强，而远离路径的局部低振幅被抑制。因此，在图 2.5c 中拾取最小路径比在图 2.5b 中要简单得多。

2. 正向累积和反向追踪

为了从光滑后的图像 $s[i, j]$ 中选取最小路径，对 $s[i, j]$ 再次作用正向累积过程得到另一累积图像 $c[i, j]$ （图 2.5d），然后追踪最小路径 $j[i]$ ，计算如下所示：

$$j[N-1, j] = \underset{j}{\operatorname{arg\,min}} c[N-1, j],$$

$$l = j[i],$$

$$j[i-1] = \underset{l-1, l, l+1}{\operatorname{arg\,min}} \begin{cases} c[i-d, l-1] + \sum_{k=i-d+1}^{i-1} c[k, l-1] \\ c[i-1, l] \\ c[i-d, l+1] + \sum_{k=i-d+1}^{i-1} c[k, l+1] \end{cases}$$

$$\text{for } i = N-1, N-2, \dots, 1. \quad (2.10)$$

图 2.5d 中的绿色曲线显示选择的最小路径。最后，将选择的最小路径从拉平的空间域映射回原始空间，并获得最终的层位，如图 2.5e 中的绿色曲线所示。通过以上所述的二维层位提取的整个流程，可以高效地更新初始层位（图 2.5e 中的黄色曲线），使其更准确地追踪目标层位。图 2.2c 也展示了使用该流程来有效提取层位的另一个例子。

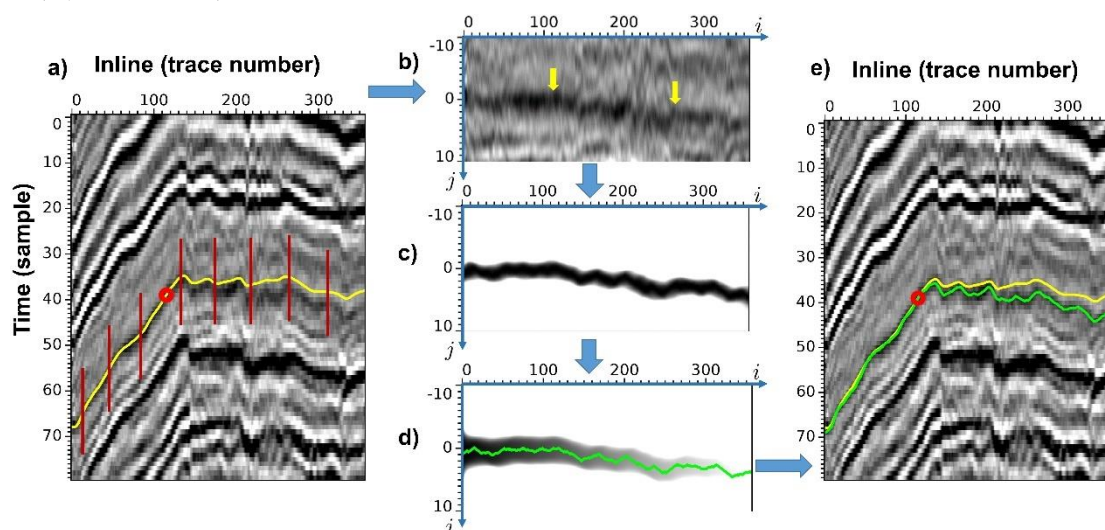


图 2.5 在二维地震图像中提取层位的工作流程图。步骤 1: (a) 首先选择一个控制点（红色圆圈）并计算一个初始层位（黄色曲线），然后选择一个以初始层位为中心的垂直窗口（竖直红线）。步骤 2: (b) 从窗口中提取一个子图像（窗口大小有 21 个采样点），并根据初始层位将其拉平。步骤 3: (c) 对拉平后的子图像进行非线性平滑，以增强待拾取的最小路径或目标层位。步骤 4: (d) 对平滑后的图像进行正向累积，并反向追踪最小路径（绿色曲线表示）。步骤 5: (e) 进一步将选取的最小路径从拉平空间域映射回原始空间，得到最终更新后的层位（绿色曲线），它比初始层位（黄色曲线）更准确，目标层位的相位更一致。

2.3.2 三维层位提取

由于动态规划算法本质上是一种二维算法，因此需要对其进行一些修改，使其适用于在三维地震图像中提取最小值曲面。图 2.6 展示了使用动态规划来提取三维地震层面的工作流程。与二维层位提取类似，本章再次从一个初始的层位开始（图 2.6a），该层位接近于目标层位，但其表面显著的振幅颜色的变化说明其仍然不够精确，相位跳跃现象严重。

图 2.6b 为根据初始层面拉平的三维地震幅值图像。在该拉平的地震图像中，目标层位变换为通过最小地震振幅的曲面，如中间红色部分所示。因此，我们可以通过求解以下带有斜率约束的最小化方程来提取目标层位 $j[i, k]$:

$$E2 = \underset{j[i,k]}{\operatorname{argmin}} \sum_{i=1}^N \sum_{k=1}^M g[i, k, j[i, k]],$$

$$\text{s. t. } |j[i+1, k] - j[i, k]| \leq \varepsilon \text{ and } |j[i, k+1] - j[i, k]| \leq \varepsilon, \quad (2.11)$$

其中, $g[i, k, j]$ 为公式 2.6 定义的输入地震幅值图像。 ε 是一个常数满足 $(0 \leq \varepsilon \leq 1)$, 它是在选取最小曲面 $j[i, k]$ 时作用在在 i 轴和 k 轴方向上的斜率约束。在拉平的地震图像内, 由于是以初始层位为中心的, 而且初始层位通常是接近于目标层位的, 所以目标层位应该是平滑的且大致是水平的。因此, 通常会选取一个较小的斜率值 (例如, $\varepsilon = 0.25$) 来约束在 i 轴和 k 轴方向上的计算过程。

由于地震图像中目标层位周围存在一定的噪声、不连续点和局部最小振幅, 直接从拉平的地震图像 (图 2.6b) 中自动提取目标层位仍然不是一件简单的事情。与计算二维图像中的最小路径类似, 本章节将二维非线性平滑过程 (公式 2.7) 应用于三维地震图像中的所有 $i-j$ 方向的切片, 得到了如图 2.6c 所示的结果, 其中目标层位显著增强, 特别是在 $i-j$ 方向的切片上。进一步对所有 $k-j$ 切片进行二维非线性平滑, 得到最终的光滑图像 (图 2.6d), 目标层位比原始地震图像 (图 2.6b) 显著增强。在此平滑后的图像上, 通过正向积累方程 2.6 和反向追踪方程 2.9 进一步计算最小值曲面。通过应用非线性平滑, 加上在 i 轴和 k 轴方向上的斜率约束, 能够确保两个方向的最小值曲面是光滑的。因此, 可以在 $i-j$ 剖面 and $k-j$ 剖面上选择二维最小路径, 形成一个一致的光滑曲面 (图 2.6e)。最后, 将选取的最小曲面从拉平的空间域映射回原始空间, 得到最终的更新之后的层位, 如图 2.6f 所示。由上述所提出的流程得到的层位面 (图 2.6f) 的颜色比初始的层位 (图 2.6a) 更加一致, 也表明了本文提出的方法在三维图像中提取的层位更加准确。

图 2.1c 和图 2.3c 的结果也分别证明了本文所提出的方法对人工解释和自动拾取层位进行改善的有效性。为了进一步分析其性能, 图 2.7 显示了从图 2.3 中提取的纵测线-深度方向上的 2D 切片视图。在图 2.7b 中, 基于动态规划方法得到的层位 (红色曲线) 比基于斜率的方法得到的层位 (绿色曲线) 的峰值路径更加一致。

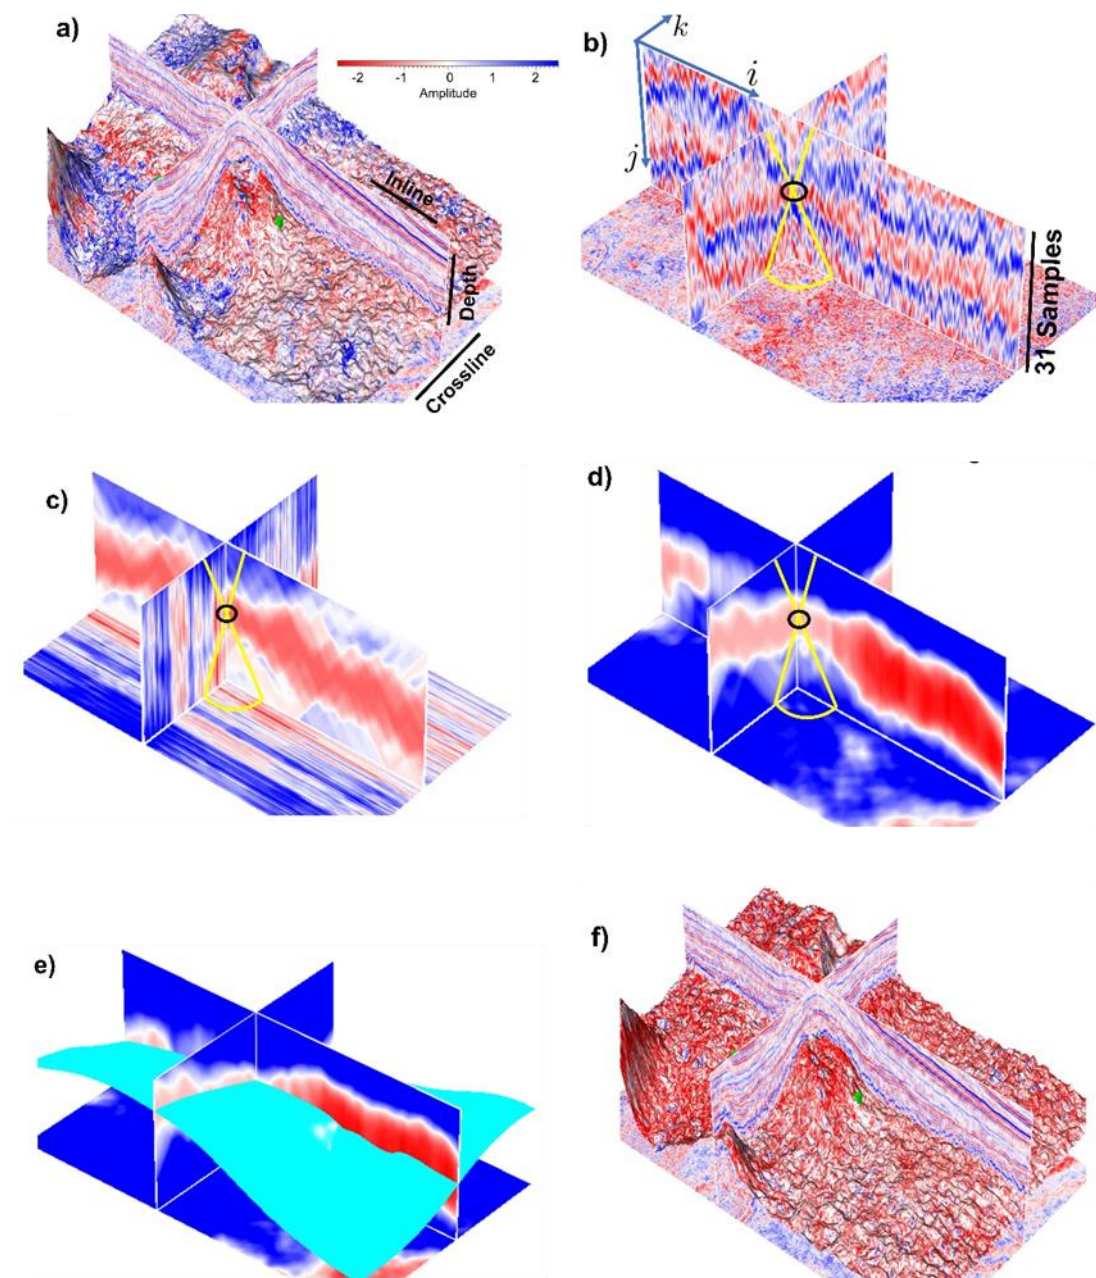


图 2.6 在三维地震图像中提取层位面的流程与二维地震图像的流程类似。步骤 1: (a) 首先选择两个控制点（绿色方块）并计算一个初始层位。步骤 2: (b) 选择一个以初始层位为中心的窗口，从窗口中提取一个子图像（垂直方向有 31 个采样点），然后根据初始层位面将其拉平。步骤 3: (c) 在所有 $i-j$ 剖面上应用二维非线性平滑来增强目标层位。步骤 4: (d) 在所有 $k-j$ 剖面上进一步应用二维非线性平滑，得到最终平滑的图像。步骤 5: (e) 对平滑后的图像进行正向累积，并反向追踪最小路径(青色曲面)。步骤 6: (f) 最后将选取的最小曲面从拉平的空间域映射回原始空间，得到最终更新之后的层位面（红色曲面）。此外，如果想要强制目标层位通过一个给定的控制点（如图 b-d 中的黑色圆圈），可以设置如图中的黄色线圈定的区域，然后将远离控制点的区域赋予最大值，控制点及其周围区域赋予最小值。

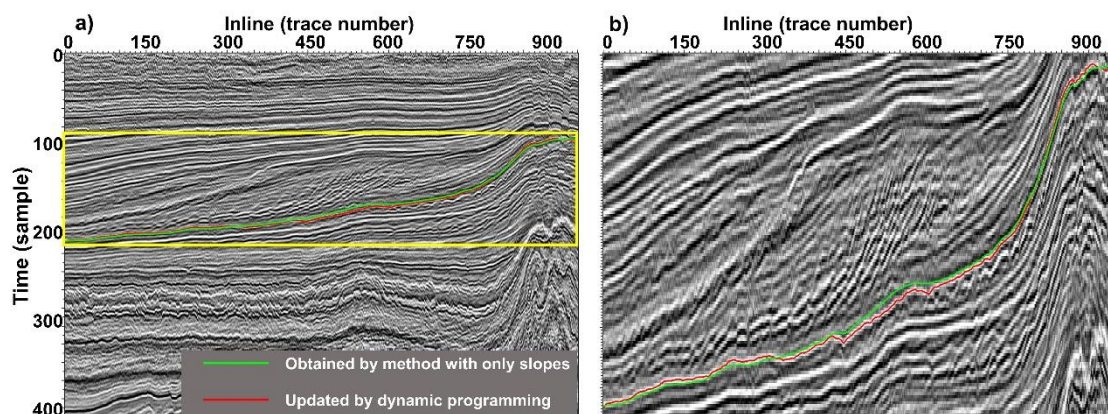


图 2.7 为了更清楚地查看图 2.3 中提取的层位面的局部细节，我们从图 2.3 中提取了一个 2D 的纵测线-深度方向上的地震剖面，如图(a)所示。绿色和红色曲线表示层位面与地震剖面的交点。图(b)为(a)中的黄色方框区域的放大图，可以观察到通过本文的方法获得的层位（红色曲线）比由基于斜率计算的层位（绿色曲线）的振幅峰值路径更加一致。

2.4 三维实例应用

为了进一步证明本文提出的方法的可行性，本章在另一个三维示例中进一步进行验证（图 2.8），并对仅基于斜率的方法 (Hale, 2009)、基于斜率和多重网格互相关的方法 (Wu et al., 2018) 和本文提出的基于动态规划的方法得到的结果进行了比较分析。

文中将本方法应用于 Wu 和 Fomel (2018) 文章中的相同数据。图 2.8 显示的是来自荷兰近海 F3 区块的三维地震数据，在纵测线(inline)、横测线(crossline) 和深度(depth) 方向上的样本大小分别为 951、550、242。该地震数据包含了复杂的构造，比如一个大断层（如图中白线所示）和明显的盐丘体。图 2.8 中的黄色和黑色箭头分别指示本章期望提取的第一个和第二个层位。

在图 2.9 中，在两个控制点的约束下（如绿色方块所示），本章使用上文提到的三种方法来拾取图 2.8 中的黄色箭头所指示的目标层位，期望选定的层位可以追踪一致的振幅波谷的位置，因此层位面应该显示一致的红色。结果表明，通过只有斜率的自动方法得到的层位（图 2.9a）的颜色明显不一致，说明其相位不一致，在波峰（蓝色）和波谷（红色）之间跳跃。这可能是因为该目标层位穿过许多小断层，但局部斜率并不能在断层的两侧追踪一致的反射轴。图 2.9b 显示了采用局部斜率和多重网格互相关的方法得到的层位。可以观察到该方法在大部分区域改善了结果。但是在图中黑色箭头所示的大断层附近仍然观察到一些颜色的

变化，即相位不一致。图 2.9c 显示了基于动态规划算法得到的结果，其中以图 2.9a 的结果作为初始层位。该结果几乎到处都呈现出红色，说明拾取的层位面能够遵循更加一致的波谷。除此之外，本方法的计算成本远远小于其他两种方法，这是因为本文提出的基于动态规划的方法可以用插值的算法来计算初始层位，从而取代了另外两种方法中计算斜率的步骤，可以大大的减少计算量（如表 2.1 所示）。

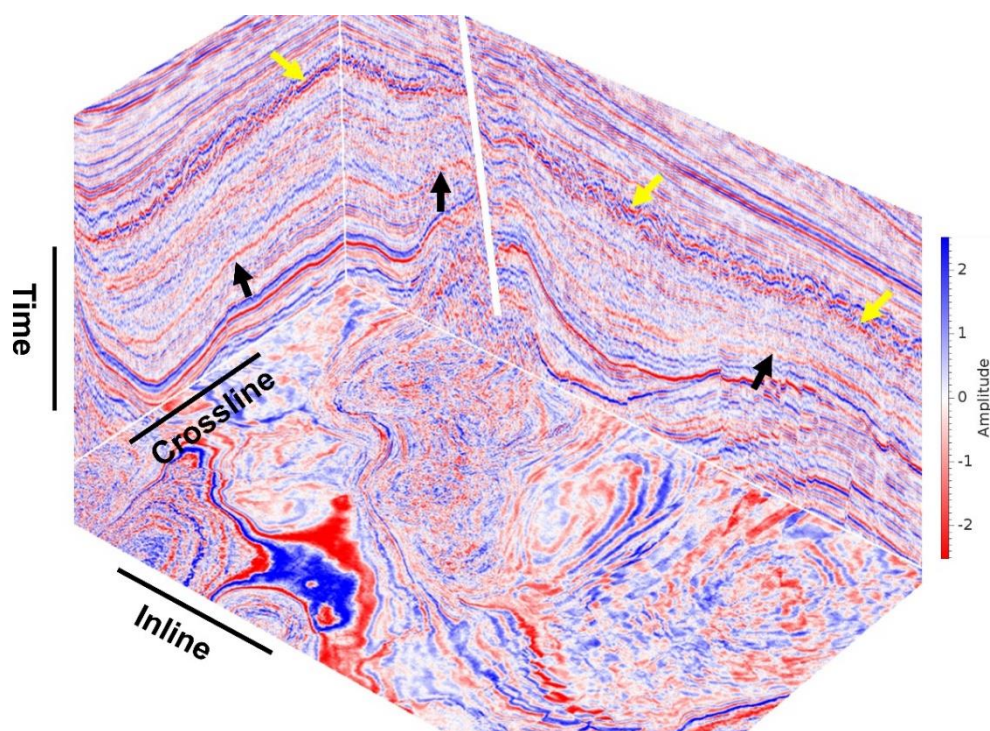


图 2.8 该三维地震图像包含多个断层，包括一个主断层（白线）和一些盐体。黄色箭头（指向波谷）指示第一个层位，显然该区域是不连续的，由一个大断层和许多个小断层组成。黑色箭头（指向波谷）指示第二个目标层，由于经过大断层和底部盐丘体而变得更加复杂。

在图 2.10 中，选择在四个控制点（绿色的方块）的约束下来拾取图 8 中的黑色箭头所指示的层位。该层位表现更为复杂，包括一个大断层（白线所示）和一些盐丘体。控制点位于振幅波谷处，所以准确的层位应该是到处都显示红色。然而图 2.10a 中所示的仅基于斜率的方法提取的层位，其表面的蓝色表明该结果不能遵循一致的相位，并不能跟踪正确的位置。图 2.10b 是基于局部斜率和多重网格互相关的方法得到的结果，可以看到其表面几乎都是红色的。同理，图 2.10c 中基于动态规划方法得到的层位也表现出一致的相位。这表明，图 2.10b 和图 2.10c 中的两种方法都可以经过断层和盐丘体等复杂结构时均可获得比较准确的结果。

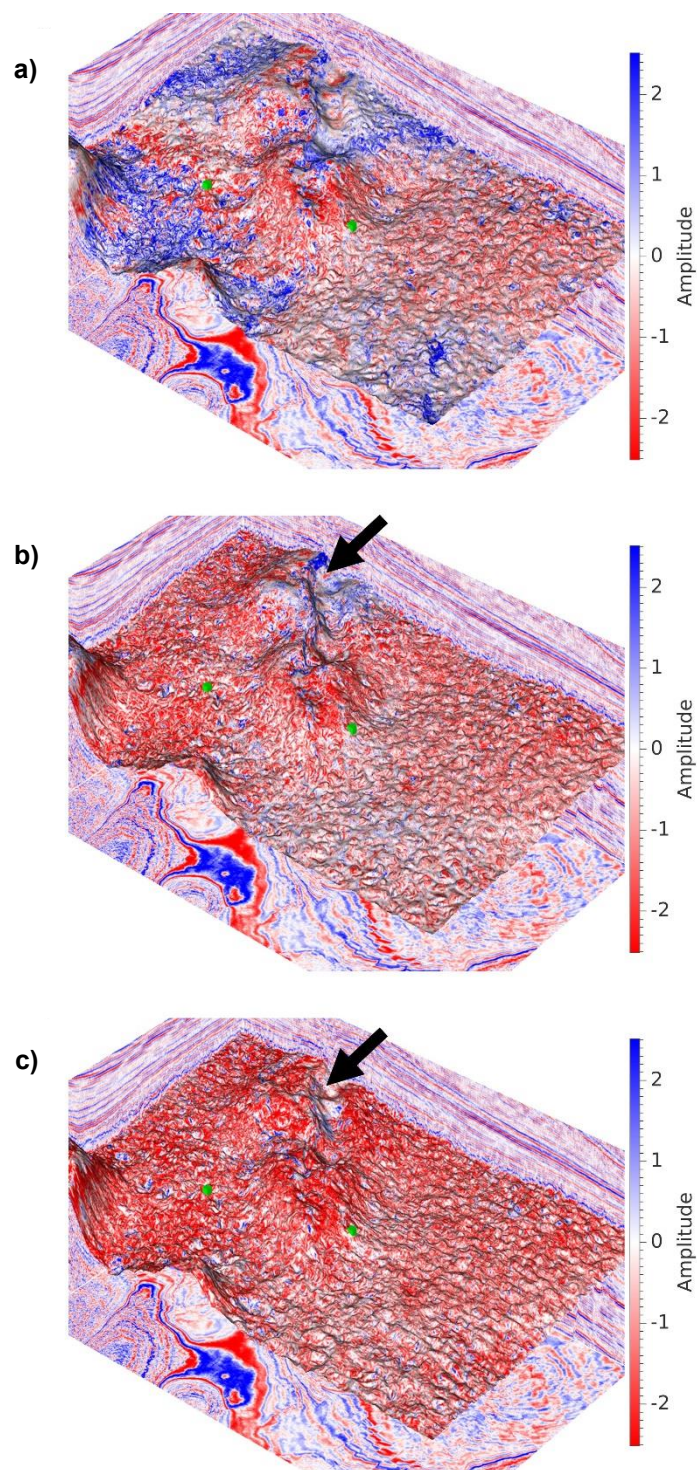


图 2.9 三种方法的对比。在三维图像（图 2.8）中用不同的方法提取第一个层位，包括 (a)只有斜率的方法，(b)局部斜率和多重网格互相关的方法，(c)基于动态规划的方法。在不同的方法中均使用两个控制点（绿色方块）。c 图所示的层位面的颜色更加统一表明其比 a 和 b 的结果遵循更一致的波谷相位。

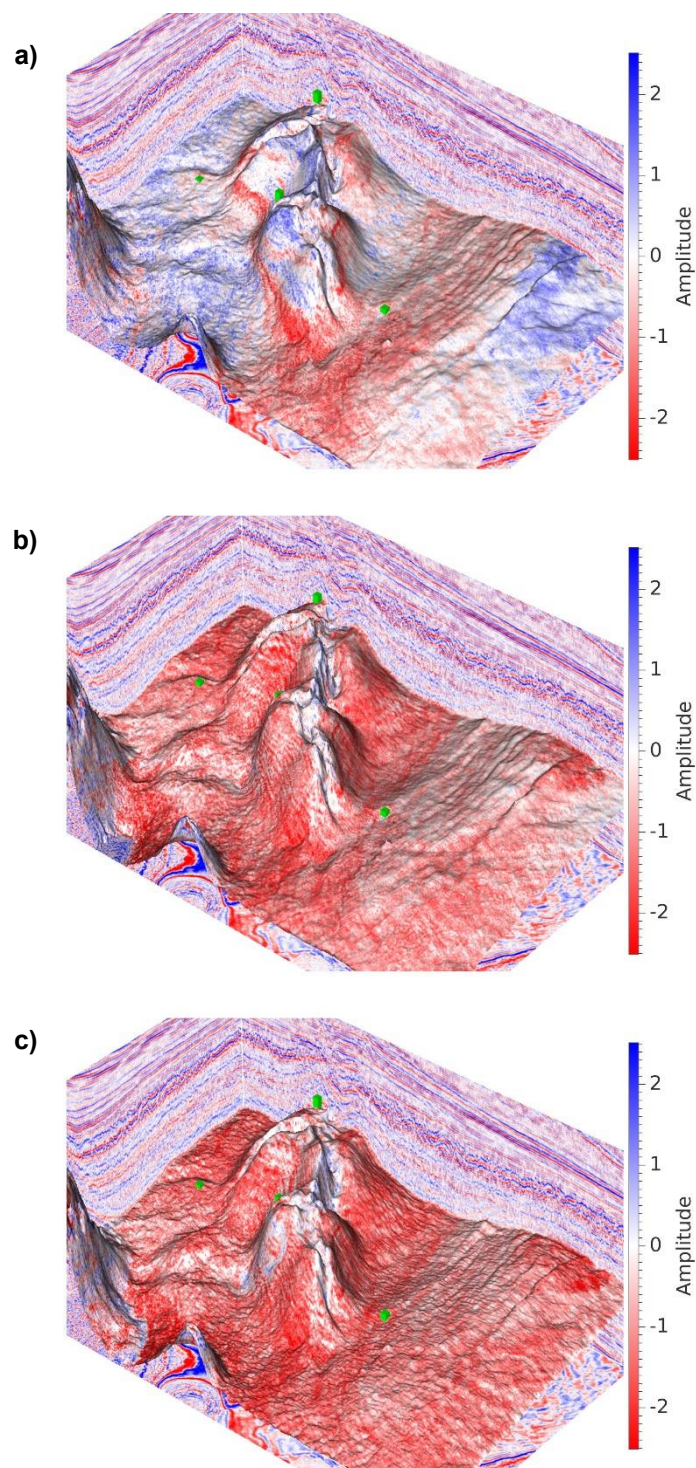


图 2.10 三种方法的对比。在三维图像（图 2.8）中用不同的方法提取第二个层位，包括(a)只有斜率的方法，(b)局部斜率和多重网格互相关的方法，(c)基于动态规划的方法。在不同的方法中均使用四个控制点（绿色方块）。(b)和(c)中的两种方法表现出了相当的性能，相比于(a)中的方法，得到很大改善，均能拾取更加准确的层位。但是(c)方法的计算效率更高。

表 2.1 显示了三种提取层位的方法（图 2.9 和 2.10）在计算成本方面的定量对比分析。该图表表明，本文提出的基于动态规划的方法比基于斜率的方法快 2 倍，比多重网格互相关的方法快 6 倍，因为这两种方法都需要迭代求解大型非线性方程组，所以比较耗时。然而，在本文提出的方法中，使用简单快速的线性插值方法代替上述步骤来获得初始层位，然后通过改进的动态规划算法来更新初始层位，一样可以产生与其他两种方法相当甚至更好的结果(如图 2.9 和 2.10 所示)，但是它在计算时间上减少很多。

表 2.1 本章提到的三种方法的计算时间的对比。

Methods	Slope calculation	Horizon 1	Horizon 2	Total time
Only slopes	73.1 s	31.07 s	41.92 s	146.09 s
Local slopes and multigrid correlations	73.1 s	108.54 s	152.53 s	334.17 s
Dynamic programming	—		32.59 s	44.91 s

2.5 本章小结

2.5.1 讨论

1. 初始化

本文提出的方法包括两个步骤: (1)计算初始层位和(2)用动态规划算法更新初始层位。对于第一步，一种稳定的方法是利用上述的基于斜率的方法来获得初始层位。然而，这类方法需要计算反射轴斜率并迭代求解庞大的非线性系统（特别是三维数据体），因此往往是非常耗时的。基于动态规划的方法只需要一个近似的初始层位，能够遵循大致的结构趋势，所以可以使用更高效的插值算法（如三次插值或线性插值）来快速获得初始层位。

图 2.11 中的两个例子中比较了两种初始化方法的有效性。图 2.11b 和图 2.11e 中的初始层位是通过基于斜率的方法（黄色曲线）和三次插值算法（绿色曲线）到的。在第一个例子中（图 2.11a、2.12b、2.12c），图 2.11c 中由两种不同的初始层位得到的结果几乎是完全重合的。第二个例子（图 2.11d、2.12e、2.12f）有明显的断层，但图 2.11f 中的结果表明无论是由插值算法（绿色曲线）还是基于斜率的方法（黄色曲线）得到的初始层位经本文提出的方法迭代更新之后都能得到较好的结果。尽管与基于斜率的方法相比，插值算法可能需要更多的控制点来计算一个合理的初始层位，但它仍然能够显著降低计算成本，并为解释人员实现交互操作提供了便捷。

2. 控制点

在前面章节讨论的所有例子中，控制点作为一个关键的约束条件，在提取目标层位时起着重要的作用。特别是在传统的基于斜率的方法中，层位一定会穿过这些控制点，所以要求这些控制点尽可能的精确。本文所提出的新方法在第一个初始化步骤中也需要一些控制点，因此在这里我们比较了控制点对图 2.12 和图 2.13 中提到的两种方法的影响。

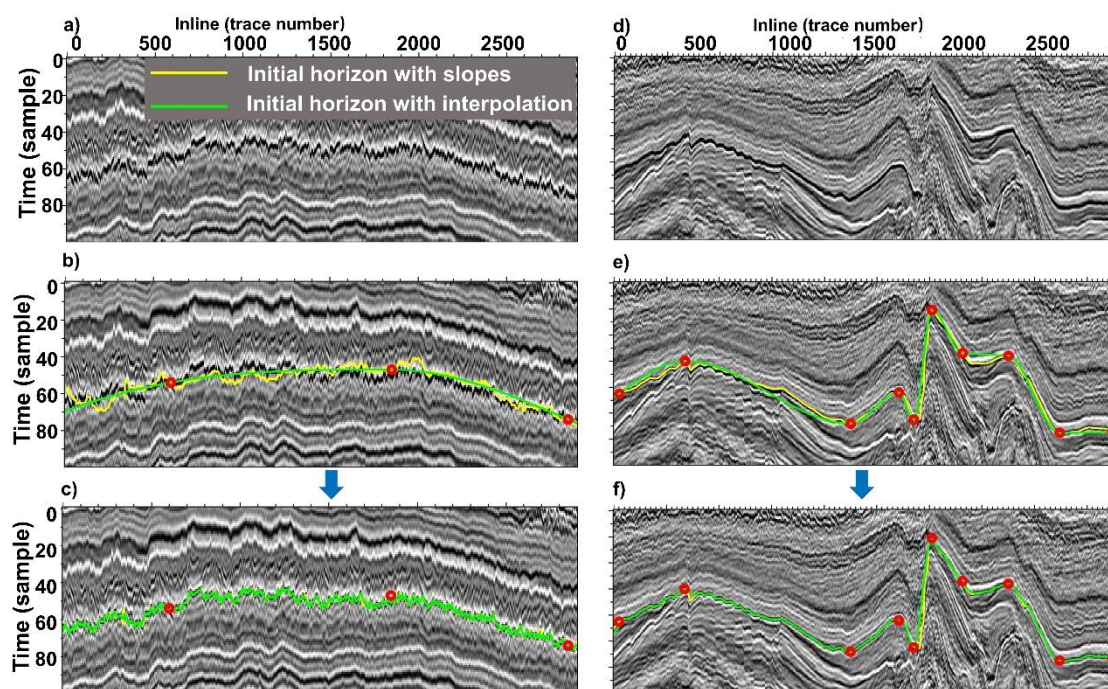


图 2.11 两种初始化层位的方法的比较。在输入二维地震图像(a 和 d)中，分别采用基于斜率的方法（黄色曲线）和插值算法（绿色曲线）计算初始层位。(c)中的结果表明，该方法通过两种初始化方法都能准确地获得最优路径。(f)中采用插值法（绿色曲线）得到的结果与采用基于斜率法（黄色曲线）得到的结果也几乎相同。基于斜率的方法需要估算反射轴的斜率和求解庞大的非线性系统，这往往比插值方法更耗时。尽管插值算法可能需要更多的控制点（红色圆圈）以获得合适的初始层位，特别是在 3D 数据中，但它本身是简单和快速的，因此仍然能够显著地降低计算成本。

在实际中，我们希望选择尽可能减少控制点的数量，以降低人为的工作量。因此，本章首先测试控制点数量对两种方法的影响。在图 2.12 中，分别选取 1 个、3 个和 5 个控制点，分别采用基于斜率的方法（图 2.12a-c）和本章提出的新方法（图 2.12d-f）提取目标层位。与基于斜率的自动方法相比，本文提出的新方法在可以获得相位一致的更准确的层位，尤其是在蓝色箭头所指示的区域。此外，还发现提出的新方法（图 2.12d）在只有一个控制点的情况下，可以达到与图

2.12e 和 2.13f 相当的性能。也就是说，基于动态规划的算法可以跟踪更一致的相位从而获得准确的层位，同时又可以减少控制点的数量进而提高工作效率。

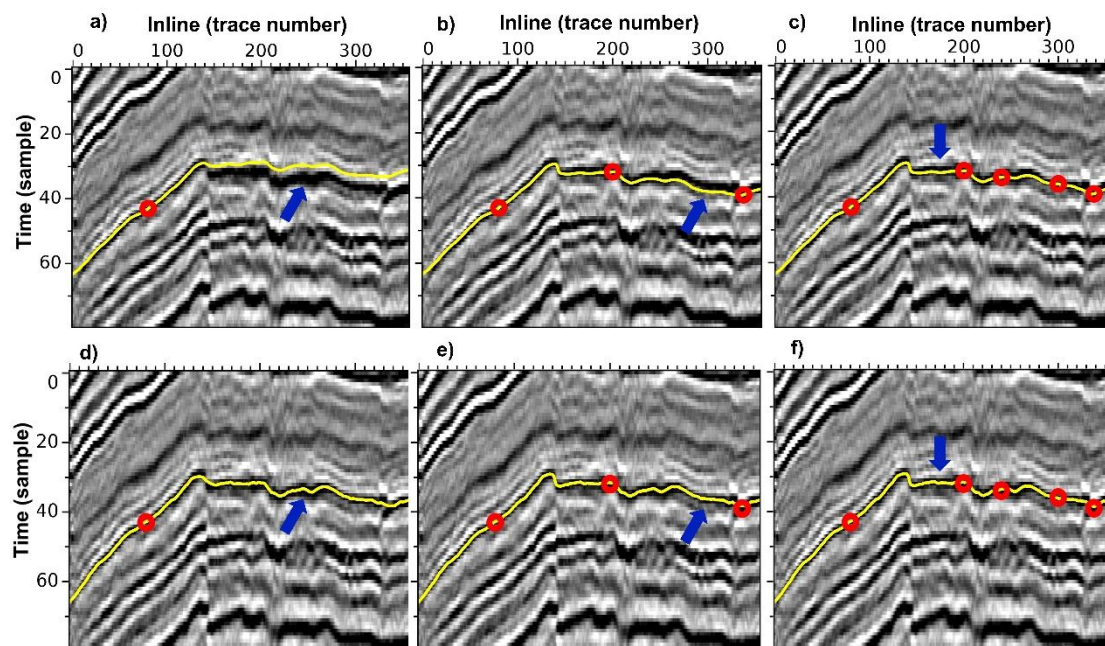


图 2.12 探究控制点数量的影响。分别选取 1 个、3 个和 5 个控制点（红色圆圈），采用基于斜率的方法(a-c)和基于本文提出的方法(d-f)提取目标层位。与基于斜率的方法相比，动态规划方法可以获得相位一致的更准确的层位，特别是在蓝色箭头所表示的区域。并且本文的方法在(d)中只需要一个控制点就可以达到与 e 和 f 相当的性能，这表明可以通过减少控制点的数量来提高效率。

更重要的是，在新方法中选择控制点是比较方便和高效的，因为这些点只需要靠近目标层位，而不需要精确的位于层位上。在图 2.13 中对这一点进行了更加详细的说明。该例子中选择了三个控制点，其中紫色箭头所指示的两个明显没有位于目标层位上（图 2.13a 中的蓝色箭头指示目标层位）。在这些控制点的约束下，基于斜率的方法得到的结果如图 2.13a 中的黄色曲线所示，显然计算的层位是错误的。然而，新方法却仍然可以准确地跟踪目标层位，得到如图 2.13b 所示的结果，从结果分析可知，以简单的线性插值（图 2.13a 中的绿色曲线）或基于斜率的方法（图 2.13a 中的黄色曲线）的结果作为初始层位，然后用本文所提出的新方法均能有效地改善结果，得到更加准备的层位。这表明，即使控制点偏离目标层位的，本文提出的方法也能获得合理的结果，这是因为该方法不强迫层位必须通过所选的控制点。

换句话说，本章提出的新方法对控制点不敏感，它只需要一个粗略的初始化值，这大大提高了地震层位解释的效率和方便性。当然，如果需要强制层位通过

某些点，可以将控制点通过一定的方法设置为强约束条件（如图 2.6 所示）。

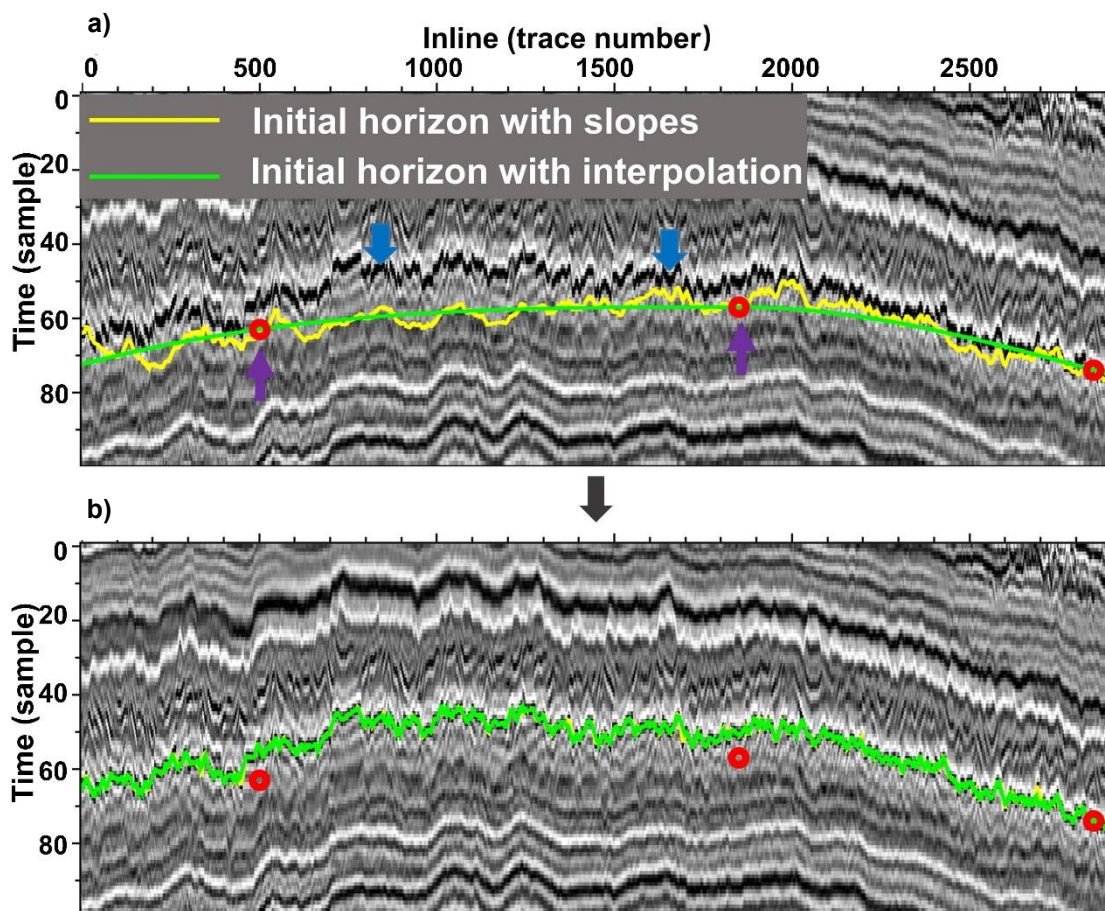


图 2.13 探究方法对控制点的敏感度。控制点（红色圆圈）是人工选择的，因此具有很高的主观色彩。这里给出三个控制点，包括两个错误的控制点（用紫色箭头指示）。(a) 中黄色曲线为基于斜率的方法提取的层位，绿色曲线为基于控制点插值的结果。(b) 图为将(a)中的插值结果（绿色曲线）或基于斜率的方法（黄色曲线）的结果作为初始层位，更新之后得到的最终结果。这表明，即使有控制点不位于目标层位上，本文提出的方法依然可以获得合理的结果。

3. 窗口的选择

在图 2.5 和图 2.6 中描述的拾取层位的工作流程中，需要选择一个合适的窗口来提取子图像。窗口的选取是另一个直接影响结果的关键因素。由于本章提出的方法是通过搜索全局最大值或最小值来寻找目标层位的，因此选择的窗口在垂直方向上应该包含目标层位，并确保目标层位是窗口内的最小值路径。同时，为了更好地提高效率和精度，在满足窗口包含目标层位的前提下，窗口应该尽可能的小。

在一些例子中,如果目标层位与周围的一些层位之间在深度方向上靠的比较

近而且与周围的振幅值大小基本相当,这是需要我们非常小心的去选择一个合适的尽可能窄的窗口,也可以如图 2.6b-d 所示加一些强约束条件。在本研究中,只使用了地震振幅属性来提取层位。然而,该方法并不仅仅局限于使用振幅属性,也可以使用其他的属性(比如波形相似度等)作为输入,以获得最佳结果。而且使用波形相似度代替地震振幅属性,可能有助于处理层位分布密集的情况。

在处理层位不连续点较多或者竖直方向位移较大的情况下,例如有大断层时,可以选择更多的控制点来约束靠近断层的目标层位。从而可以获得一个更合理的初始层位来选择一个更合适的窗口。然而由于根据控制点插值的算法非常快,所以增加控制点也不会加大计算成本。

4. 准确度和稳定性的评估

这里使用一个二维的例子来进一步评估本文所提出的方法对噪声的鲁棒性。本章中手动拾取了 6 个层位作为真实的层位位置,如图 2.14b 中的黄色曲线所示。这些层位经过图中标示的三个断层,并不非常复杂,但对层位的自动提取仍然是一个挑战。模拟不同程度的噪声,并将它们添加到原始图像(图 2.14b)中。图 2.14c-g 的信噪比(S/N)分别为 20、8、4、1 和 0.75dB。在这些图像中,均选择相同的控制点(红色圆圈)参与计算。从结果中可以观察到,随着信噪比的减小,除了红色箭头所示的几个区域外,新方法仍然可以得到合理的结果。另外如图 2.14h 所示,这些红色箭头所示区域的层位可以通过增加控制点来提高准确度。与基于斜率的方法相比,新方法在蓝色箭头所示的区域获得了更准确的结果,并且在通过断层时可以遵循更一致的相位(图 2.14c 中的黄色矩形)。

在图 2.15 中,进一步定量地评估了其准确性。图 2.15a 和图 2.15b 中的实线和虚线分别代表基于动态规划法和基于斜率法的误差。其中利用方程(2.10)计算误差:

$$E = \frac{\sum_{j=1}^N |Z_{true}[i] - Z_{cal}[i]|}{N} \quad (2.12)$$

其中 N 为每个层位的采样点数, Z_{true} 为目标层位的真实位置, Z_{cal} 为基于斜率的方法或提出的基于动态规划方法计算得到的层位。误差来源主要受断层(如层位 1、5、6)和噪声(如层位 4)的影响。这些误差曲线也再次表明,与基于斜率的方法相比,新方法在经过断层区域得到的结果更准确,对噪声有更强的鲁棒性。

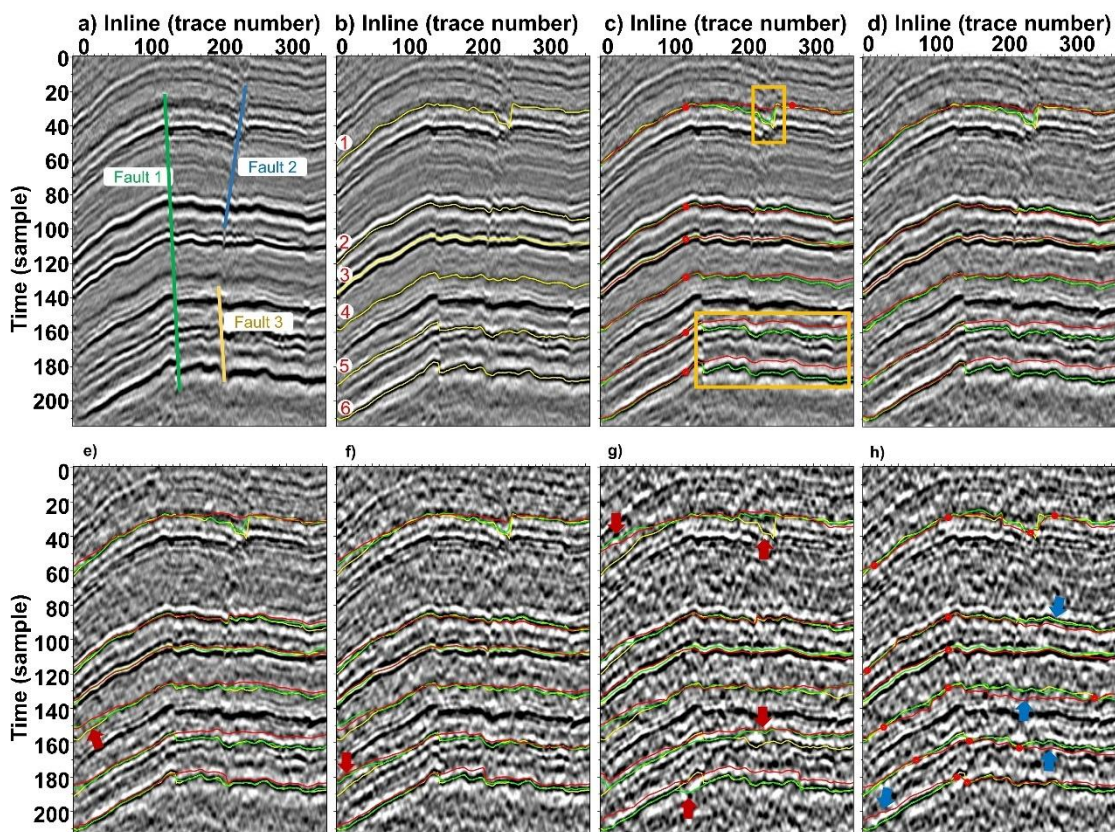


图 2.14 不同程度的噪声的影响。(a)输入图像有三处明显断层。(b)手动选取 6 个层位 (黄色曲线)作为真实的层位位置。分别用基于斜率的方法 (用红色曲线表示) 和动态规划 (用绿色曲线表) 计算这些目标层位。(c-g)中的信噪比 (S/N) 分别为 20、8、4、1 和 0.75dB, 但具有相同的控制点。(h)图像的噪声与(g)相同, 但是在计算过程中具有更多的控制点 (红色圆圈)。

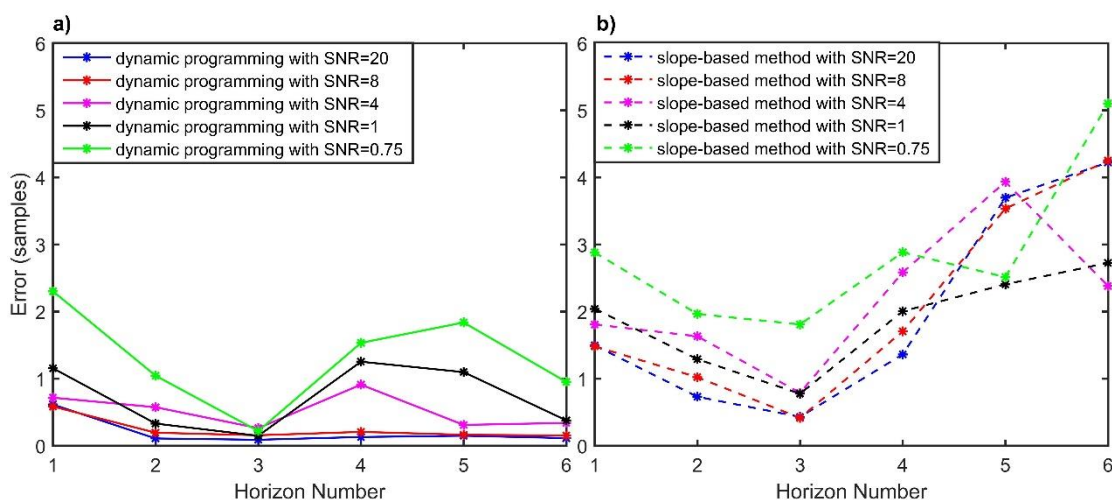


图 2.15 在不同程度噪声的影响下, 本文提出的新方法(如[a]所示)通常会比基于斜率的方法(如[b]所示)得到的结果的误差更小。

2.5.2 结论

本文提出了一种基于动态规划算法从地震图像中搜索全局最优路径（二维）或最优面（三维）的全新方法，该方法不仅在计算上高效，而且在经过断层时仍能够获得准确的相位一致的层位。

在本方法中，首先选择一定数量的控制点，可以通过人工解释，或者自动方法，或插值算法来计算一个初始层位。该初始层位只需要一个与目标层位相接近的位置，可以遵循大致的结构趋势。因此，我们建议使用插值方法来获得初始层位，这通常比自动提取方法（如基于斜率的方法）更有效。然后，使用动态规划算法来更新初始层位，使之更加精确，并揭示更详细的地质构造。在这一过程中，需要以初始层位为中心选择一个合适的竖直窗口，并根据初始层位拉平所选择的图像。在这张拉平的部分地震图像中，使用动态规划算法有效地选择最小值路径（二维）或最小值曲面（三维）。最后，将该路径或曲面从拉平的空间域映射回原始空间，以获得最终更新的层位。

与目前广泛使用的基于斜率的方法相比，本文提出的方法可以更一致地跟踪相位，揭示详细的构造（如通道），并在经过断层时表现出有效性。除此之外，该方法也只需要少量的控制点，对控制点不敏感，可以高效、方便地进行层位解释。在一些复杂的区域，可以强制加入一定的控制点作为强约束条件，以取得更可靠的结果。

本文提出的方法是一种全新的方法，不依赖于其他已发表的方法。所展示的实例表明，该方法可以有效地提高计算效率和对噪声的鲁棒性。因此，它适合作为一种人工交互式的方法来实现，以便在编辑控制点的同时快速更新层位。此外，该方法也可以用于改进其它的全自动工作流程（例如，体斜率估计和相对地质时间体的计算）。

在本研究中，使用地震振幅图像作为输入，通过假设一个层位遵循一致的相位或振幅值来提取层位。然而，一些复杂的情况下，相位可能沿着层位发生改变，此时这个假设不一定是成立的。在这些情况下，可能需要使用一些其它更合适的地震属性代替振幅属性。在新属性中，目标层位可以被转换成全局最大或最小路径（二维）或曲面（三维）。此外，本章的方法一次只能从地震图像中提取一个单一的层位，因此在后续的研究中将考虑改进方法来实现可以一次同时提取多个层位的目的。

第3章 相对地质年代体引导的储层参数建模

3.1 引言

从地震数据和测井数据建立准确的地下模型对储层预测至关重要 (Lemon et al., 2003; Zhu et al., 2012; Wu, 2017a), 地震数据可以提供地层特征和地质构造信息, 而测井数据可以提供地震所没有的高分辨率的深度方向的岩石属性信息。传统方法使用地震结构和测井测量值来建立模型。其中一些方法以几个层位和主要断层作为地下构造的约束条件来建模 (Mallet, 2002; Caumon et al., 2009; Bakulin et al., 2010)。其他的一些方法则使用图像引导的插值方法, 根据地质信息和测井数据获得地下模型 (Hansen et al., 2008; Hampson et al., 2000; Hale, 2010a; Naeini et al., 2015; Karimi et al., 2017)。此外, 有一些学者提出基于体技术的方法, 整合层位、断层和不整合面来获得合理的地下模型 (Jayr et al., 2008; Souche et al., 2013; Dorn, 2013; Souche et al., 2014; Mallet, 2014; Labrunye et al., 2015; Wu, 2017a)。

本文中则使用相对地质年代体引导的地质建模方法来获得初始的储层参数模型, 具体流程为: (1) 从地震数据中提取一定数量的层位面; (2) 根据获得的层位进一步计算相对地质年代体 (RGT), 其能隐含地代表地震构造和地层特征; (3) 结合测井信息和 RGT, 利用基于 RGT 导向的插值方法, 插值得到一个储层参数模型, 该模型能够遵循地震地层学特征并符合测井的属性。本章节中以公开的 Teapot Dome 数据为例 (Anderson, 2009), 说明储层参数建模的过程。

3.2 方法理论

3.2.1 地震构造导向的插值方法

利用空间内稀疏分布的数据插值得到整个空间域的结果是地球物理领域常见的问题。Hale (2009) 提出了一种地震构造导向插值方法, 并成功应用于地震和测井数据中 (Hale, 2010a,b)。该方法与自然邻域插值方法 (Sibson, 1981; Sambridge et al., 1995; Bobach et al., 2006) 类似, 均是对最近邻插值进行平滑, 且平滑程度随着到最近的已知采样点的距离的增加而增加。这为解释地震图像时, 提供了一种新的、更直接的方式来插值这些离散的数据 (如测井数据)。其求解过程分为两步, 具体如下:

对于已知的 k 个位置 $L = x_1, x_2, x_3, \dots, x_k$, 对应的值为 $F = f_1, f_2, f_3, \dots, f_k$, 构建方程 $q(x)$ 满足 $q(x_k) = f_k$, 其中 x 为整个空间的任意一点, 要求 $q(x)$ 是

光滑有界的，而且计算效率高的。首先根据结构张量 $S(x)$ (Van Vliet et al., 1995) 计算一个度张量场 $D(x)$:

$$\mathbf{D}(x) = \frac{\mathbf{S}^{-1}}{1 - c(x)}, \quad (3.1)$$

其中， $c(x)$ 是利用 Fehmers and Hocker (2003) 提出的方法从结构张量 $S(x)$ 计算出的衡量其相干性的量。

然后分两步求解，步骤 1，求解程函方程：

$$\begin{aligned} \nabla t(x) \cdot \mathbf{D}(x) \nabla t(x) &= 1, x \notin L; \\ t(x) &= 0, x \in L, \end{aligned} \quad (3.2)$$

其中， $t(x)$ 表示从任意 x 点到最近的已知点 x_k 的最短时间 (这里的时间表示非欧几里得距离)。

在步骤 1 中，通过求解方程式 (3.2) 的有限差分近似来计算时间场 $t(x)$ ，可以利用类似于 Jeong 等人提出的迭代算法求解 (Jeong et al., 2007)，或者其他算法，比如快速匹配法的变体 (Sethian, 1999; Sethian et al., 2003; Konukoglu et al., 2007) 和扫描法 (Tsai et al., 2003; Zhao, 2005; Qian et al., 2007, Detrixhe et al., 2013)。但是必须注意正确处理该方程式中的各向异性系数和非均匀系数时的 $\mathbf{D}(x)$ ，要特别注意邻近垂直的断层附近时的计算。

步骤 2，利用迭代的共轭梯度求解以下方程的有限差分近似得到最终的插值 $q(x)$:

$$q(x) - \frac{1}{2} \nabla \cdot t^2(x) \mathbf{D}(x) \nabla q(x) = p(x), \quad (3.3)$$

其中， $q(x)$ 表示地震构造导向插值。

3.2.2 RGT 引导的插值方法

传统上的插值算法经常以层位为导向 (Hampson et al., 2001; Pedersen Tatalovic et al., 2008; Huck et al., 2010)，但是这类方法存在一个问题，由于它是由解释的层位导向的，所以插值得到的值仅与提取的层位所在位置相一致，而对于层位面之间的结构细节无法恢复。另一方面，由图像引导的插值技术可以得到符合地震结构的结果，然而在地质条件复杂、质量低或者井较少的情况下，此类方法也不能得到较好的效果。因此，Nacini 等人 (2015) 提出了一种图像和层位共同导向的插值算法，但也存在一定的缺陷，比如使用地震图像结构指导测井曲线插值，缺少地震振幅属性参与估算和预测井间岩石特性。除此之外，这些方法有一个共同的特征，就是需要求解一个庞大的非线性方程组，所以计算量大，且耗时。

在本文中，我们使用 RGT 导向的插值算法获取地下储层参数模型。图 3.1 展示了该方法的基本思路，首先从给定的地震图像中提取一些层位，然后根据解释的层位计算相对地质年代体（RGT）。由于 RGT 的每一点代表与地震图像的采样点相对应的相对地质时间，因此 RGT 体就可以隐含地代表着地震构造和地层特征。结合 RGT 和测井的信息，利用 RGT 导向的插值算法外插得到储层参数模型。该方法最大的优点就是计算快，大大节约时间成本。

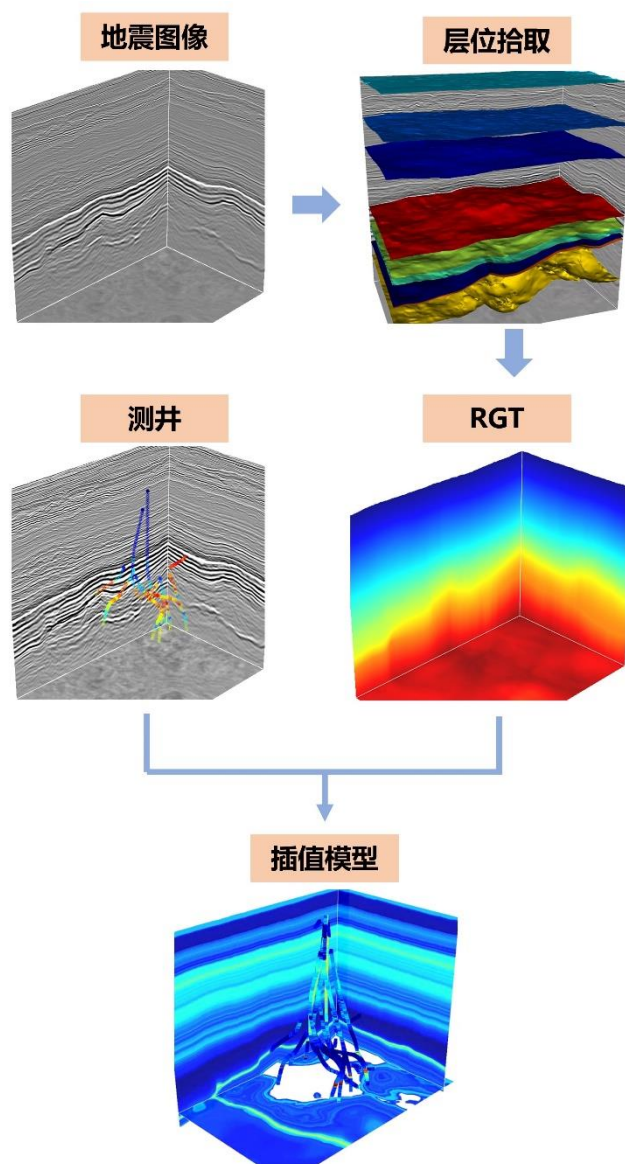


图 3.1 RGT 导向的储层参数建模的基本思路。首先从地震图像中提取层位，然后根据解释的层位计算（RGT），最后结合 RGT 和测井的信息，利用 RGT 导向的插值算法外插得到储层参数模型。

3.3 实例应用

3.3.1 层位的提取

如图 3.2 所示, 在 Teapot Dome 的三维地震图像中(图 3.2a), 已经提供有五个层位面(图 3.2b), 但这些层位不完整, 有一些缺失的地方, 可以利用第二章中提到的基于动态规划的自动方法快速更新这些层位, 使其更加完整, 也更符合地震图像的构造, 也可以追踪更多的层位, 以便为了能够更准确的计算相对地质年代体。

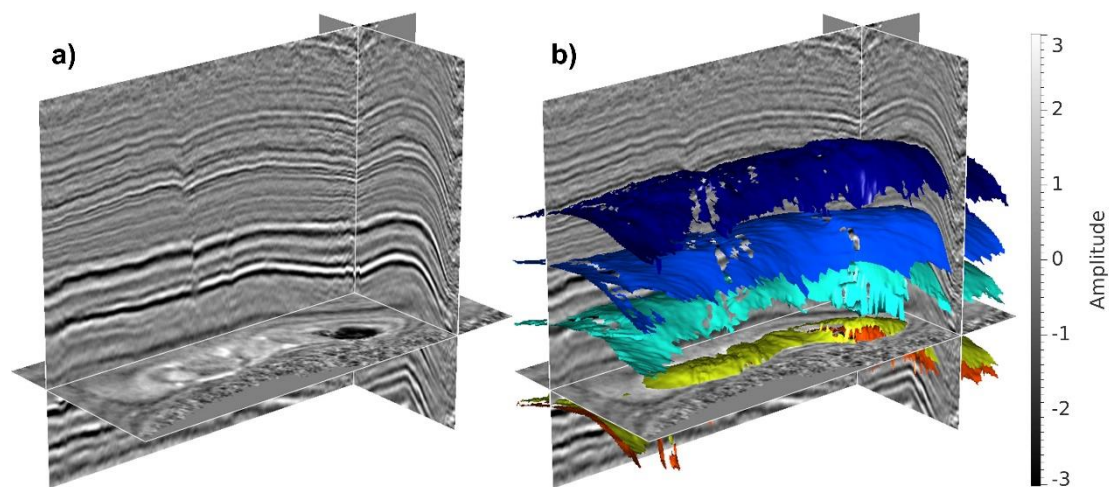


图 3.2 Teapot Dome 数据。(a) 三维地震图像；(b)与地震数据一致的五个层位面。

3.3.2 RGT 的计算

Stark (2003, 2005b)提出了相对地质年代体(RGT)的概念和其产生方法。RGT 表示与地震数据采样相对应位置的地质时间。生成 RGT 最简单的方法是从几个层位和地震数据中插值产生 (Stark, 2005a)。因此, 本章首先对提取的每个层位(图 3.2b)定义一个相对地质时间, 然后利用三次插值算法计算层位之间的 RGT 值, 就可以得到如图 3.3 所示的相对地质年代体, 它可以被看作是代表着地震构造和层序特征的隐式构造模型。

3.3.3 RGT 导向建模

根据已有的相对地质年代体(RGT)和测井数据, 以 RGT 为导向, 利用径向基函数(Dyn, 1987; Carr et al., 1997)来获得储层参数模型 $q(x)$:

$$q(x, y, z; \tau(x, y, z)) = \frac{1}{\sum_{i=1}^k \varphi_i} \sum_{i=1}^k w(x_i, y_i, z_i(\tau)) \varphi_i, \quad (3.4)$$

其中, k 为已知空间点的个数, ω 表示物性参数, 比如速度、密度、伽马等, τ 为RGT, φ_i 为反多维二次函数, 表达式如下:

$$\varphi(i) = \frac{1}{1 + \sqrt{(\varepsilon^2((x_i - x)^2 + (y_i - y)^2))}}, \quad (3.5)$$

ε 表示径向基函数的尺度因子。

首先在测井位置处对 RGT 数据进行插值, 然后根据距离的大小计算权重, 距离越远平滑程度越大, 然后从多个测井数据外插得到整个空间内的模型, 如图 3.4, 3.5 所示, 并将地震构造导向插值方法(Hale, 2019)和 RGT 引导的插值的方法的结果进行了对比。




图 3.3 根据地震数据和提取的层位插值得到的相对地质年代体(RGT)。

图 3.4 和图 3.5 分别展示了已知速度测井和密度测井, 利用地震构造导向的

插值方法和 RGT 引导的插值的方法得到速度和密度模型。从两组对比结果分析可知，地震构造导向的插值方法得到的结果更平滑，而基于 RGT 插值得到模型的垂向分辨率更高，能够突出细节构造。

为了更好的展示其结果，本章中从图 3.4 中随机抽取了一组二维剖面，图 3.6 展示了两种插值方法的二维剖面图。图 3.6b 为对应的地震构造导向的插值方法的结果，整体表现出平滑的特征，在白色箭头所示的位置由于断层的影响导致插值结果不准确。而图 3.6c 对应的 RGT 引导的插值结果，在白色箭头所示的断层位置，仍有较好的效果，且垂向分辨率较高。图 3.7 所示的两种插值方法在测井位置处的结果也再次证明了这一结论。与地震构造导向的插值方法方法的结果（蓝色实线）相比，RGT 引导的插值结果（红色实线）与真实测井曲线（黑色实线）的一致性更高，尤其是在蓝色箭头所指示的地方，尽管有许多变化的薄层，但是 RGT 引导的方法仍能一定程度上恢复出细节。

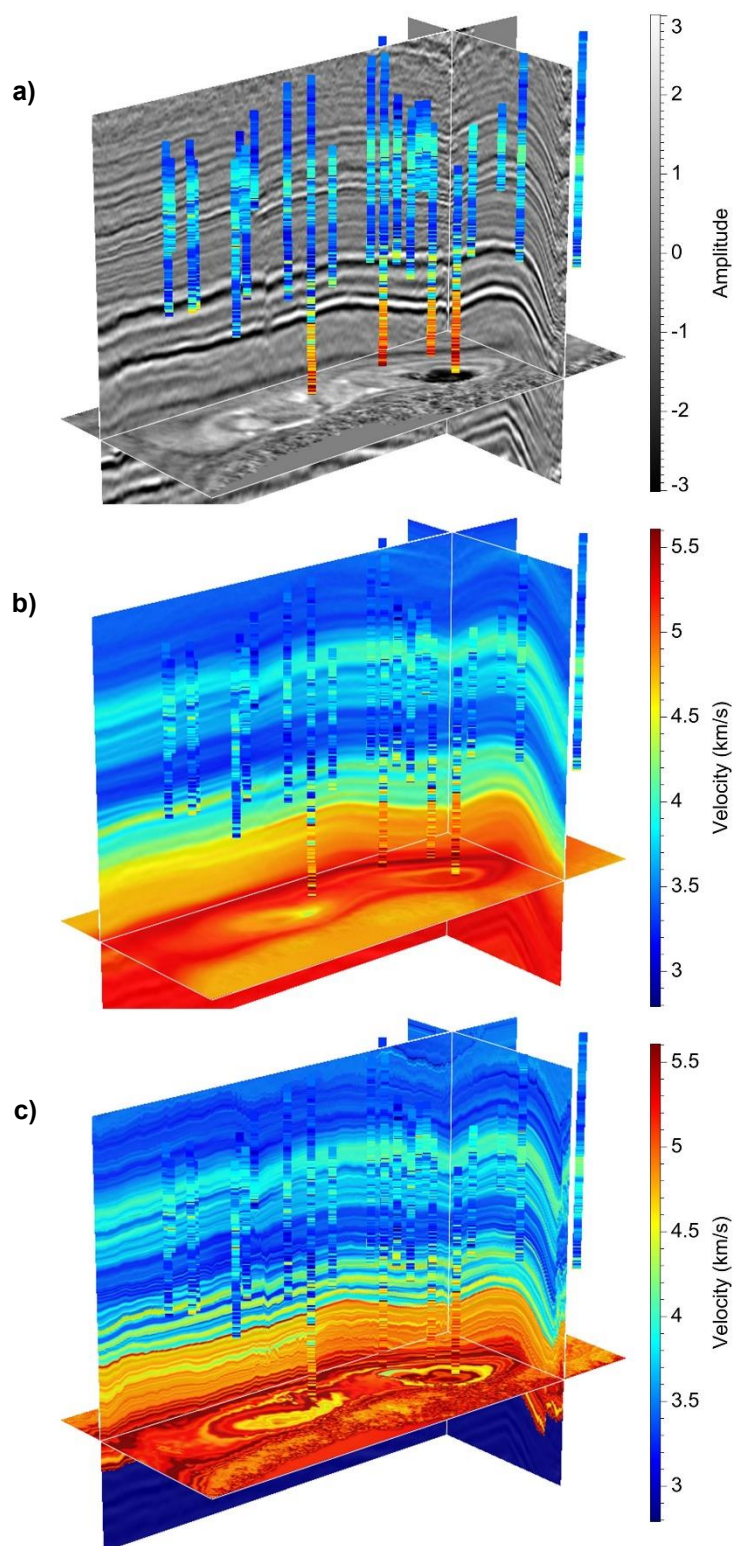


图 3.4 地震构造导向的插值方法和 RGT 引导的插值的方法对速度建模结果的对比。(a) 速度测井在三维地震图像中的分布；(b) 地震构造导向的插值方法得到的速度模型；(c) RGT 引导的插值方法得到的速度模型。可以看出，地震构造导向的插值方法得到的结果更平滑，而基于 RGT 插值得到模型的垂向分辨率更高，能够突出细节构造。

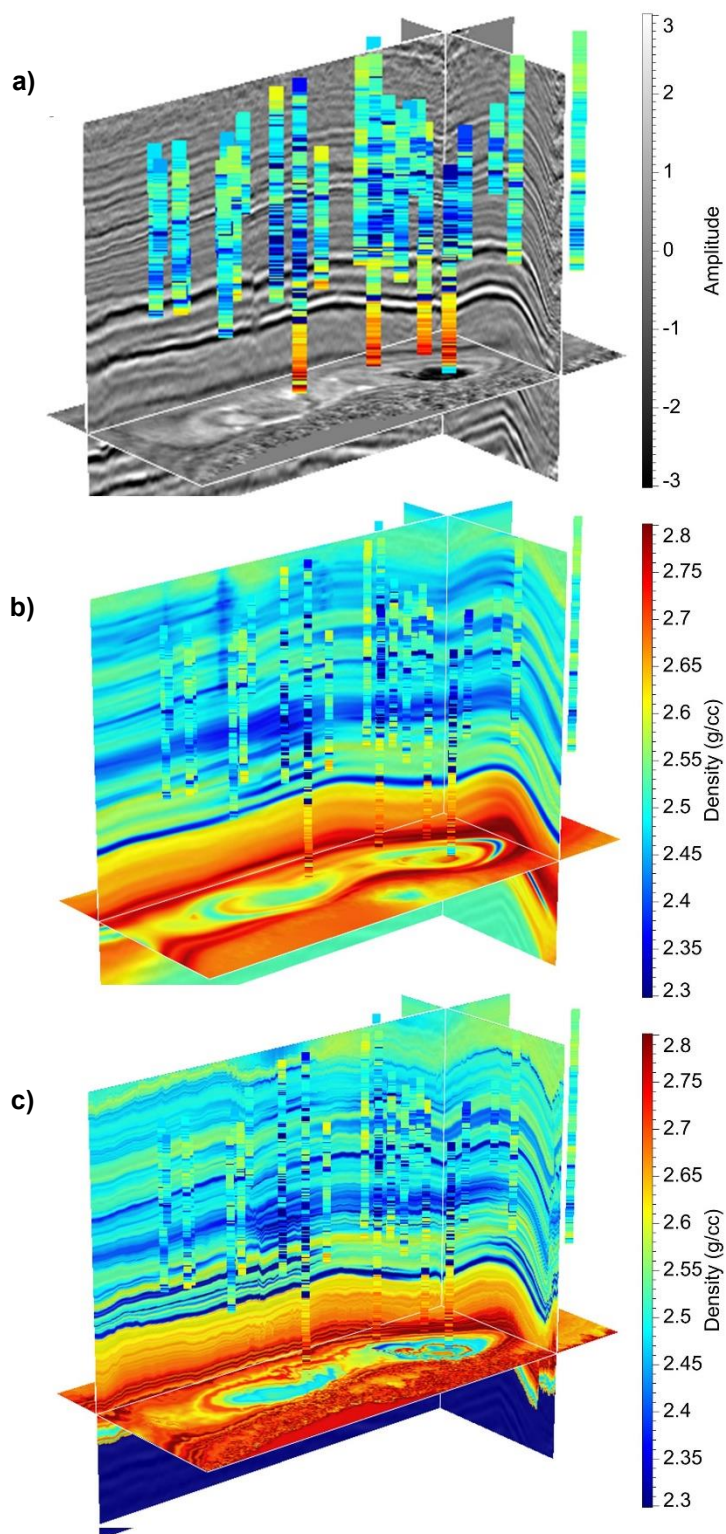


图 3.5 地震构造导向的插值方法和 RGT 引导的插值的方法对密度建模结果的对比。(a) 密度测井在三维地震图像中的分布；(b) 地震构造导向的插值方法得到的密度模型；(c) RGT 引导的插值方法得到的密度模型。其结果去速度模型类似，基于 RGT 插值得到模型比地震构造导向的插值方法的垂向分辨率更高，能够较好地突出一些细节构造。

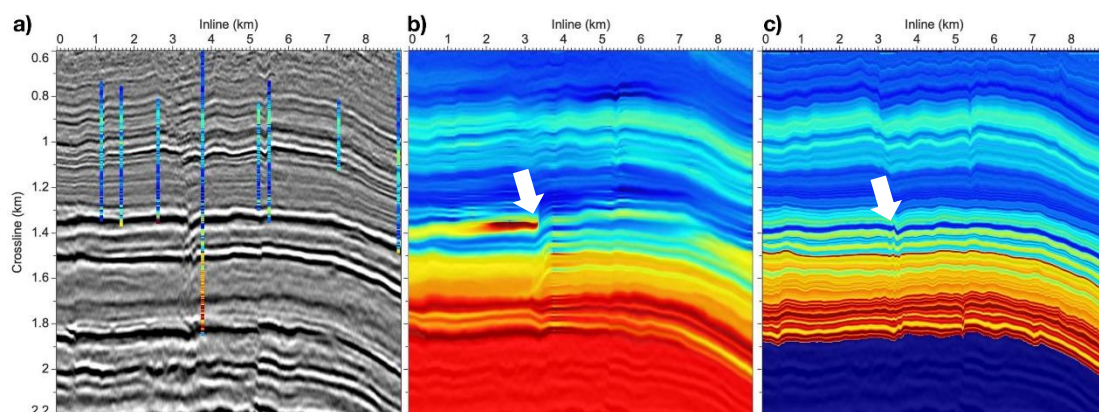


图 3.6 两种插值方法的二维显示图。(a) 从图 3.4 中抽取的一个二维剖面；(b) 为对应的地震构造导向的插值方法的结果，整体表现出平滑的特征，在白色箭头所示的位置由于断层的影响导致插值结果不准确；(c) 为对应的 RGT 引导的插值结果，在垂向分辨率提升，而且在白色箭头所示的断层位置，仍有较好的效果。




图 3.7 两种插值方法在测井位置处的对比结果分析。结果表明，RGT 引导的插值结果（红色实线）比地震构造导向的插值方法的结果（蓝色实线）与真实测井曲线（黑色实线）的一致性更高，比如在蓝色箭头所指示的地方，有许多变化的薄层，但是 RGT 引导的方法仍能一定程度上恢复出细节。

3.4 本章小结

本章对 Hale (2009)提出的地震构造导向的插值方法进行了简单的介绍，并将本文中用到的相对地质年代体导向的插值方法与之进行对比分析，结果证明，本章提出的 RGT 导向的插值方法能够更好的突出细节，在垂向上具有更高的分辨率，而且得到的结果与地震图像构造吻合，在遇到断层不连续处仍有一定的效果。此外，RGT 导向的插值方法不要求解庞大的非线性方程组，因此在计算效率上有很大的提升，节约时间成本。

第4章 井震联合的智能储层参数建模

4.1 引言

地震反演通常根据使用的数据可以分为叠前数据反演和叠后数据反演,这里所提到的波阻抗反演主要是指基于叠后数据进行的,主要方法有道积分、递推反演、基于模型的反演(例如, Veeken et al., 2004; Fu, 2004; Wu, 2017b)、稀疏脉冲反演(例如, Zhang et al., 2011; Yuan et al., 2015; Wang et al., 2016; Sui et al., 2019)以及随机反演(例如, Ma, 2002; Buland et al., 2003; González et al., 2008; Bosch et al., 2010)等。

道积分是指针对叠后数据,直接计算相对波阻抗的反演技术,其原理如下:反射系数 $r(t)$ 与波阻抗 $Z(t)$ 满足关系式:

$$r(t) = \frac{1}{2} \frac{d \ln Z(t)}{d(t)} \quad (4.1)$$

则可以得到:

$$Z(t) = Z_0 \exp \left[2 \int_0^t r(t) dt \right] \quad (4.2)$$

该反演方法计算简单,不需要测井数据,直接可以反映岩层的参数变化,但是它无法得到绝对波阻抗,只能对地层进行粗略的评价。

递推反演的原理是利用反射系数递推计算出波阻抗,然后与真实测井进行匹配(张宏兵等, 2006)。所以其关键步骤在于如何求得比较准确的地层得反射系数(刘喜武, 2005)。因此这就要求具有较高质量的地震数据,其质量的好坏直接影响到反演结果的准确性,所以该方法适用于频带较宽、信噪比高、相对振幅保持准确的成像数据。其原理为:

地震记录 $s(t)$ 与反射系数序列 $r(t)$ 的关系如下:

$$s(t) = w(t) * r(t) \quad (4.3)$$

其中, $w(t)$ 代表地震子波。然后利用反褶积方法可以计算得到反射系数序列,从而波阻抗 $Z(t)$ 为:

$$Z_{j+1} = Z_0 \prod_{i=1}^j \frac{1+r_i}{1-r_i} \quad (4.4)$$

递归反演的优点可以得到地层的绝对波阻抗,不存在基于模型方法的多解性问题。但是它的一个显著缺点就是存在误差累计现象,浅层的波阻抗相对较好,中深层误差的累积导致误差较大,分辨率相对较低,不能满足对薄储层精度需求。

基于模型的地震反演是一个迭代求解的过程，其基本原理是，在地震资料解释的基础上，利用测井资料，从井出发进行内插外推建立反演初始模型（姚逢昌等，2000；井斯亮，2017；刘凤等，2017；韦瑜等，2017）。然后根据初始模型计算合成地震记录并与真实的地震记录进行对比分析，并不断更新参数，优化结果，直至两者最佳吻合。

约束稀疏脉冲反演以地震道为基础，假设地下的反射系数是稀疏分布的，在反演过程中加入趋势约束和地质先验信息等（安鸿伟等，2002；郭朝斌等，2006；王权锋等，2008）。该方法适用于井数较少或者无井的地区，对初始模型依赖较小，但是缺陷是需要满足其假设条件时得到的结果才是比较准确的。

随机反演方法可以得到高分辨率的波阻抗值（李方明等，2007；刘百红等，2009；潘昱洁等，2011）。该反演方法得到的模型可以反映出物性参数在空间上的变化，并且利用测井在垂向上具有高分辨率的特性，在预测较薄的储层问题上有一定的优势，可以用来评估储层的情况。但该方法运算速度慢，实现的次数多，具有多解性，需要对结果综合分析。而且在工区内测井分布均匀且相对较多的情况下才能得到比较好的结果。

这些传统的地震反演方法通常存在有一定的问题，而深度学习方法在从地震数据预测声阻抗方面表现出了良好的前景。然而，大多数深度学习方法都是基于易于实现的一维神经网络，但在逐道预测多维阻抗模型时往往会产生一些不合理的横向不连续现象。本章对其进行改善，利用二维卷积网络（CNN）实现基于深度学习的波阻抗预测，并引入初始波阻抗模型的约束到该网络。初始模型可以从几个测井曲线利用地震构造导向的插值方法得到，然后作为低频约束输入到网络当中，从而使1D和2D的CNN网络产生稳定的阻抗预测结果。本章所提出的2DCNN的架构非常简单，但是由于我们是无法直接得到一个二维的波阻抗标签，所以准备训练数据集是一个挑战。为了准备二维的训练数据集，首先定义一个随机路径可以穿过一定数量的测井位置，然后沿着这个路径去提取一个二维的地震剖面和对应的初始模型剖面作为二维网络的输入，穿过该路径的所有测井作为波阻抗剖面相对应的部分标签。有了这些随机抽取得到的二维训练数据集，本章利用弱监督的方法训练网络，并定义自适应损失函数，即网络输出的二维波阻抗模型仅在有井的地方进行验证评估。由于二维的数据训练集是从最原始的三维数据中从各个方向随机选择的，所以利用训练得到的二维网络，可以从沿测线或者垂直测线的方向，预测一个个连续的二维剖面，进而得到相对应的三维波阻抗模型。合成和实际的例子也表明，相对于一维卷积神经网络，本章提出的二维卷积神经网络不仅对噪音的干扰反应更加稳定、能够更好得恢复出薄层，而且在横向上能够产生更加一致的结果。

本章从两个方面提出了改进利用深度学习进行波阻抗估计的方法。首先，利用初始波阻抗模型和地震数据同时输入到网络中去，这类似于传统方法中使用的初始模型或者基于模型的正则化。这种初始阻抗模型为网络提供了低频趋势约束，从而能够进行稳定的预测。其次，提出了一种简单而有效的二维卷积神经网络（CNN）来预测更准确的多维阻抗模型。准备 2D 训练数据集并不像在 1D 中那样简单，因为在实践中没有完整的 2D 阻抗标签。在准备一对训练数据集时，我们首先定义一个随机路径，该路径通过原始 3D 测量中的多个测井位置。然后，沿着这条路径提取输入数据集（2D 地震剖面 and 初始阻抗剖面）和 2D 阻抗标签，该标签由路径上的测井数据组成。通过这样的操作，就可以获得大量的 2D 训练数据集，因为我们可以定义大量的随机路径，从各个方向穿过 3D 数据。利用这些特殊定义的 2D 训练数据集，本章通过使用自适应损耗来训练具有弱监督的 2D CNN，其中输出 2D 阻抗轮廓自适应地拟合到部分标记的目标。利用这些特殊定义的 2D 训练数据集，通过使用自适应损失函数来训练具有弱监督的 2D 卷积神经网络，其中输出的 2D 阻抗剖面可以自适应地拟合标签部分。所提出的二维 CNN 对输入地震数据中的噪声具有较强的鲁棒性，并能对地震数据进行合理的预测二维阻抗模型，而且在结构上能与地震资料保持一致。相比一维 CNN，二维 CNN 能够较好地恢复薄层，这些薄层在垂直方向上比较隐蔽，但在横向上可能会大范围延伸。

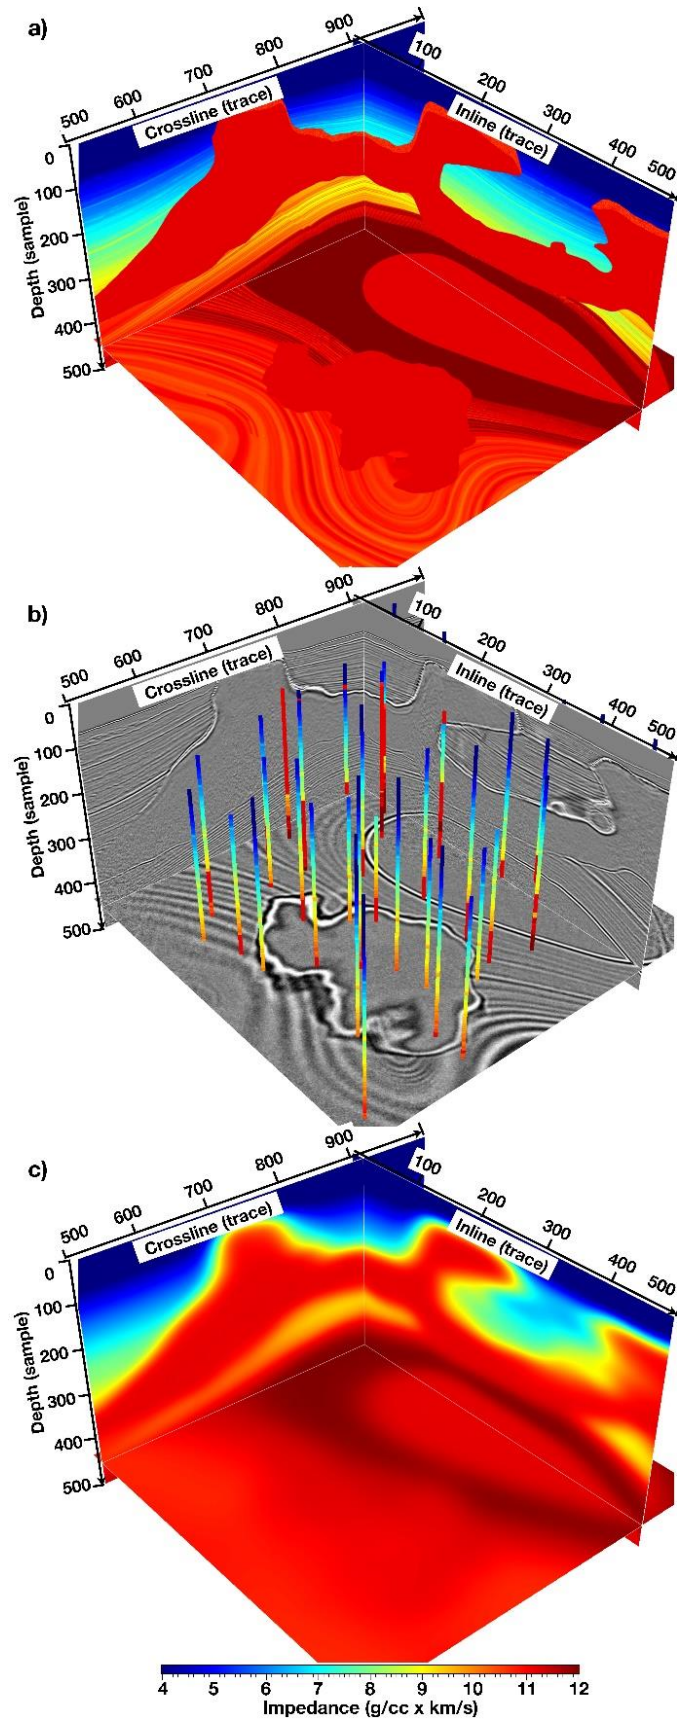


图 4.1 合成 3D SEAM Phase I 数据用来进行 1D 和 2D 的 CNN 波阻抗预测。(a) 真实的波阻抗模型；(b) 地震图像和测井数据展示；(c) 作为约束的初始的波阻抗模型。

4.2 方法理论

当地震数据集及其相关的测井数据（多个速度和密度测井数据）在同一观测中可用时，可以使用这些数据训练有监督的机器学习方法来预测波阻抗模型。从一个简单的一维 CNN 开始讨论，它可以根据地震数据逐道预测阻抗模型，并对比是否有初始模型约束下的结果。本章进一步提出一个改进的方法，使用二维 CNN 来解决阻抗估计问题，其中训练数据集和损失功能是专门设计的。采用与一维 CNN 相同的网络结构，2D CNN 对噪声的鲁棒性更强，可以产生更精确和横向更一致的结果。

4.2.1 数据集

为了演示 1D 和 2D CNN 方法，本章使用了从原始 3D 合成 SEG SEAM Phase I 数据集中提取出来的数据体（图 4.1）。这个数据包括复杂的盐丘体，并且波阻抗值在从周围的边界到盐界上表现出明显的变化。另外，在周围观察到阻抗值在横向和纵向上有诸多变化。数据体如图 4.1 所示，采样点数为 $600(\text{depth}) \times 501(\text{inline}) \times 502(\text{crossline})$ ，覆盖面积为 15×15 平方公里。图 4.1a 中的阻抗模型（由密度和速度模型计算得出）已重新采样，以与相关的深度偏移地震图像（图 4.1b）保持一致。在阻抗模型中，选择 50 条垂向道作为阻抗测井曲线，如图 4.1b 所示。随机选取测井曲线的位置和长度，两条测井曲线的最小距离大于 40 个样本（1.2km），每条测井曲线的长度大于 300 个样本。本章中使用这些提取的 40 个测井数据来训练 CNN，而剩余的 10 个测井数据用于验证。通过使用三维各向同性高斯滤波器（半宽 $\sigma = 20$ 个样本）对真阻抗模型（图 4.1a）进行严重平滑，以获得作为 CNN 方法约束的初始阻抗模型（图 4.1c）。

4.2.2 1D CNN

将观测得到的一维测井数据作为标签，输入和输出分别为地震道和相应阻抗序列的一维 CNN，可以直接实现 1D CNN 训练并进行预测。

1. 网络架构

图 4.2 显示了一个非常简单的一维 CNN 来进行一维阻抗预测。这 CNN 依次由一个规则的卷积层、四个模块和最终输出层组成。第一个常规的卷积层包含 16 个一维卷积滤波器（每个大小为 7），输入数据通过该层之后，得到 16 个一维特征向量，然后经过一个 ReLU 激活层和四个连接起来的模块。每一个模块包含一个常规的卷积层和一个残差模块(ResBlock (He et al., 2016))。如图 4.2 的底部所示，一个 ResBlock 包含两个卷积层（每一层有 16 特征或过滤器），在两层之间

有一个跳跃连接层。这样 ResBlocks 被广泛应用于构造深度 CNN 网络，而且跳跃层在训练网络过程中有助于梯度回传 (He et al., 2016)。最后一层是一个简单的卷积核大小为 1 的卷积层，最后产生一个阻抗序列的输出。

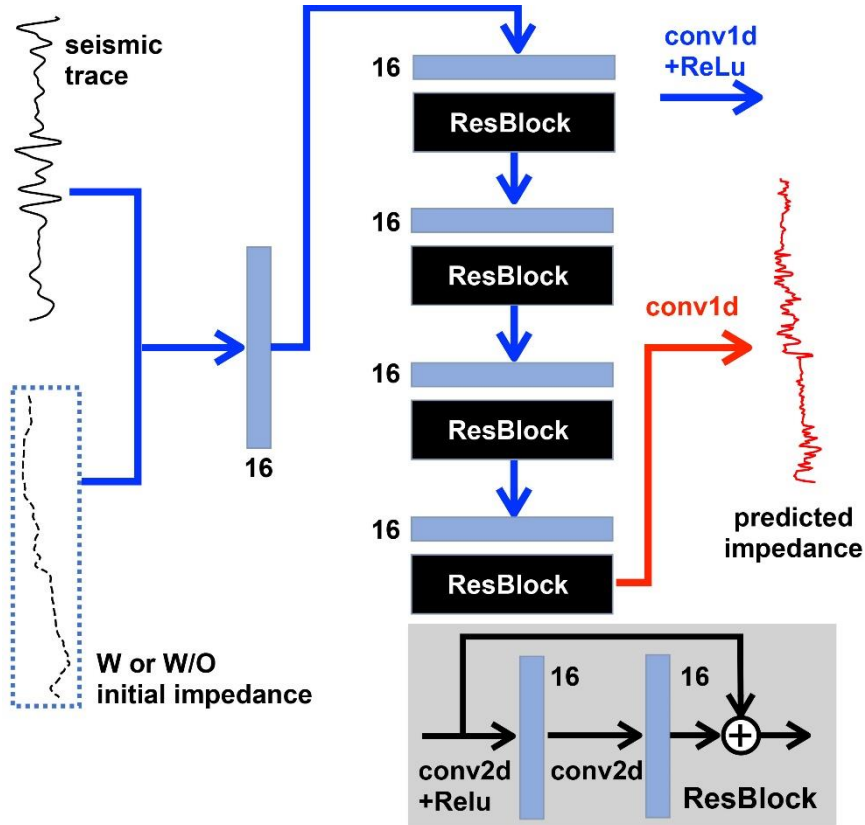


图 4.2 一维 CNN 网络架构，用于从地震道到波阻抗的预测。该网络依次由一个规则的卷积层、四个模块和最终输出层组成。第一个常规的卷积层包含 16 个一维卷积滤波器（每个大小为 7），输入数据通过该层之后，得到 16 个一维特征向量，然后经过一个 ReLU 激活层和四个连接起来的模块。每一个模块包含一个常规的卷积层和一个残差模块(ResBlock)。

2. 训练集

本章用两种方案训练这个一维 CNN，其不同之处在于输入网络的数据不同。在第一种方案中，我们只向网络输入地震道数据，因此一个训练数据集对由输入地震道和对应的波阻抗阻抗序列组成。该数据中总共有 40 个不同长度（300~600 采样点）的训练井（图 4.1b）。但是，通过随机选择一个起始样本，可以从 40 个较长的测井中提取远多于 40 个固定长度为 300 个样本（测井的最短长度）的训练数据集对。

在第二种方案中，输入网络的数据包括地震道和相应的初始阻抗序列，该初

始波阻抗是从一个高度平滑的阻抗模型中提取的（图 4.1c）。这个初始阻抗序列（在图 4.4 和图 4.5 绿色曲线所示）提供了低频阻抗趋势用来约束网络，以预测更准确的阻抗序列和更多细节。在第二种方案中，使用与第一种方案相同的方法从相同的 40 个测井中随机提取训练数据集。

在这两种方案中，估计波阻抗序列都是一个经典的回归问题。因此，本文使用以下常用的损失函数来训练网络：

$$L = \frac{1}{N} \sum_{i=1}^N (y[i] - y^p[i])^2 \quad (4.4)$$

该公式表示实际的波阻抗($y[i]$)和预测波阻抗($y^p[i]$)之间的均方误差 (MSE)。本章使用 Adam 方法 (Kingma et al., 2014) 通过多次迭代最小化损失函数来优化网络参数。在训练过程中，本文采用的初始学习率是 0.001，并采用自适应下降的学习率。在两方案中，经过 300 个 epoch 后，训练损失函数值分别平稳地收敛到接近 0.03 和 0.02。这表明简单的一维 CNN（图 4.2）（共 10,001 个训练参数）已经足够拟合训练数据集达到较好的结果。

3. 测试结果

利用这两种方案训练好的一维 CNN 模型，单道进行预测。输入仅有地震数据（图 4.1b）时得到的三维模型如图 4.3a 所示，加入初始阻抗模型（图 4.1c）后得到的三维阻抗模型如图 4.3b 所示。在输入只有地震数据的情况下，一维 CNN 产生了一个高噪声的阻抗模型（如图 4.3a），有很多不合理的不连续点，这与真实阻抗模型（图 4.3d）有很大的不同。图 4.4 和图 4.5 显示了未包含在训练集中的 10 个测井（图 4.6a 中的红色圆圈表示）的预测结果，其中洋红色曲线表示预测阻抗，黑色曲线表示真实的测井值。我们观察到，仅由地震数据训练的网络预测出的波阻抗序列（洋红色曲线）随着深度不稳定地振荡，并且在图 4.4 和图 4.5 中的红色箭头所示的某些深度处，与真实值（黑色曲线）相差甚远。

因此，第一种方案中训练的一维 CNN 虽然能够很好地拟合训练数据集，且其训练损失已经收敛到 0.03，但并不能在整个数据集的阻抗序列和地震数据之间建立有效的映射关系。这一现象并不意味着构造的 CNN 不起作用，而是表明本章选取的 40 个测井不足以让 CNN 学习整个地震数据体和波阻抗之间的复杂映射关系。此外，地震数据中存在空间变化的噪声也可能导致训练好的 CNN 做出不稳定的预测结果。而且，一维 CNN 逐道预测三维阻抗模型，缺少了横向约束，进而导致无法保持横向一致性。




图 4.3 不同网络预测的 3D 波阻抗模型的对比显示：(a)仅从地震数据到波阻抗的 1D CNN 预测结果；(b)有初始阻抗模型约束的 1D CNN 预测结果；(c)2D CNN 网络预测结果；(d)真实的波阻抗模型。

在实践中，由于钻井的数量总是有限的，我们不能指望得到更多的测井数据来提高一维 CNN 的性能。由于受到常规反演方法中使用合理初始值作为正则化项或初始模型的启发，第二种方案将初始阻抗序列与地震道一起输入一维 CNN。通过使用初始阻抗序列（从图 4.1c 中高度平滑的阻抗模型中提取），训练后的 1D CNN 能够产生比仅使用地震道（图 4.3a）更精确的预测结果（如图 4.3b 所示）。在每个验证井中（图 4.4 和图 4.5 所示），当输入为地震道和初始阻抗模型（绿色曲线）时，能够预测更准确的阻抗序列（蓝色曲线），该预测结果更接近真实值并且比第一种方案的结果（洋红色曲线）更加稳定。然而，我们仍然观察到预测结果中的一些噪声特征（图 4.3b），如蓝色曲线所示能够观测到一些不稳定振荡和不匹配的现象（如图 4.4 和 4.5）。

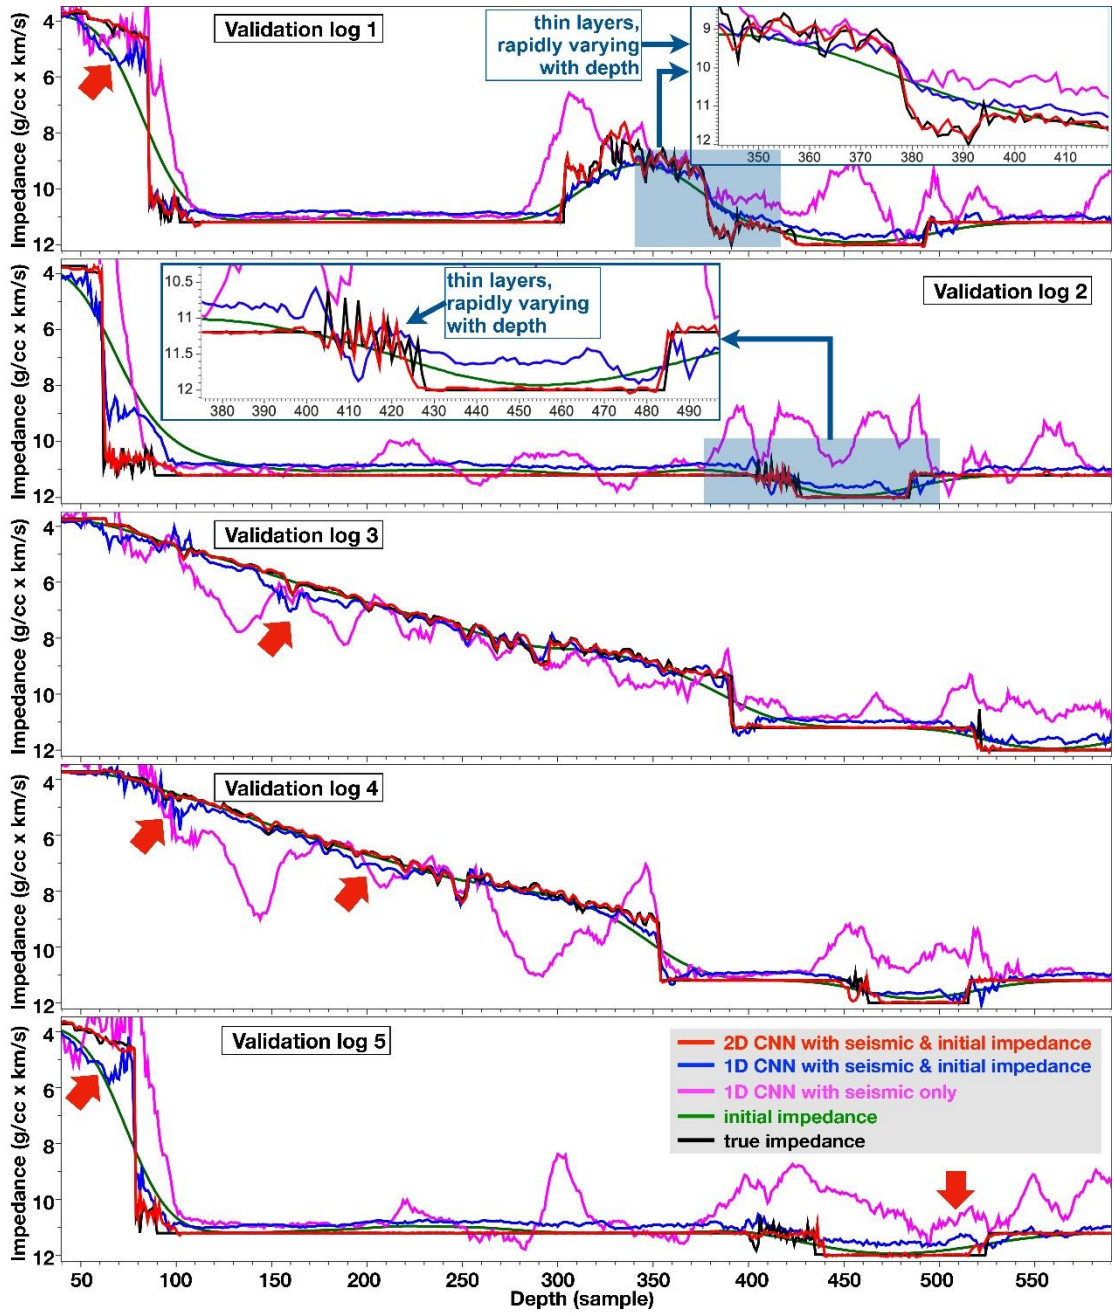


图 4.4 对比验证井 1、2、3、4 和 5（图 4.6a 中红色圆圈表示）的预测阻抗结果，其中 2D CNN 方法表现最好，特别是在红色箭头表示的位置。2D CNN 预测的阻抗值（红色曲线）与真实测井曲线（黑色曲线）即使在薄层，也能很好地匹配，如测井曲线 1 和测井曲线 2 的放大图所示。

总之，由于岩石性质的空间变化、潜在的噪声或地震数据的采集和处理误差，当测井数量有限时，一维 CNN 无法仅从地震数据预测准确的波阻抗模型。利用地震道和合理的初始模型作为网络的双通道输入，引入低频趋势控制训练过程，可以显著提高一维 CNN 的性能。

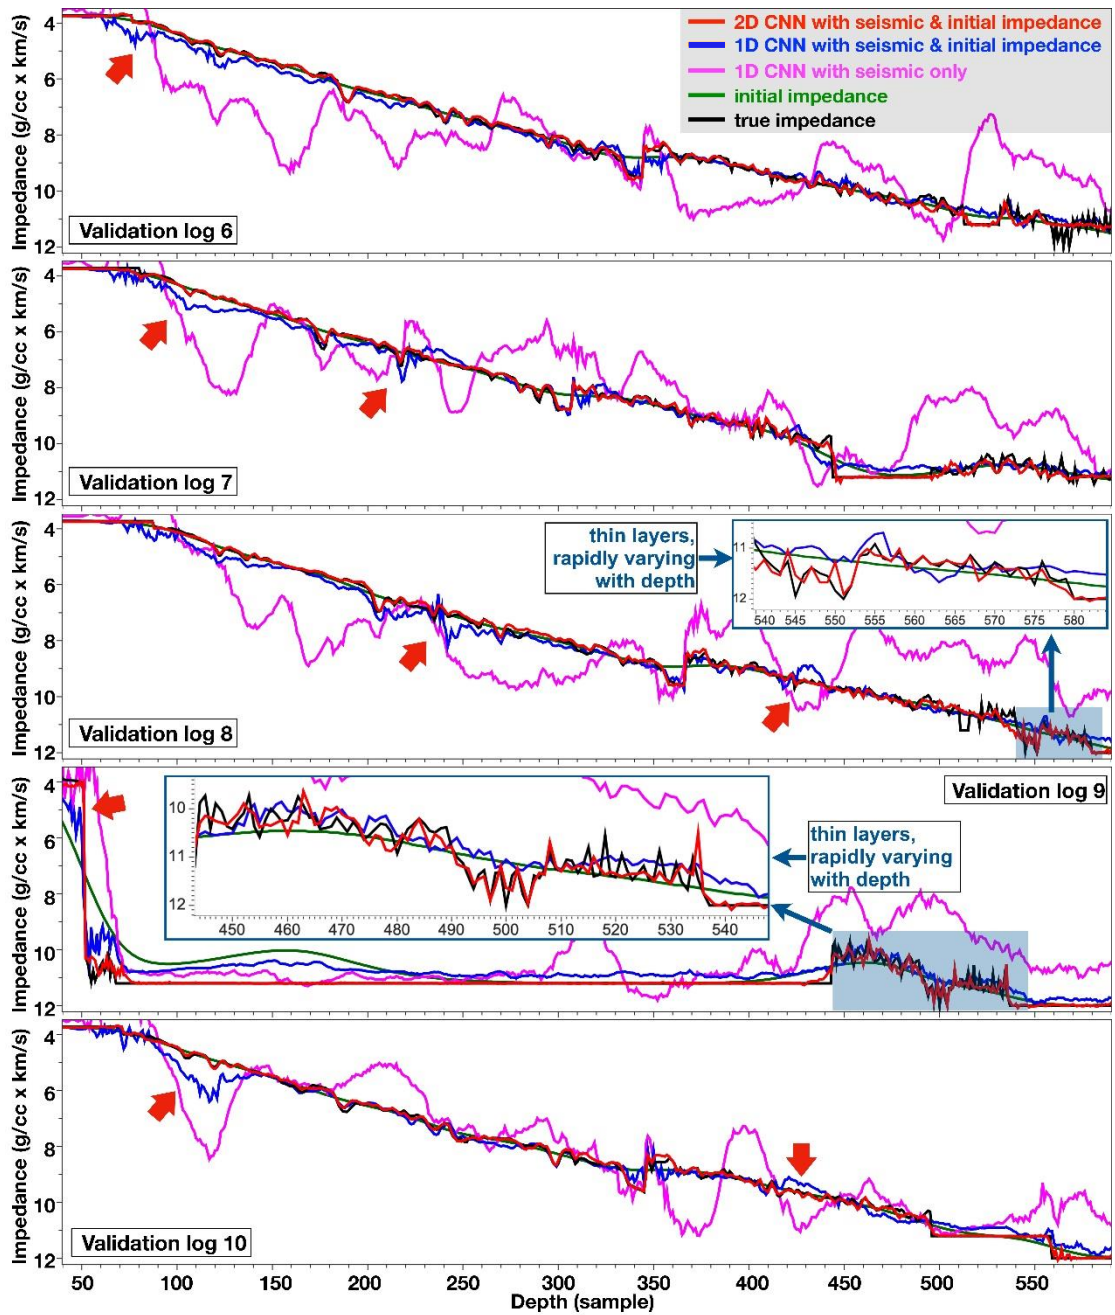


图 4.5 对比验证井 6、7、8、9 和 10 处（图 4.6a 中红色圆圈表示）的预测阻抗结果，其中 2D CNN 方法表现最好，特别是在红色箭头表示的位置。2D CNN 预测的阻抗值（红色曲线）与地面真实值（黑色曲线）即使在薄层，也能很好地匹配，如测井曲线 8 和测井曲线 9 的放大图所示。

然而，使用初始阻抗模型作为约束并不能从根本上消除 1D CNN 的主要局限性，由于它是逐道进行预测的，所以并没有考虑到地震数据中的横向结构特征。而考虑地震横向结构有助于估计横向更加一致的阻抗模型，能够更好的恢复薄层，

并增强抗噪性。薄层在垂直方向上不明显，但在横向上可能会大面积延伸，而在逐道训练的一维过程中很容易被忽略，但在考虑地震数据中横向构造的约束的多维过程中可能会被捕捉到，因此考虑使用二维卷积神经网络。

4.2.3 2D CNN

本章提出了一种二维 CNN 来进一步提高波阻抗预测的可靠性。为了保持一致，我们使用同样的测井数据，并且为二维 CNN 设计的架构（图 4.7）与一维 CNN（图 4.2）完全相同，只是将一维卷积滤波器改成 3×3 的二维滤波器，这将有助于提取输入地震数据中的空间结构特征。相应地，输入更改为从图 4.2 提取的二维的地震剖面和一个初始阻抗剖面（图 4.7 左图），对应的输出也是一个完整的二维阻抗剖面，而不是一维的阻抗序列。

1. 训练集

将 2D CNN 应用于阻抗预测的主要挑战是准备有效的训练数据集，特别是标签数据，因为真实的测井值只是一维序列。为了解决这个问题，本章将基于 CNN 的 2D 阻抗预测看成是一个弱监督或部分监督学习问题，其中 2D 标签仅在测井位置部分有值。然后，我们从原始的 3D 数据集中随机提取 2D 训练数据集，并确保每个提取的 2D 数据集经过多个测井曲线。

为了提取这样的 2D 训练数据集，本章首先定义一条经过至少 5 个测井曲线的随机路径，如图 4.6a 中红色曲线所示。我们通过将一系列随机选择的井位置（蓝色圆）与线段串联起来来定义这样的路径。在定义这条路径时，要考虑三个简单有效的因素：(1)在随机选择多个井时，需要确保任意两个相邻的井位置是不相同的；(2)两条相连线段的夹角 $\alpha > 80^\circ$ ；(3)路径不应该以井的位置开始或结束，以避免在 CNN 中产生边界效应。这样，就可以随机选择许多路径，在图 4.6b 中用彩色曲线显示其中的 100 条路径。这些路径连接所有的测井位置，并在所有方向上遍历整个空间。

根据每个随机路径，我们提取一对 2D 训练数据集，包括输入的 2D 地震和初始阻抗剖面，以及相应的 2D 标签剖面，其中作为标签的剖面在非测井位置的值为零。图 4.8 显示了按照图 4.6a 所示路径提取的一对训练数据集。我们可以提取大量的 2D 训练数据集，且由于它们是沿着随机路径从各个方向遍历 3D 空间的，所以可以充分捕捉 3D 数据体的空间变化结构特征。

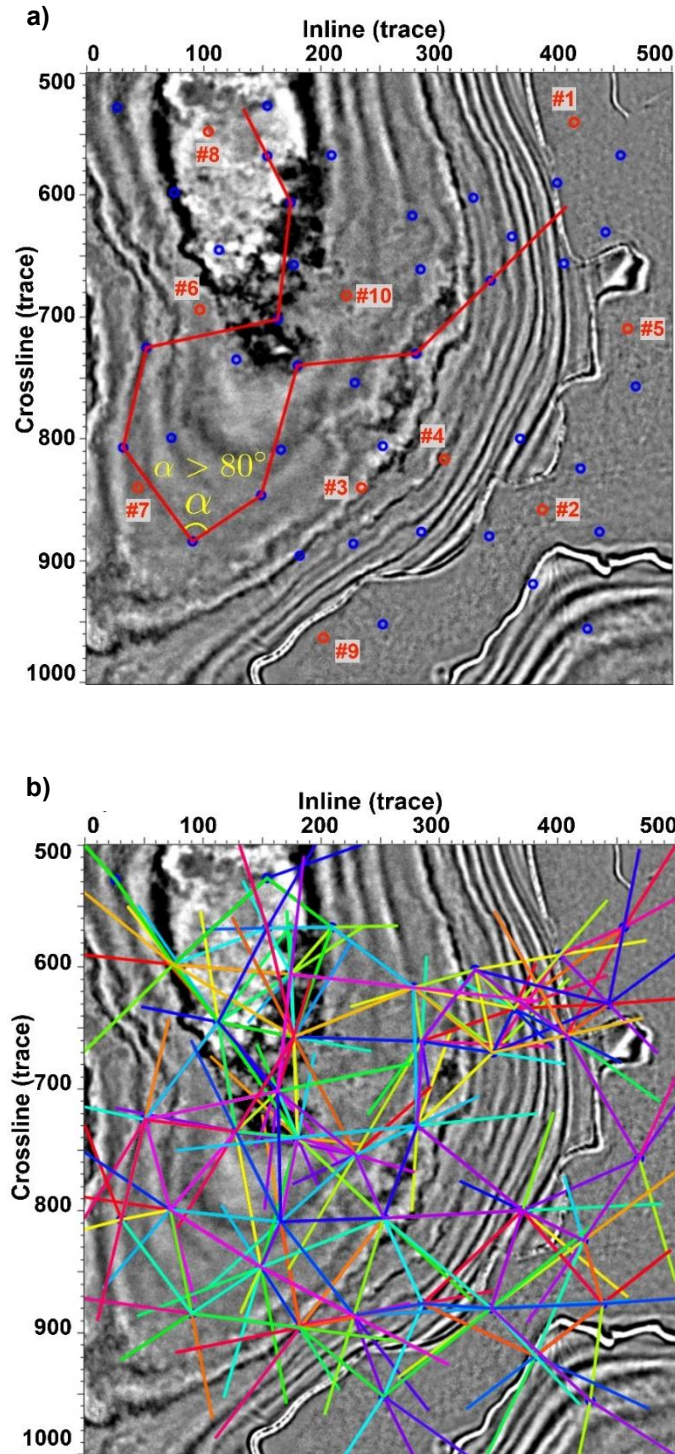


图 4.6 (a)中的圆圈表示 40 口训练井（蓝色圆圈）的位置，10 口验证井（红色圆圈）。(a)中的红色曲线表示经过 10 个随机选择的井的路径。(b)中的彩色曲线表示 100 条随机路径，每条路径至少经过 5 口井，在(b)中有许多类似的路径，沿着这些路径提取 2D 训练数据集。

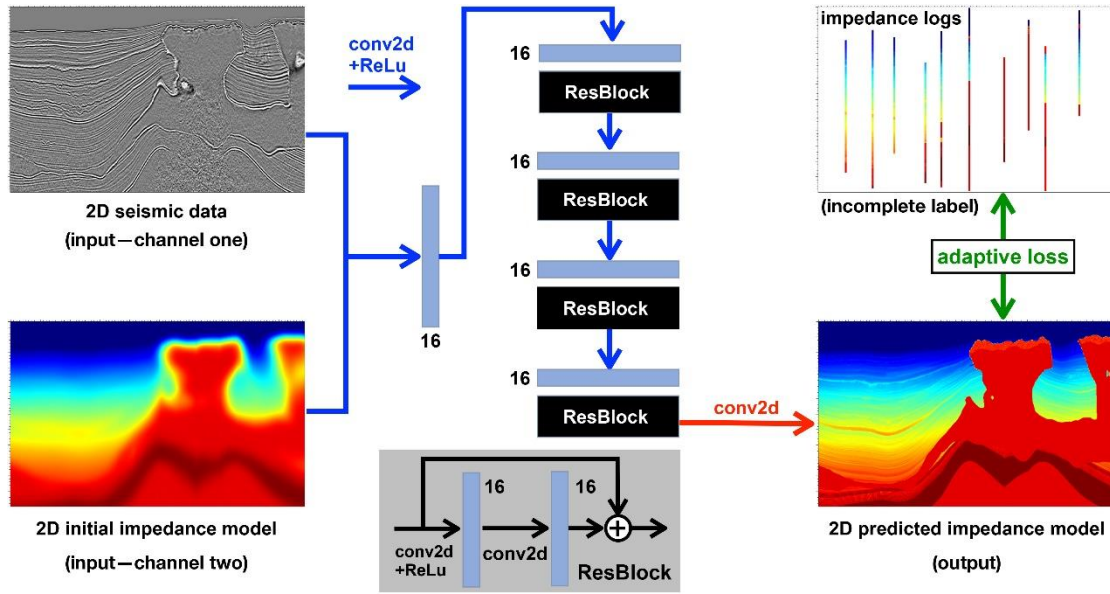


图 4.7 二维 CNN 网络架构与一维 CNN 类似（图 4.2）。网络的输入是二维地震剖面 and 初始阻抗剖面的组合。输出是一个预测的 2D 全阻抗剖面，与具有部分标记的标签拟合，在训练期间使用自适应损失函数。

2. 自适应损失函数

在如图 4.7 所示的二维 CNN 方法中，我们期望输出是一个完整的 2D 阻抗剖面，而标签剖面是不完整的，只有测井位置的有值，其他位置为零。为了解决训练 CNN 时输出和标签数据不匹配的问题，本章定义了一个自适应的 MSE 损失函数如下：

$$L = \frac{1}{\sum_{i=1}^N \sum_{j=1}^M w[i,j]} \sum_{i=1}^N \sum_{j=1}^M w[i,j] \cdot (y[i,j] - y^p(i,j))^2, \quad (4.5)$$

其中， $y[i,j]$ 表示二维目标阻抗剖面（标签数据）和 $y^p[i,j]$ 为预测阻抗剖面。 $w[i,j]$ 表示一个系数，自适应的从标签数据获得，在测井位置设置 1，在其他位置设置 0。在训练这种损失的二维 CNN 时，我们自适应地将网络的输出与未完全标记的目标阻抗剖面仅在测井值的位置进行拟合。然而，这种情况下卷积滤波器仍然持续处理输入的 2D 数据，并提取 2D 特征映射，以预测具有空间一致值的完整 2D 阻抗剖面。如图 4.9 所示，训练好的 2D CNN 模型从输入的地震（图 4.9a）和初始阻抗（图 4.9b）剖面直接预测出完整的 2D 阻抗剖面（图 4.9c），而且预测的 2D 阻抗剖面（图 4.9c）与图 4.9d 的真实波阻抗保持高度一致。




图 4.8 二维训练样本对。在图 4.6a 所示的红色路径上提取了一个 2D 地震振幅剖面 (a)、一个 2D 初始阻抗剖面(b)和 10 口测井曲线(c)。(a)和(b)共同构成 2D CNN 的双通道输入，而 10 口测井曲线是相应的标签（弱标签），在训练 2D CNN 时通过自定义的自适应损失进行拟合（图 4.7）。

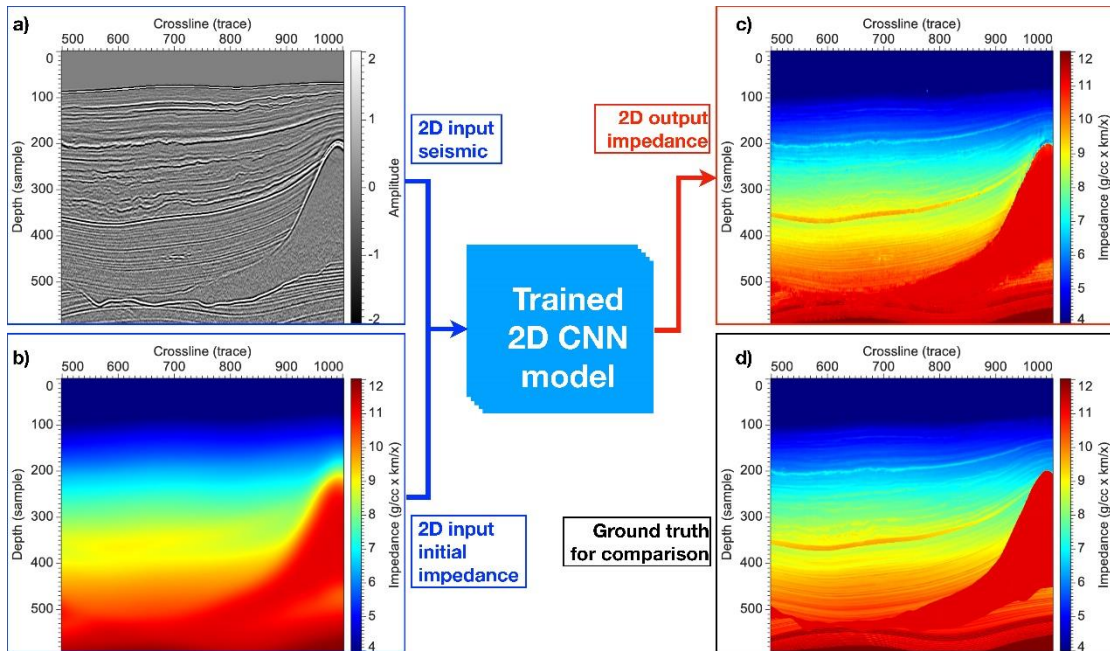


图 4.9 2D CNN 方法的推理步骤是：通过输入一对地震数据(a)和初始阻抗(b)剖面，通过训练直接预测完整的 2D 阻抗剖面(c),与真实的波阻抗剖面(d)匹配。

3. 测试结果和准确度指标

由于本文的 2D CNN 输入的大小是不固定的，因此可以直接将训练好的 2D CNN 应用到原始的 3D 数据集上，在纵测线 (incline) 或横测线 (crossline) 方向一个一个剖面的预测 3D 阻抗模型。图 4.3c 为预测的三维阻抗模型，其横向层状特征比采用一维 CNN 计算得到的层状阻抗特征（图 4.3b）更加一致。与一维 CNN 估计的阻抗模型（图 4.3a 和图 4.3b）相比，二维 CNN 预测的阻抗模型（图 4.3c）受地震数据噪声的影响较小，能更好地恢复薄层。图 4.4 和图 4.5 显示了 10 个测井的预测阻抗值的更多细节。我们观察到，即使在图 4.4 和图 4.5 放大的

薄层中，二维 CNN 预测的阻抗值（红色曲线）也与真实的测井值（黑色曲线）能够很好地匹配，在薄层中阻抗值随深度变化很快。图 4.10 显示了验证井的真实值与预测值之间的交会图。从图 4.10c 可以看出，2D CNN 预测的阻抗值与测井阻抗值的相关性最高。

表 4.1 中的表给出了使用一维和二维 CNNs 预测阻抗结果的 MSE 的定量比较。尽管用相同的 40 个测井值进行训练，但在 10 个验证井和整个三维数据体上，2D CNN 的结果的均方根误差（MSE）明显小于 1D CNN 的结果。

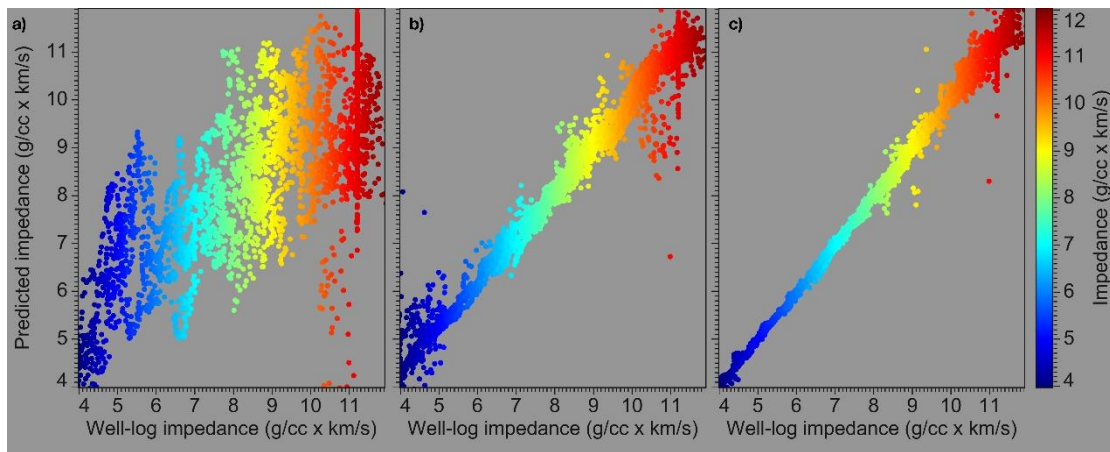


图 4.10 10 口验证测井曲线的交会图：(a)输入仅使用地震数据的一维 CNN；(b)输入同时使用地震和初始阻抗的一维 CNN；(c)同时使用地震和初始阻抗的二维 CNN；三者分别与真实波阻抗进行对比的交会图。

4.3 实例应用

图 4.11a 显示了公开的 Teapot Dome 数据集中提取的三维实际地震数据和 27 口波阻抗测井曲线 (Anderson, 2009)。虽然有数百口井，但在除去密度或速度记录缺失的井后，本章只选择了图 4.11a 所示的 27 口井，且这 27 个测井数据已经与地震数据转化到同一深度域中。根据这 27 条阻抗测井曲线，以地震构造为导向，采用空间各向异性插值方法 (Hale, 2010b; Naeini et al., 2015; Karimi et al., 2017; Wu, 2017a)，插值得到如图 4.11b 所示的三维波阻抗模型。该插值模型在纵向上与实测测井值的总体趋势相吻合，横向上与地震构造相吻合，它作为初始阻抗模型，与地震数据一起输入一维和二维 CNN 网络中，期望初始阻抗模型能够提供低频约束，CNNs 能够根据地震振幅在初始模型中填充细节并修正插值带来的误差。

图 4.12a 显示了 27 口测井在地震体深度切片上的空间位置。本章使用 24 口

井（蓝色圆圈）进行训练，而使用其余 3 口井（红色圆圈）进行验证。在这 24 口井的位置随机选取 1D 训练数据集，每个训练数据集的垂直长度设置为 72 个样本，即井的最短长度。2D 训练数据集是通过至少经过 5 口井的随机路径提取的。图 4.12b 显示了 100 条随机路径，它们在各个方向上穿过整个空间。

表 4.1 不同的方案在 10 口验证井上和整个 3D 数据体上的均方误差对比结果。数据显示，2D CNN 的结果的均方根误差（MSE）明显小于 1D CNN 预测的结果。

Methods / Validation data	MSEs by 1D CNN with seismic only	MSEs by 1D CNN with seismic & initial impedance	MSEs by 2D CNN with seismic & initial impedance
Validation Log 1	1.3940	0.1888	0.0265
Validation Log 2	2.9415	0.3183	0.0241
Validation Log 3	0.8722	0.0833	0.0124
Validation Log 4	1.5199	0.0717	0.0123
Validation Log 5	2.1104	0.1963	0.0188
Validation Log 6	2.2405	0.0632	0.0167
Validation Log 7	1.9171	0.0686	0.0135
Validation Log 8	2.4492	0.0707	0.0167
Validation Log 9	2.1172	0.2584	0.0211
Validation Log 10	1.2863	0.0922	0.0073
The whole Volume	1.7694	0.2122	0.0928

图 4.13a 和图 4.13b 分别为采用一维 CNN 在没有和有初始阻抗模型的约束情况下逐道预测的三维阻抗模型。显然，使用初始阻抗模型有助于二维 CNN 预测更稳定的结果。另外，本章通过将训练好的 2D CNN 应用于 3D 数据集，在 inline 和 crossline 的方向上分别逐个剖面进行预测，得到了两个一致的 3D 阻抗模型，如图 4.13c 和 4.14d 所示。这说明沿随机路径提取的二维训练数据集具有足够的代表性，能够捕捉三维地震数据中空间结构变化。与初始阻抗模型的一维 CNN 结果（图 4.13b）相比，二维 CNN 阻抗模型（图 4.13c 和 4.14d）横向特征更加一致，纵向薄层更加清晰。

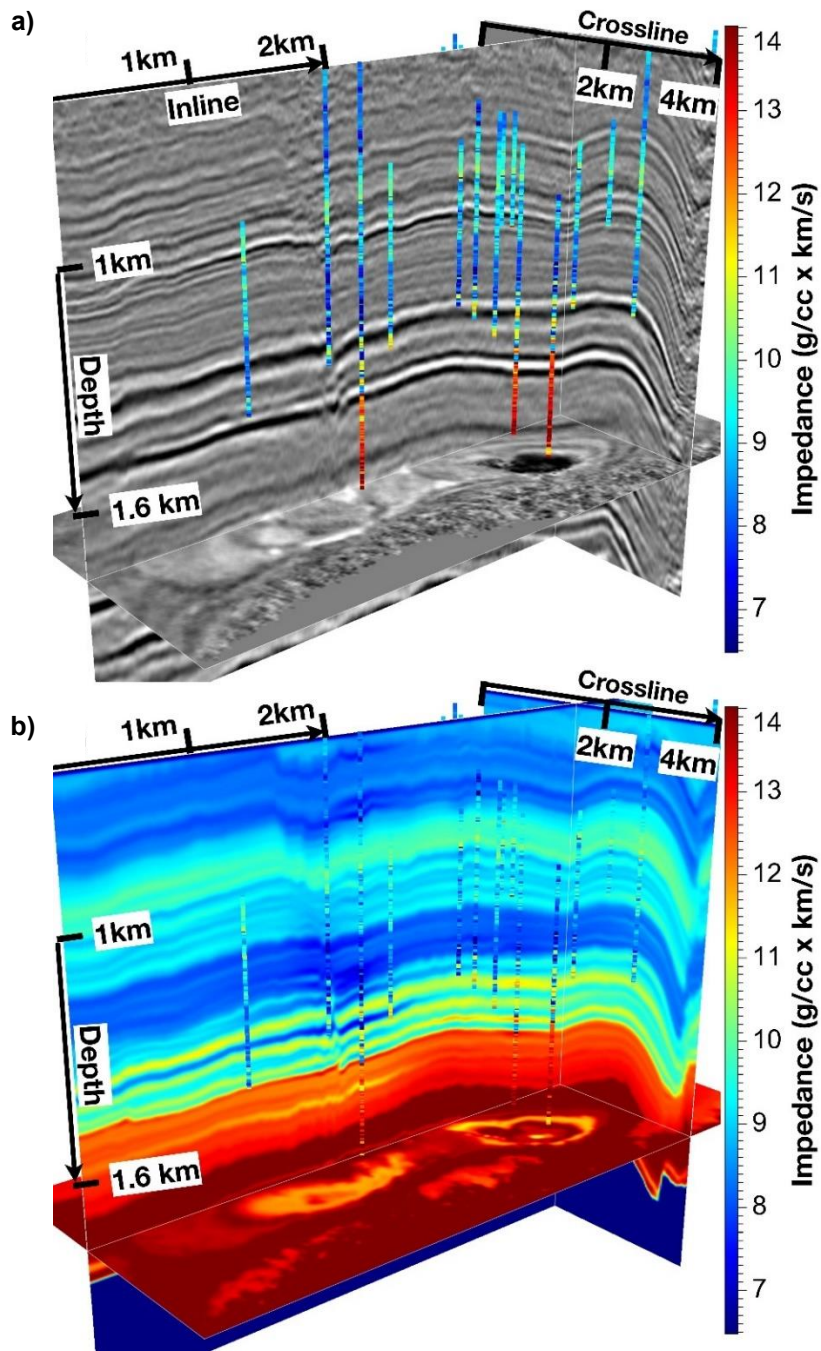


图 4.11 (a)从公开的 Teapot Dome 数据集中提取三维地震体和 27 口阻抗测井曲线。(b) 由地震构造导向插值得到的初始波阻抗模型。

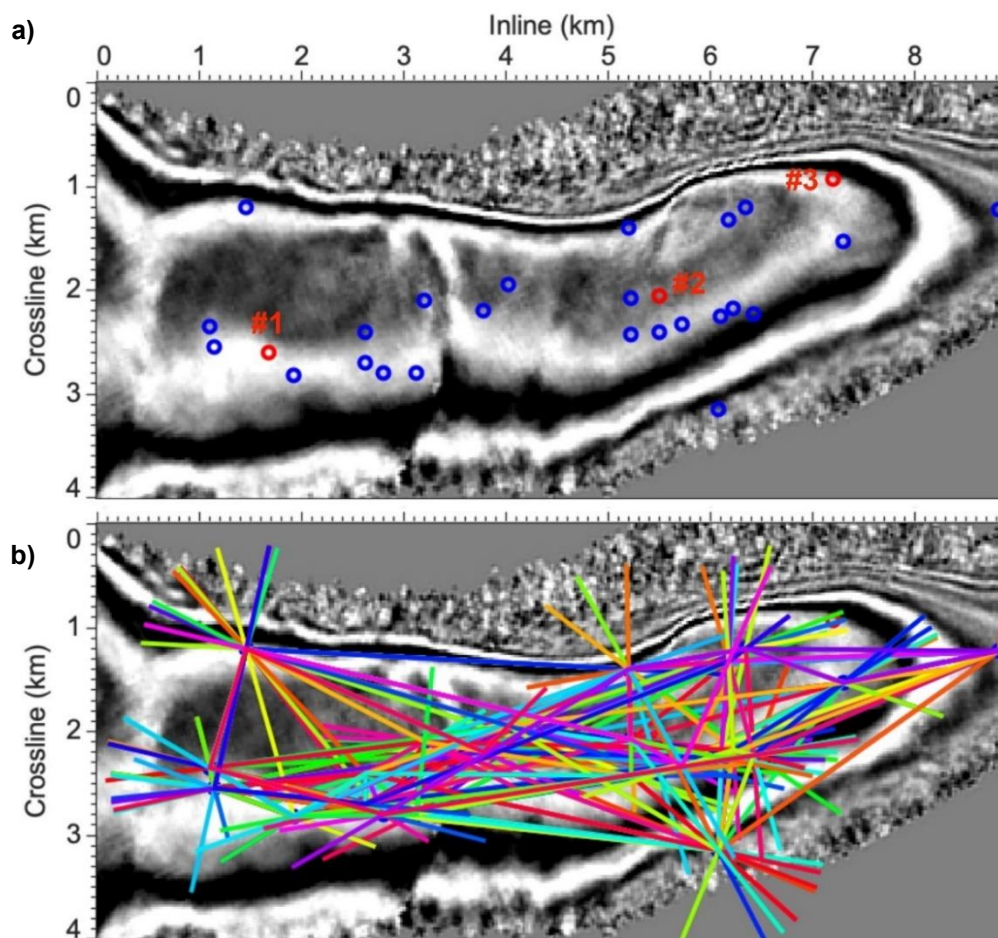


图 4.12 (a)中的圆圈表示 27 口测井（图 4.11a）在地震体深度切片上的位置，其中蓝色和红色的圆圈分别表示用于训练和验证的测井曲线。(b)中的彩色曲线表示任意路径，每条路径至少经过 5 口井。我们可以定义许多这样的随机路径，并沿着这些路径提取大量的 2D 训练数据集。

图 4.14 比较了 3 个验证井的预测结果。与不输入（洋红色曲线）和输入（蓝色曲线）初始阻抗模型（绿色曲线）的 1D CNN 结果相比，2D CNN 预测的阻抗曲线（红色曲线）看起来与实测阻抗曲线（黑色曲线）更匹配，并且验证井的真实值与预测值之间的交会图（图 4.15）支持了这一观察结果。我们观察到二维 CNN 预测的阻抗值与测井阻抗值的相关性最高，如图 4.15c 所示。在表 4.2 的定量精度指标表中，二维 CNN 的预测在三个验证井中都显示了最高的精度（或最小的 MSE）。

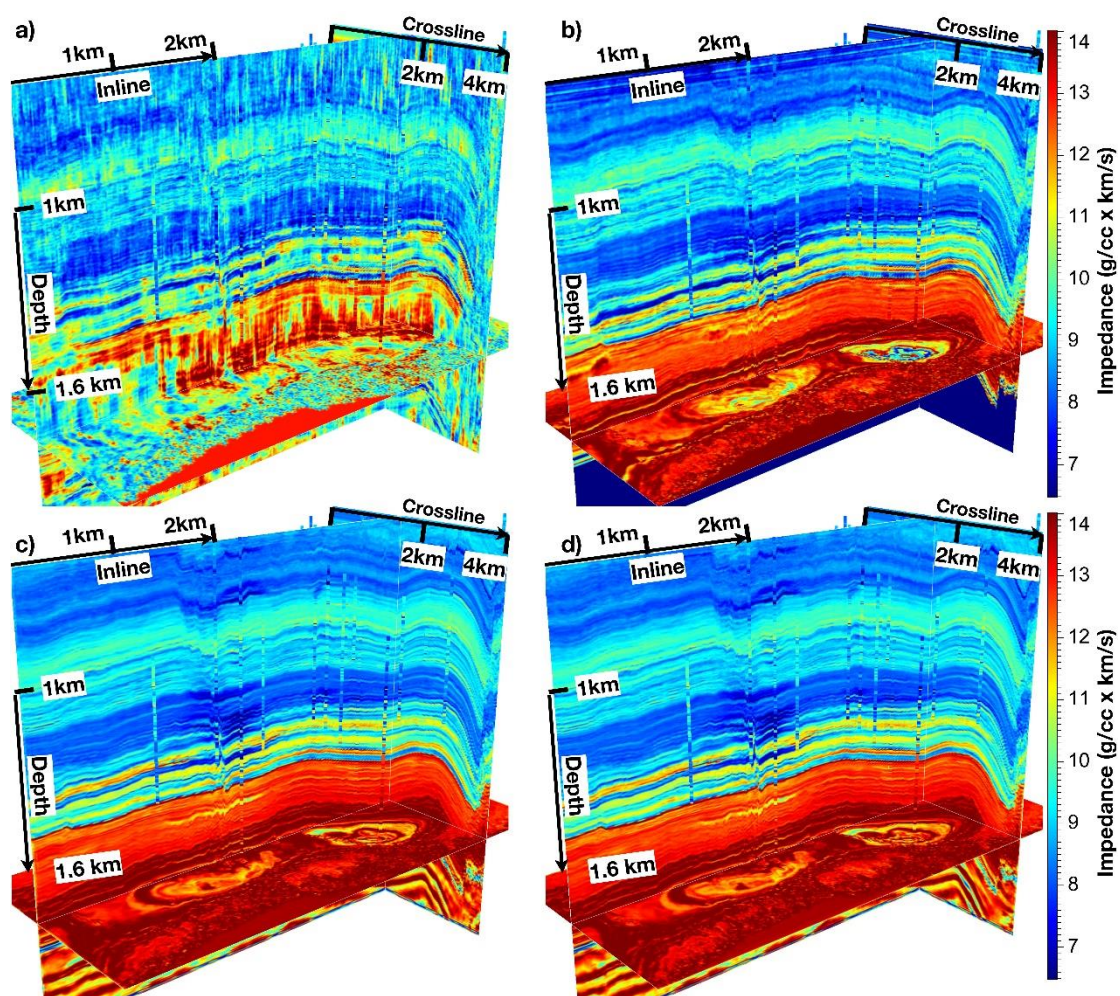


图 4.13 不同方案得到的波阻抗模型的对比图。(a)只使用地震数据的一维 CNN; (b)时使用地震和初始阻抗的一维 CNN; 同时输入地震数据和初始阻抗模型, 利用 2D CNN 在 crossline 方向(c)和 inline 方向(d)上的预测结果。结果表明沿随机路径提取的二维训练数据集具有足够的代表性, 能够捕捉三维地震数据中空间结构变化。与初始阻抗模型的一维 CNN 结果相比, 二维 CNN 阻抗模型横向特征更加一致, 纵向薄层更加清晰。




图 4.14 三个验证井的预测结果（图 4.12a 中的红色圆圈表示的井）。2D CNN 预测的结果明显比 1D CNN 得到的结果分辨率更高，与真实测井的吻合性更高。

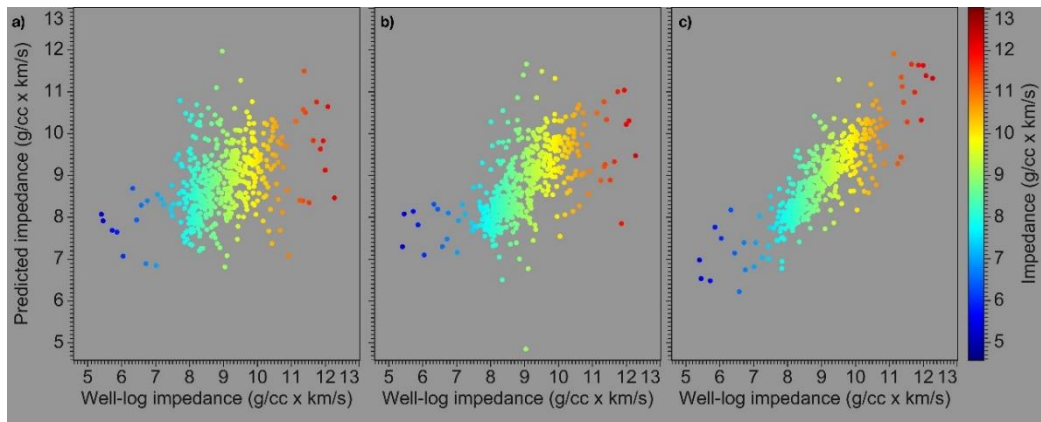


图 4.15 3 口验证井的交会图：(a)输入仅含地震数据的一维 CNN 结果；(b)同时含地震和初始模型的一维 CNN 结果，(c)同时含地震和初始模型的二维 CNN 结果。从图中可以看出，二维 CNN 的预测结果与实际测井值的匹配度最好。

表 4.2 在三个验证测井曲线上预测波阻抗的均方误差 (MSE) 对比。其中二维 CNN 预测的结果的 MSE 最小。

Methods / Validation data	MSEs by 1D CNN with seismic only	MSEs by 1D CNN with seismic & initial impedance	MSEs by 2D CNN with seismic & initial impedance
Validation Log 1	0.6051	0.5500	0.1689
Validation Log 2	0.6997	0.5599	0.2411
Validation Log 3	1.7195	1.0255	0.3854

4.4 与传统方法的对比

4.4.1 与约束稀疏脉冲反演方法的对比结果

基于稀疏脉冲反演的基本原理

约束稀疏脉冲反演假定地层的波阻抗模型对应的反射系数序列模型是稀疏分布的,它具有以下特征:(1) 基于地震道计算;(2) 加入了层位、测井、地质信息等作为约束;(3) 反演结果降低多解性,对初始模型依赖程度小;(4)在满足假定条件时才能得到较好的反演效果。

通过求解以下目标函数,找到满足条件的最小的脉冲数目,然后计算波阻抗。其目标函数为(方磊, 2008):

$$\min f = \sum |r_j|^p + \lambda^q \sum (d_i - s_i)^q + a^2 \sum (t_i - z_i)^2 \quad (4.6)$$

其中, f 为目标函数; 右边第一项 $\sum |r_j|^p$ 为反射系数绝对值的和, 第二项 $\lambda^q \sum (d_i - s_i)^q$ 为真实地震与合成地震的均方差和, 第三项 $a^2 \sum (t_i - z_i)^2$ 为波阻抗趋势协调项, 当目标函数最小时, 反射系数在测井约束下, 合成记录与实际地震数据匹配误差最小。 s_j 表示合成地震数据, d_j 表示真实的地震记录, r_j 表示反射系数, t_j 表示低频趋势, 可以是依据测井数据插值得到的低频的波阻抗模型, z_j 表示波阻抗, a 表示趋势匹配系数, q 表示地震偏差因子, p 表示与反射系数有关的因子, λ 表示控制稀疏脉冲的系数, λ 值的大小反映了实际地震记录与合成地震道的匹配程度。如果 λ 值过小, 则会强调稀疏性, 将会导致结果缺少细节, 分辨率低; 如果 λ 值过大, 则会过于强调残差要达到最小值, 过于强调数值上的拟合, 不仅会引入一定的噪音, 而且会缺少波阻抗的背景趋势, 达不到合理的结果。因此, 需要找到一个合适的值平衡两者的关系, 才能达到较好的反演效果。

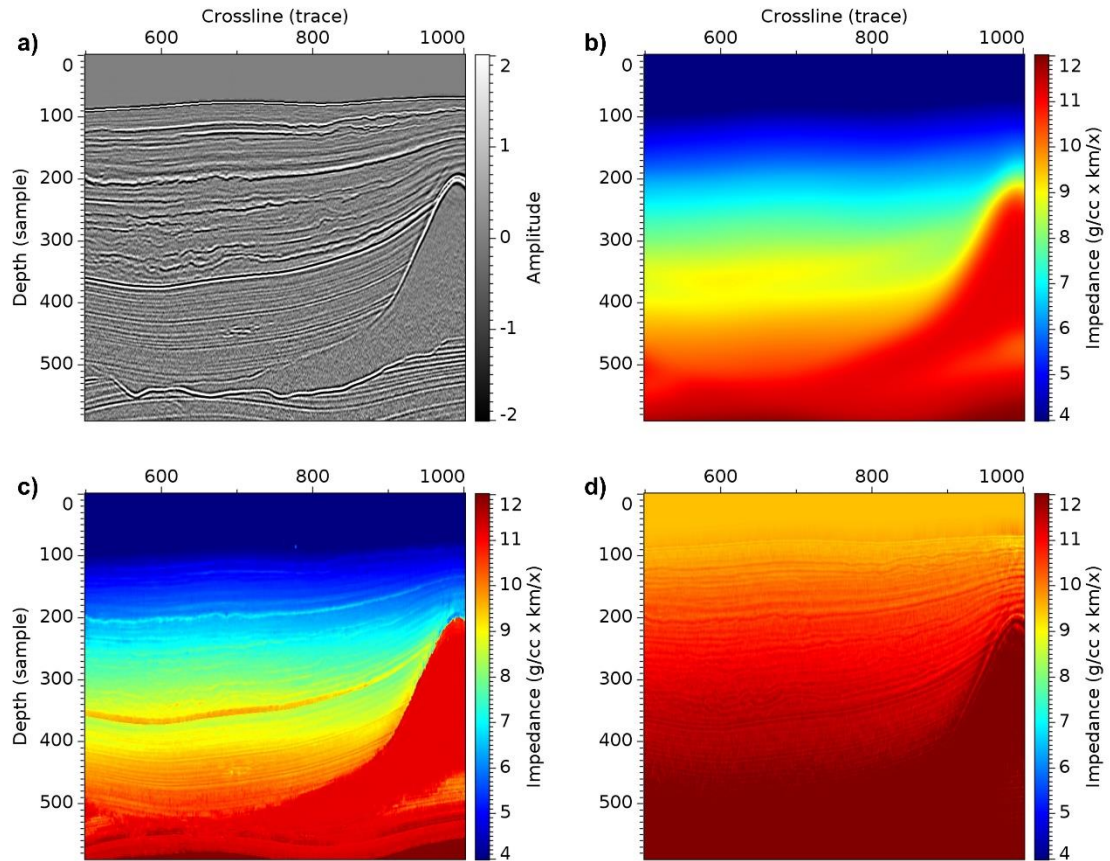


图 4.16 基于稀疏脉冲反演的结果与 2D CNN 预测结果在 SEAM 数据上的对比。(a) 二维的地震剖面；(b) 提供的初始模型作为低频约束；(c) 2D CNN 预测得到的结果；(d) 基于约束稀疏脉冲得到的结果。可以看出，基于约束稀疏脉冲得到的结果的值整体偏高，而且与地震图像的构造一致性较差。

图 4.16 中，抽取 SEAM Phase I 数据的一个二维剖面，提供一个初始的低频模型作为约束(图 4.16b),利用基于稀疏脉冲反演方法得到结果如图 4.16d 所示。与 2D CNN 反演得到的结果(图 4.16c)相比，基于约束稀疏脉冲得到的结果的值整体偏高，而且与地震图像的构造一致性较差。为了进一步对比验证，本章展示了三处测井位置处的结果，如图 4.17 所示。结果再次证明了基于约束稀疏脉冲方法的曲线（紫色）与真实井（黑色）的吻合度比较差。

4.4.2 与基于模型反演方法的对比结果

基于模型反演方法原理是，利用地震资料和测井资料先建立初始的反演模型，然后根据合成地震记录和实际地震记录的匹配效果，不断的优化参数，改进模型，经过不断的迭代，直到两者数据最佳匹配(边树涛, 2008)。该方法具有以下特点：(1) 能够有效的结合测井的信息，可以补充地震数据中缺失的高频信息；(2) 分辨率较高；(3) 但反演结果容易产生多解性。

该反演方法更适合测井分布较多而且位置比较均匀的区域，如果目标区域的

地形构造复杂，横向变化大，则需要更多的井来进行约束。由于井的数量有限且稀疏，地层的横向变化主要根据地震数据反演，所以地震数据的分辨率越高，解释的层位越多越精确，由此建立的初始模型才会更接近真实的地下模型，结合测井信息，能够得到更加准确的反演效果。通常要求在反演之前要对测井数据进行预处理和校正，使其与地震数据匹配，能够正确的指示岩性。




图 4.17 基于稀疏脉冲反演的结果与 2D CNN 预测结果在其中三口测井上的对比。黑色曲线：真实测井值；绿色曲线：提供的低频约束；红色曲线：2D CNN 反演结果；紫色曲线：基于稀疏脉冲反演的结果，数值整体比真实测井要高，与真实测井吻合差。

图 4.18 展示了 Teapot Dome 数据基于模型反演得到的结果，与图 4.13c,d 中的 2D CNN 预测结果相比，该结果分辨率低，缺少细节信息。为了进一步对比验证，图 4.19 展示了其中三口测井上的结果对比。可以看出，基于模型反演的结果（蓝色曲线），高于真实测井值（黑色曲线），偏差较大，而且没有细节构造信息。而 2D CNN 反演结果（红色曲线）变现处与真实值更高的吻合度，且遇到变化的薄层时仍有一定的效果。




图 4.18 基于模型反演在 Teapot Dome 数据上的结果，与图 4.13c,d 中的 2D CNN 预测结果相比，分辨率低，缺少细节信息。

4.5 本章小结

当地震数据和波阻抗测井数据都可用时，监督深度学习提供了一种简单而有前景的方法，可以根据地震振幅数据去预测波阻抗模型，而不需要像传统阻抗反演方法那样设计和解决大型线性或非线性系统方程。通过将记录的 1D 测井作为标签，将相应的地震道作为输入，可以很容易地训练一个 1D CNN 来逐道的从地震数据预测波阻抗模型。然而，当可用的测井曲线数量有限时，这种一维 CNN 的性能就会受到限制。尤其是从有噪声和变化多样的的结构或岩石属性的地震数据集中估计阻抗模型，对于用有限数量的稀疏测井曲线训练的一维 CNN 更加具有挑战性。在这些情况下，经过训练的 CNN 不足以呈现地震数据和阻抗之间复杂且有空间变化的关系。

为了改进简单的一维 CNN 方法，有必要引入合理的约束，这类似于通过引入良好的起始模型或正则化约束来解决传统反演方案中的不适定问题。一种可行的方法是向一维 CNN 输入初始的波阻抗序列和地震数据，这将显著提高网络预测的稳定性和准确性，而且这一方案在合成和实例中都得到了证明。另外一种可以进一步改进基于 CNN 的波阻抗预测效果的方法是使用 2D CNN，因为 2D 卷积滤波器有助于提取到横向结构特征，以预测横向更一致的波阻抗模型。然而，




图 4.19 基于模型反演在 Teapot Dome 中三口测井上的结果对比。黑色曲线：真实测井值；绿色曲线：提供的低频约束；红色曲线：2D CNN 反演结果；蓝色曲线：基于模型反演的结果，但其结果远高于真实测井值，偏差较大。

训练一个 2D CNN 并不简单直接，因为我们没有一个已知的 2D 波阻抗剖面来用作标签。本章设计了一个自适应损耗来训练包含多个测量井的不完全标签的，并通过使用与一维 CNN 相同的网络结构，结果发现二维 CNN 对噪声不那么敏感，并且能够预测一个横向上更一致的阻抗模型。此外，二维 CNN 可以提取地震数据中的横向结构特征，更准确地恢复薄层，这些薄层在垂直方向上很隐蔽，但横向延伸范围很大。

虽然本文使用的神经网络结构相当简单，但足以解决波阻抗预测问题。我们也尝试了更复杂的架构，但这些架构表现出类似的效果，却需要更多的计算成本。根据我们的经验，更多的井，更多的先验知识约束，以及更合理地使用这些数据比设计一个更复杂的网络来改善训练效果更重要。另外，与传统的波阻抗反演方法相比，本章提出的二维 CNN 的方法具有更好的效果，在地震结构的一致性以及分辨率上都比传统的方法的效果要好，得到的模型更加合理。

除此之外，本章所提出的方法也有一些局限性。第一，我们是基于假设训练区的测井曲线与预测区测井曲线完全相似进行预测的。这个假设表明，本章的一维和二维 CNN 模型，可能不能很好地推广或成功地应用到另一个工区。这也就意味着，对于每次工区我们可能需要使用新的地震数据和波阻抗测井来训练新的 CNN 模型。对于本文的两个例子，我们也训练了不同的一维和二维 CNN 模型。

尽管我们需要为不同的工区重新训练一个模型，但它在训练成本上是可以承受的。在本章的例子中，使用一个 GPU 训练 1D 和 2D CNN 分别需要大约几分钟和几小时。其实，对于大多数 CNN 模型来说，在不同的地球物理问题（包括波阻抗反演）中，泛化问题仍然是一个共同的挑战。我们尝试使用更多样化的训练数据集（来自多个工区的真实数据集和大量基于物理模型的合成数据集）来训练更广义的模型。然而，我们发现，CNN 用于阻抗（或其他岩石属性）预测的泛化性不如用于地震构造解释的问题中（例如，断层、层位和地质体检测）。直接用训练好的 CNN 模型来预测各种工区的地震阻抗是有很大的不准确性的。迁移学习可能是改进训练模型在新区域中的泛化性能的一种潜在方法，其中模型参数通过拟合新工区的新的训练数据集进行不断调整的。

另一个限制来自训练数据集。首先，本章的一维和二维 CNN 方法需要多个测井曲线来构建训练数据集。当可用测井曲线数量有限时，CNN 方法的适用性将受到限制。其次，在为一维和二维的 CNN 构建训练数据集时，需要精确的地震和测井数据的匹配关系。训练后的 CNN 模型预测的精度上界取决于测井的数量和地震测井的匹配准确度。在未来的研究中，为了减少 CNN 方法的局限性，我们可能会找到一种方法，将物理约束整合到 CNN 网络中去，以建立数据和物理同时驱动模型。

第 5 章 实例应用：Volve 数据

5.1 引言

Volve 是一个已经关闭的油田，位于北海中部如图 5.1a 所示，图 5.1b 显示了该油田的观测系统。该油田于 1993 年被发现，发展规划于 2005 年获批营运，于 2016 年关闭，于 2018 年 6 月 Equinor 发布了 Volve 数据用于学术研究 (Equinor, 2018)。该数据集包含 5TB 的数据，近 4000 个文件，包括生产数据、井设计、完井管柱设计、地震资料，测井（岩石物理和钻井），地质和地层资料，静态以及动态模型、表面和网格数据。其中有 16.3GB 的测井数据和与 24 口井相关的资料

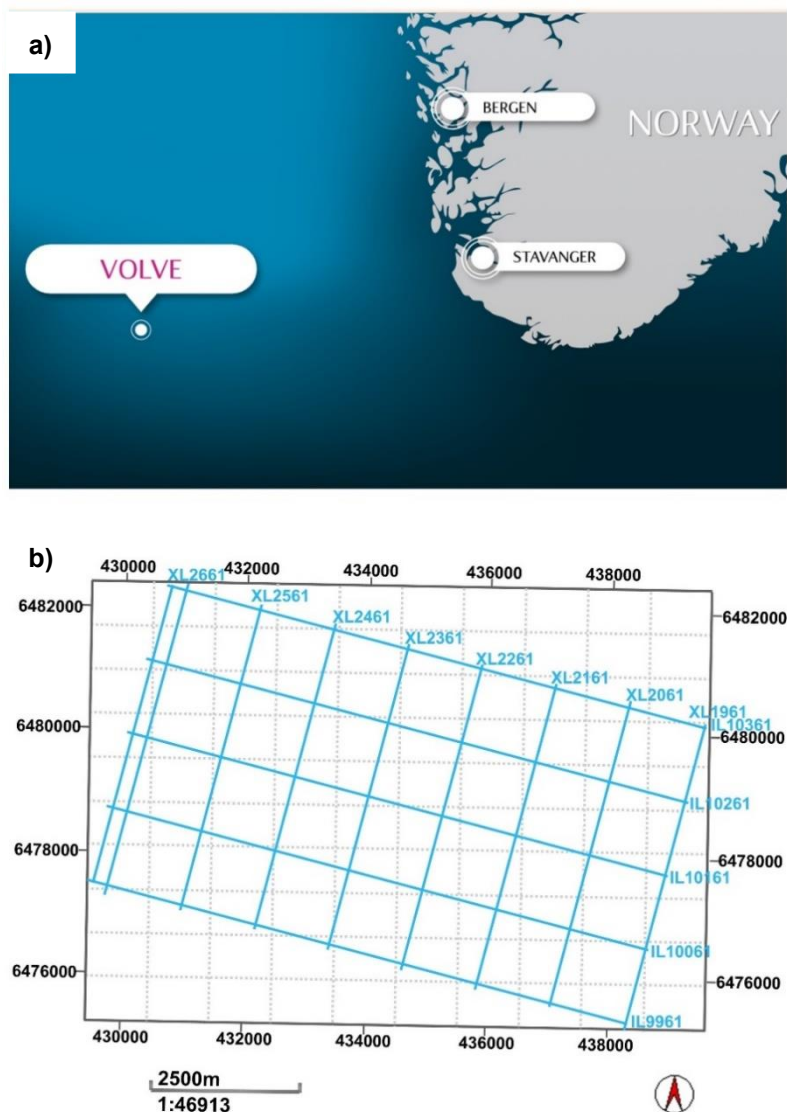


图 5.1 (a) Volve 油田位于挪威区南端的斯塔万格以西大约 200 公里处 (修改于 Equinor(2018))。 (b) 地震勘探的观测系统。

分析。它主要包括泥浆测井、随钻测井测试结果、压力测试结果、岩石物理复合材料及其解释、生产测井、完整记录和生物地层分析。在本文中，我们将重点关注地震成像数据、层位数据和测井曲线。

在本研究中，我们提出了一套通过利用地震构造、地震振幅属性和测井数据来建立地下储层参数模型的工作流程，并将其应用于公开的 Volve 数据集上验证其可行性。在本章提出的工作流程中，首先对所提供的地震数据、层位和测井曲线进行一些预处理校正，以消除异常值的影响，并对井震数据进行匹配。其次通过自动提取的方法对已提供的层位数据进行更新和改善，使其能够填充缺失的区域并在深度方向上校正到更加准确的位置，同时通过地震数据提取更多的层位面。根据获得的层位进一步计算相对地质年代体（RGT），其能隐含地代表地震构造和地层特征。然后，利用基于 RGT 导向的插值方法，根据测井数据插值得到一个初始的模型。该模型能够遵循地震地层学特征并符合测井的属性。最后，本章提出了一种多尺度卷积神经网络来预测更精确的模型，同时将初始模型作为低频约束引入网络。其完整的工作流程如图 5.2 所示。

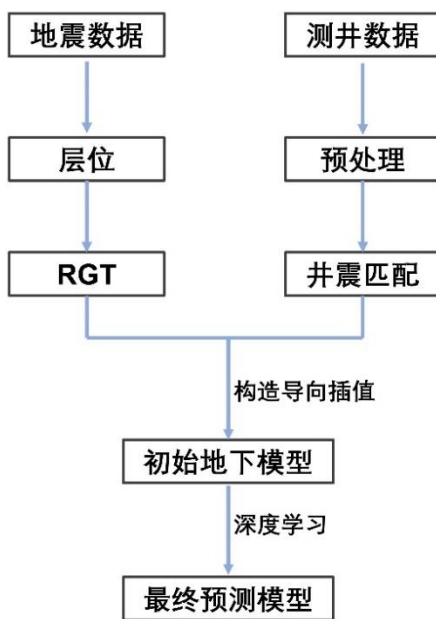


图 5.2 建立地下储层参数模型的流程图。首先对所提供的地震数据、层位和测井曲线进行一些预处理校正，以消除异常值的影响，并对井震数据进行匹配。其次对已提供的层位数据进行更新和改善，同时通过地震数据提取更多的层位面。根据获得的层位进一步计算 RGT）其能隐含地代表地震构造和地层特征。然后，利用基于 RGT 导向的插值方法，根据测井数据插值得到一个初始的地下模型。该模型能够遵循地震地层学特征并符合测井的属性。最后，通过深度学习来预测更精确的模型，同时将初始模型作为低频约束引入网络。

5.2 层位

地震层位的提取是地震解释中的一项基础和重要的工作。Volve 数据中提取的几个层位在整个工区内是不完整的，所以我们用基于动态规划的自动算法进行更新和改善。

5.2.1 层位的更新和提取

Volve 工区的深度域叠后地震成像如图 5.3a 所示，同时提供了与地震图像相对应的 5 个层位如图 5.3b 所示。但这些解释的层位在水平方向上有缺失而且不够准确，不能够追踪一致的地震反射轴。因此，本章用基于动态规划的算法 (Yan et al., 2021) 对其进行改进，使其填充缺失区域并更新其深度方向上的准确度。

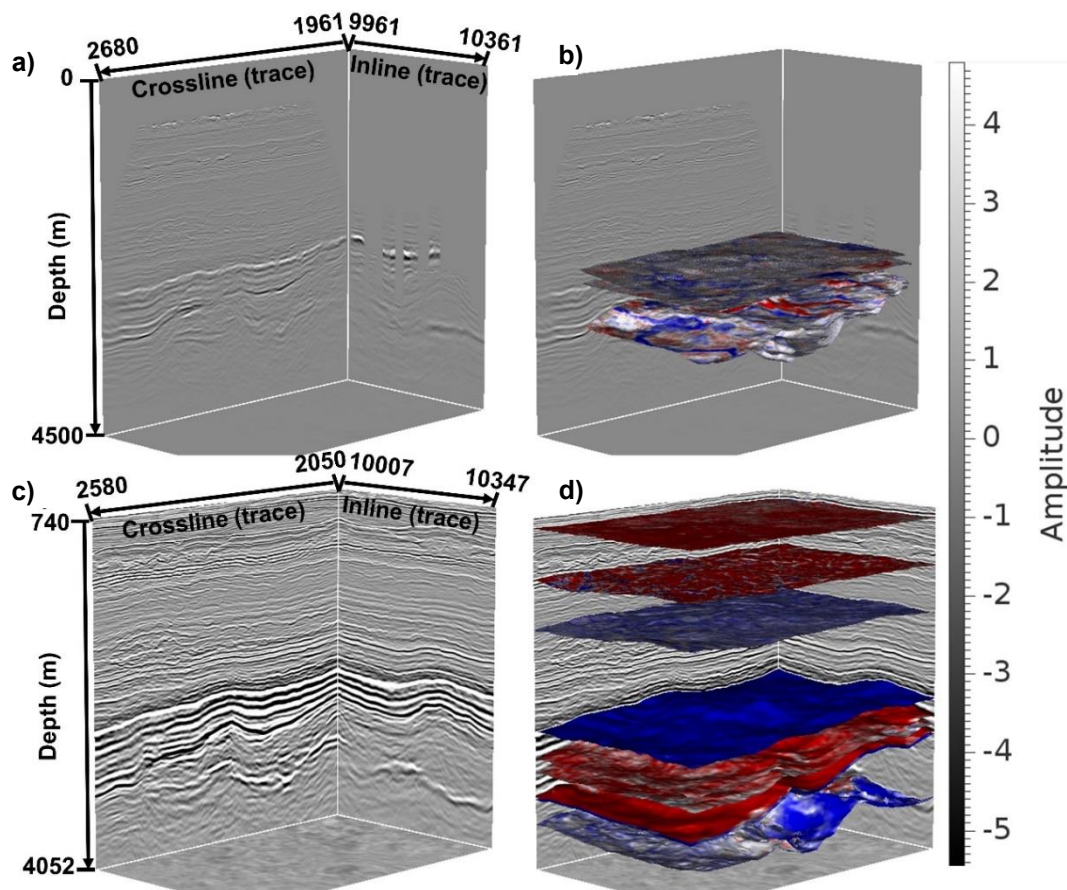


图 5.3 (a) Volve 油田三维叠后地震成像。(b) 随地震图像一起提供的层位，在整个工区内横向是不完整的，也不够准确，不能跟踪一致的反射轴。(c) 切除浅部和坏道之后的地震图像。(d) 所提供的层位得到改进（更一致地跟随地震反射并填补缺失的区域），并用自动方法提取一些其它的层位。

此外，我们也用此自动提取方法拾取更多的层位（如图 5.3d）以便获得更准确的地层格架。图 5.3c 展示了切除浅部和坏道之后的地震图像，在后续的实验中也将会使用此图像和其对应的层位以及井数据。

为了更加清楚地对比层位改进前后的效果，本章选取了其中一个层位进行展示，如图 5.4 所示。该图展示了包含目标层位（绿色箭头所示的波谷位置）的部分地震图像（图 5.4a）。图 5.4b 中显示了随地震数据一起提供的已解释好的层位，然而可以看到提取的层位有明显的的不一致性，表面上的颜色变化表明该层位在波峰和波谷之间来回跳跃（红色代表波谷位置，蓝色代表波峰位置）。因此本章用基于动态规划的方法对(b)中的结果进行更新，得到如图 5.4c 所示的结果，其表面一致的红色表明更新之后的层位能够更加准确地追踪一致的波谷位置。为了更好地对比说明两者结果的准确性，本章沿着深度-横测线方向提取了一个二维剖面

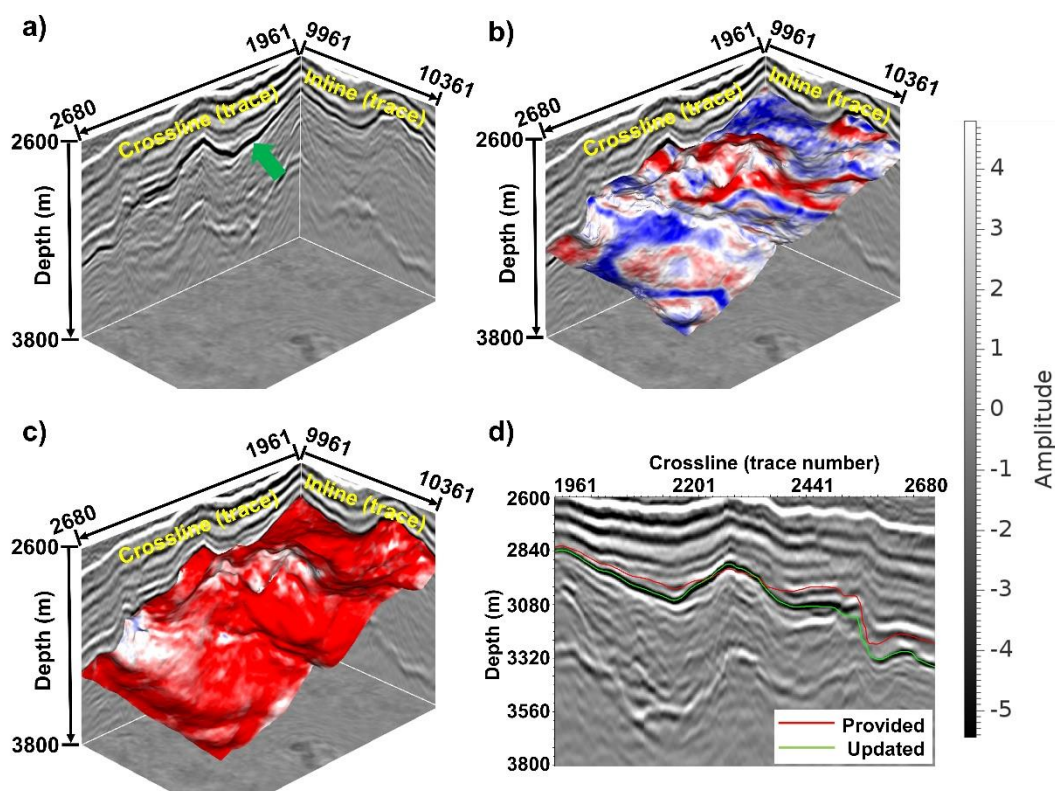


图 5.4 单个层位改进示例。(a) 选取的部分地震图像，绿色箭头指示期望提取的目标层位。(b) 随地震图像一起提供的层位，在整个工区内横向不准确，层位面上明显的颜色变化表明其不能追踪一致的反射轴（红色指示波谷，蓝色指示波峰）。(c) 利用动态规划算法对(b)中所提供的层位进行更新改进，可以看到其颜色更加统一，表明改层位能够追踪一致的波谷位置。(d)沿着横测线-深度方向的一个二维剖面，改进后的层位（绿色曲线）明显比数据集提供的层位（红色曲线）的位置更加准确。

面（图 5.4d），可以观察得到基于动态规划方法获得的层位（绿色曲线）比原本提供的层位（红色曲线）更加准确，能够追踪与地震构造相一致的反射轴信息。

5.2.2 RGT 的计算

如本文中的第三章所述，首先对提取的每个层位（图 5.3d）定义一个相对地质时间，然后利用三次插值算法计算层位之间的 RGT 值，就可以得到如图 5.5 所示的 RGT 体，它可以被看作是代表着地震构造和层序特征的隐式构造模型。




图 5.5 通过地震数据和层位计算得到的相对地质时间（RGT）体，可以被看作是代表着地震构造和层序特征的隐式构造模型。

5.3 测井

测井资料是建立初始模型的基础资料，是进行地质解释的基础，它是指示岩石属性的最准确记录。Volve 数据集有 20 口井，包括速度、密度、阻抗、伽马和孔隙度等不同属性（如表 5.1 所示），其中阻抗测井是通过速度和密度测井来计算得到的。该数据集中的井均为斜井，如图 5.6 所示。然而，测井资料往往受到井壁坍塌、泥浆浸没等井眼环境的影响。并且不同的测量时间和测井仪器也会对测井资料产生不同程度的影响。因此，为了减少这些因素影响，需要对本文用到的测井数据进行校正。

图 5.7 展示了测井 15_9-F-4 记录中不同的属性曲线。本章主要对其进行以下预处理：去除缺失部分，井的顶部和底部的测量畸变以及在两部分曲线连接处的测量断面和异常点（如图中的红色矩形所示）。此外，也必须剔除一些不合理的异常值，如毛刺噪声（黑色圆圈所示），因为这些异常值往往会产生很强的幅值，导致其压制有效信号之间的正常相对关系。而且测井的采样率往往比地震的采样

率高很多倍，因此我们采用中值滤波的方法对其进行预处理和重采样使其与地震数据相匹配。

测井和地震数据之间的匹配对地震解释也是非常重要的工作，目的是为了使得井位置测量的岩性与地震数据一致。本文中采用的地震成像数据是深度域的，一样需要利用合成地震记录和层位信息进行测井和地震数据的匹配。图 5.8 展示了其中一个井震匹配的例子。本文选择速度测井 $v(z)$ (红色曲线) 和密度 $\rho(z)$ (绿色曲线) 在相同的深度范围内，如图 5.8a 所示，计算反射率序列 (图 5.8b) 如下方程所示 (Sheriff et al., 1995):

$$r(z_1) = \frac{\rho_2(z_2)v_2(z_2) - \rho_1(z_1)v_1(z_1)}{\rho_2(z_2)v_2(z_2) + \rho_1(z_1)v_1(z_1)} \quad (5.1)$$

其中 z 表示深度

表 5.1 Volve 数据集中的 20 口井包含的不同属性，包括速度、密度、波阻抗、伽马和孔隙度。其中，对号表示包含其属性。

Names Properties	15_9-F-1	15_9-F-1-A	15_9-F-1-B	15_9-F-1-C	15_9-F-4	15_9-F-5	15_9-F-9	15_9-F-9-A	15_9-F-10	15_9-F-11-A
Velocity	√	√	√		√	√			√	√
Density	√	√	√	√	√	√			√	√
Impedance	√	√	√		√	√			√	√
Gamma	√	√	√	√	√	√	√	√	√	√
Porosity	√				√	√				
Names Properties	15_9-F-11-B	15_9-F-11-T2	15_9-F-11	15_9-F-12	15_9-F-14	15_9-F-15	15_9-F-15-A	15_9-F-15-B	15_9-F-15-C	15_9-F-15-D
Velocity		√		√	√	√	√			
Density	√	√		√	√	√	√	√	√	
Impedance		√		√		√	√			
Gamma	√	√	√	√	√	√	√	√	√	√
Porosity				√	√	√	√	√		




图 5.6 Volve 数据集中的测井的平面图。




图 5.7 测井 15_9-F-4 的不同属性曲线图。井记录中经常会有部分的缺失或者异常值（红色方形框所示），或者一些毛刺噪声（如黑色圆圈所示）。

然后，我们简单地计算出实际地震数据的主频，据此选择合适的雷克子波，通过将反射率序列与雷克子波卷积获得合成地震图像（图 5.8c），并根据井位置

从地震数据中利用插值算法提取真实的地震图像（图 5.8d）。最后，根据在测井上的岩性标注点和地震数据上拾取的对应的层位进行手动匹配，图中主要反射轴区域（黄色箭头所示）匹配好后，进而得到井在深度方向上的校正量。按照此方法，对所有的井进行井震匹配的校正，增加地质建模的准确性。

在图 5.9 中，展示了地震数据和测井数据匹配效果的影响。首先，本章使用简单的最近邻插值方法，利用 12 口速度井曲线（如图 5.9a 所示），获得 RGT 导向的速度模型（图 5.9b）。图中有一些区域（如白色箭头所示）可以看到很明显的 discontinuity，这是因为测井位置和地震数据在深度方向上的不一致性导致的不合理的插值结果。在进行如图 5.8 所示的井震匹配之后，再次使用最近邻插值方法进行 RGT 导向的速度模型插值，可以看到图 5.9b 中白色箭头所示的区域得到

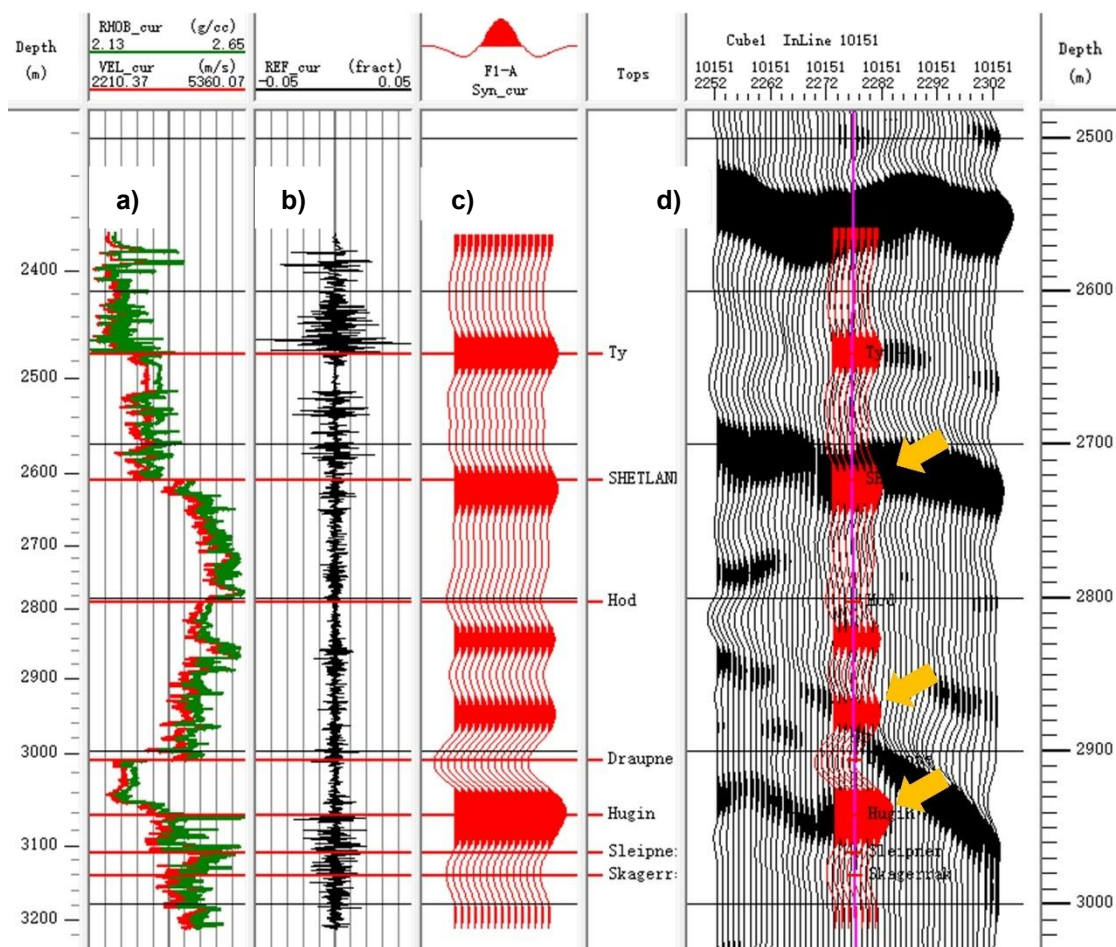


图 5.8 井震匹配流程图。选择速度（红色）和密度（绿色）测井曲线（(a) 中所示），计算得到反射系数（b）。然后选择合适的子波，通过反射系数和子波进行卷积得到合成的地震图像如（c）图所示。（d）图为邻近井位置提取的实际的地震记录。最后通过匹配合成的和实际的地震图像得到井在深度方向上的校正量。图中主要反射轴区域（黄色箭头所示）匹配良好。

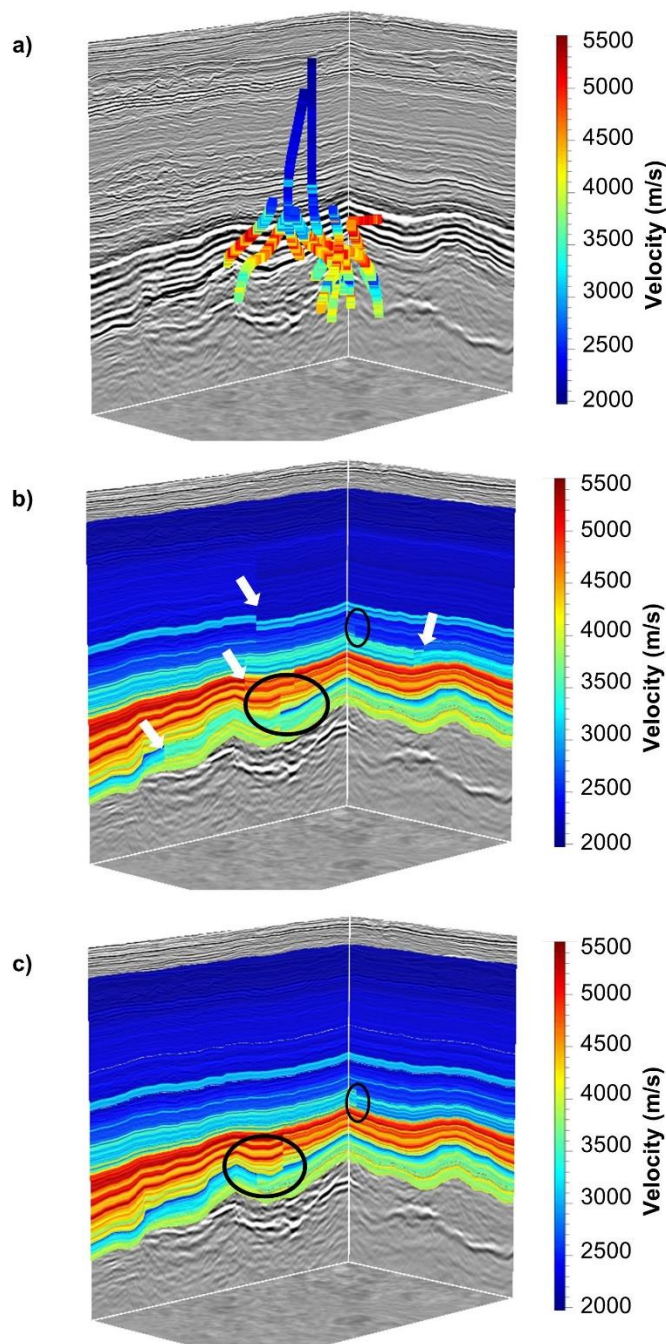


图 5.9 井震匹配效果。使用简单的最近邻插值方法，利用 12 口速度井曲线 (a)，获得 RGT 导向的速度模型。在进行井震匹配前的结果 (b) 中有明显的不连续区域 (如白色箭头所示)，这是因为测井位置和地震数据在深度方向上的不一致性导致的不合理的插值结果。在进行井震匹配之后，同样进行插值得到结果 (c)，可以看到 (b) 中白色箭头所示的区域得到明显的改善。如黑色圆圈所示的区域未得到改善的原因可能是，均是斜井且距离比较近，在进行插值的时候可能会造成彼此之间的冲突。

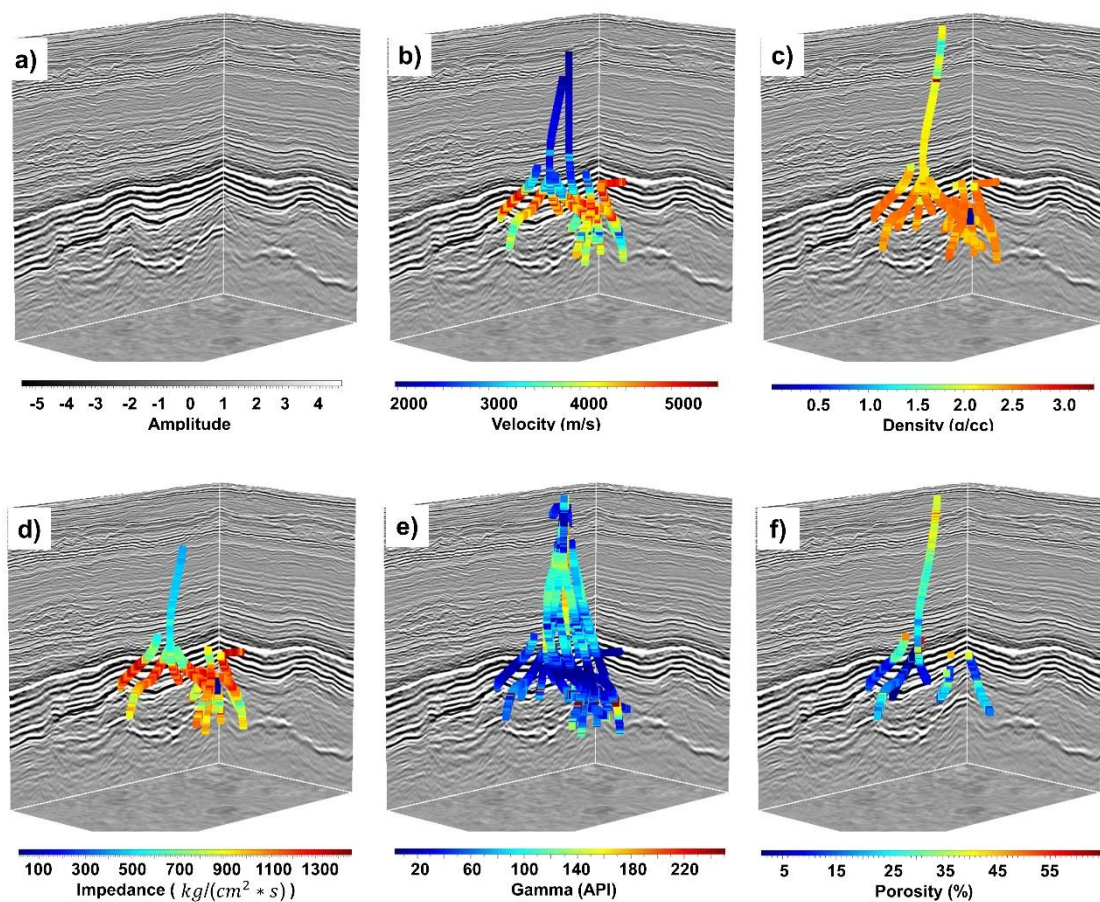


图 5.10 不同属性的测井在三维地震图像中的展示图。(a)12 口速度测井；(b)14 口密度测井；(c)12 口波阻抗测井；(d)21 口伽马测井；(e)9 口孔隙度测井。

明显的改善，保持了良好的一致性，与地震的反射特征一致。当然，也有一小部分区域（如图中的黑色圆圈）在图 5.9c 中却未能得到提升，可能的原因是本数据集为海上数据，所有的井均是斜井，而且距离比较近，多口井在同一深度的可能有不同的数值，所以在进行插值的时候可能会造成彼此之间的冲突。图 5.10 展示了不同属性的测井在三维地震图像中的分布情况。

5.4 储层参数建模

为了建立准确的地下储层参数模型，本章提出了一种基于低频约束的卷及神经网络(CNN) 来反演不同属性的地下模型。

5.4.1 RGT 导向插值的初始模型

根据已有的相对地质年代体（RGT）和测井数据，可以 RGT 为导向，通过外插测井属性来获得初始模型，具体如第三章所述。

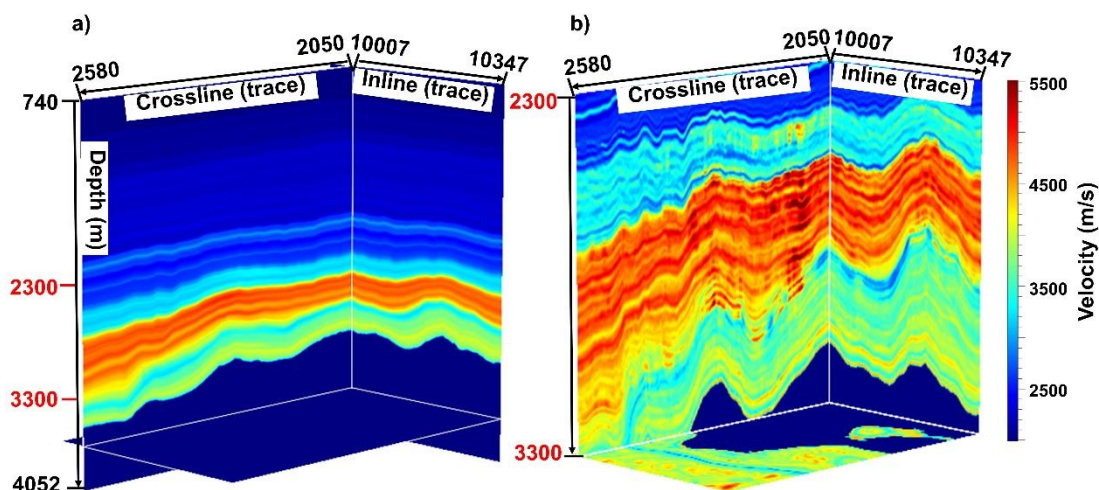


图 5.11 (a) RGT 导向的速度模型；(b) 基于 CNN 预测得到的最终模型。由于主要的储层在 2750m - 3120m，因此在(b)中主要展示 2300m - 3300m 之间的模型结果。可以看到基于 CNN 的模型在垂向分辨率更高，更符合地震图像的特征。

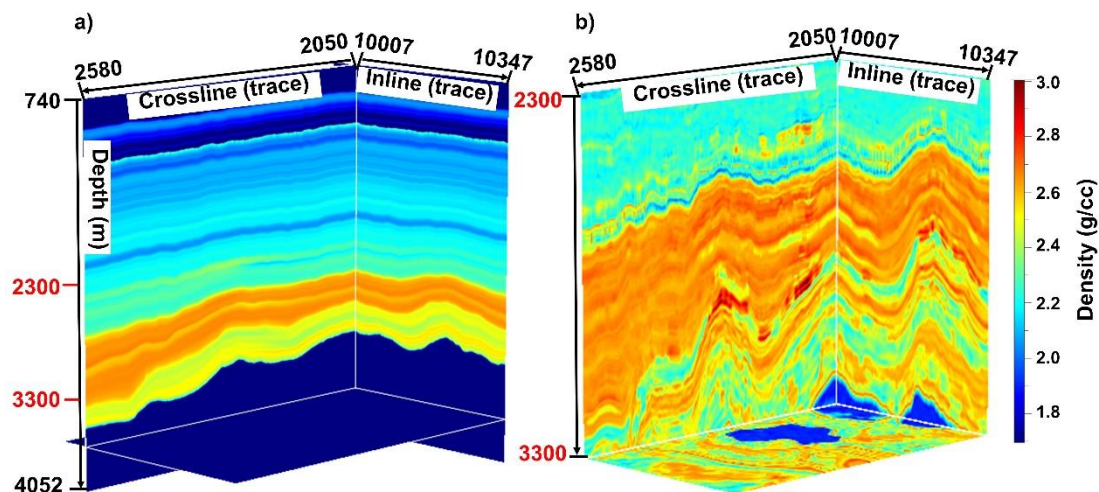


图 5.12 (a) RGT 导向的密度模型；(b) 基于 CNN 预测得到的最终模型。由于主要的储层在 2750m - 3120m，因此在(b)中主要展示 2300m - 3300m 之间的模型结果。可以看到基于 CNN 的模型在垂向分辨率有所提升。

图 5.11-5.16 中的(a)图均为从井的不同属性获取的初始模型。但是由于测井数据非常有限，所以初始模型通常比较光滑并且缺少很多细节部分。除此之外，由于 RGT 不是完全地准确，会给我们引入错误的信息，特别是离测井位置较远的地方。因此，本文尝试使用深度学习方法来进一步提高初始模型的准确性。

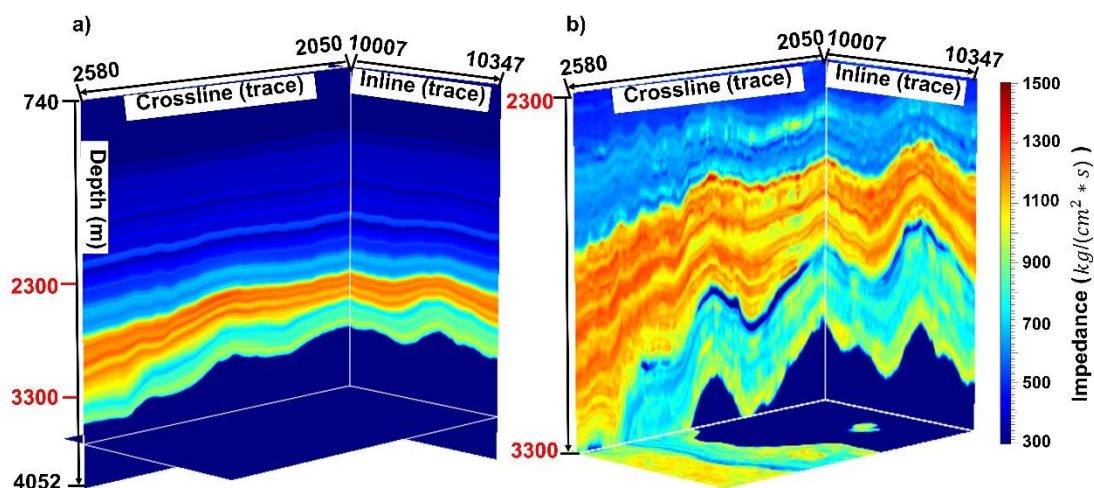


图 5.13 (a) RGT 导向的波阻抗模型；(b) 基于 CNN 预测得到的最终模型。由于主要的储层在 2750m - 3120m，因此在(b)中主要展示 2300m - 3300m 之间的模型结果。可以看到基于 CNN 的模型在垂向分辨率有所提升，横向连续性较好。

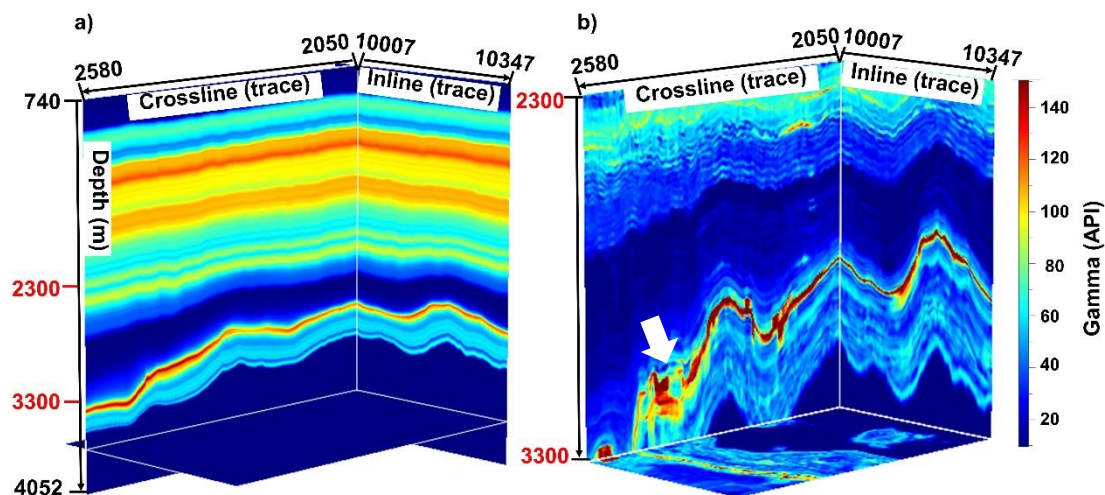


图 5.14 (a) RGT 导向的伽马模型；(b) 基于 CNN 预测得到的最终模型。由于主要的储层在 2750m - 3120m，因此在(b)中主要展示 2300m - 3300m 之间的模型结果。可以看到基于 CNN 的模型在垂向分辨率更高，但在白色箭头所示的区域的连续性较差。

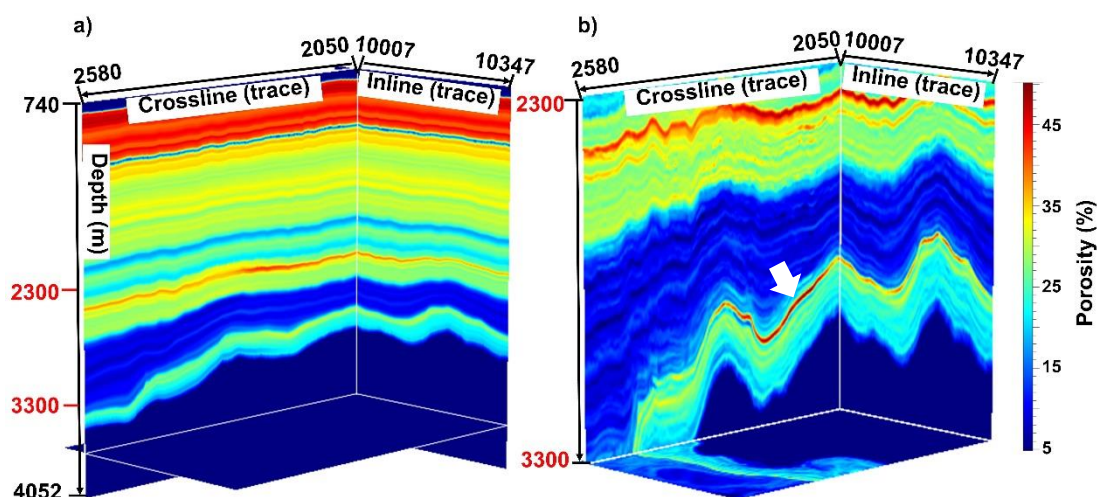


图 5.15 (a) RGT 导向的孔隙度模型；(b) 基于 CNN 预测得到的最终模型。由于主要的储层在 2750m - 3120m，因此在(b)中主要展示 2300m - 3300m 之间的模型结果。可以看到基于 CNN 的模型在垂向分辨率更高，更符合地震图像的特征，而且在白色箭头所示的反射层的结果有横向变化，更加合理。

5.4.2 基于深度学习的最终模型

为了解决地球物理反演问题，通常会需要一个初始模型，然后通过多次迭代更新来获得最终可靠的结果。受此启发，我们将初始模型（图 5.11a-5.15a）引入到本章的训练网络中。

1. 数据集

地震成像数据（828（深度） \times 530（横测线） \times 340（纵测线））包括深度相同的 20 口测井曲线。本章使用一维 CNN 训练网络，并且提取了测井位置处相应的地震道数据和初始的插值参数模型数据。图 5.16 显示了一个训练对的例子。包括地震道（黑色实线），实际测井曲线（红色实线）和插值出来的初始值（黑色虚线）。插值后的模型提供了一个低频约束以使反演结果与实际测井结果更加一致，有助于获得更合理的结果。




图 5.16 训练数据对的示例。黑色实线代表地震道，红色实线代表实际的测井曲线，黑色的虚线代表插值得到的初始值。

2. 网络架构

本章提出了如图 5.17 所示的网络体系结构。输入包括两个通道，一个是地震道数据（黑色实线），另一个是插值出来的波阻抗曲线（黑色虚线），输出是相应的测井曲线（红色曲线）。网络包含几个具有不同内核的多尺度块以提取不同尺度的特征。在本章的实际训练过程中，我们使用样本大小分别为 9, 13 和 23 的多尺度块，其中每个块有 32 个通道（图 5.17b）。然后将这些通道连接起来作为输入进入下一个卷积层。将 ReLU 激活方法应用于除了最后一层的所有卷积层的输出，最后一层使用线性激活。

最常用的损失函数是回归问题中的 MSE（均方误差），因此本章使用该值来衡量真实值和预测值之间的误差：

$$L_2 = \frac{1}{N} \sum_{i=1}^N (p_i - r_i)^2, \quad (4.1)$$

其中 p_i 和 r_i 分别表示预测波阻抗和真实波阻抗。 N 为测井数据的总采样点数。在具体的实现中，本章使用 MSE 损失函数来评价网络的性能好坏。




图 5.17 多尺度卷积神经网络架构。(a)本文使用的网络架构。(b)多尺度模块。利用不同的卷积核大小提取不同尺度的特征，然后将其并联作为下一层的新输入。

3. 预测结果

如上所述，本章在反演流程中对初始模型进行了低频约束。图 5.18 显示了伽马数据的预测值和真实测井记录的比较情况。从结果对比可以看出在插值的约束下（蓝色实线），预测伽马值（黑色实线）整体上能拟合实测数据（红色实线）。预测曲线呈现出更多的高频特征。例如，预测结果能很好地拟合 3000 m 深度处的实测数据。并且在主要的反射层的效果要优于薄层。




图 5.18 四口验证井的预测结果对比分析。插值的模型（蓝色曲线）作为低频趋势输入到网络当中，得到的预测结果（黑色曲线）与实际的测井（红色曲线）大体上匹配一致（例如黄色箭头所示），但也有匹配不够理想的地方（如蓝色箭头所示），原因可能受到周围井或者噪音的影响。

如图 5.11-5.16 中的(b)图所示，我们逐道进行一维 CNN 的预测，并用三维显示出模型结果。本文主要通过 2300-3300m 深度位置来显示深度学习的反演结果，因为 Volve 油田储集层的侏罗纪砂岩主要分布在 2750-3120m TVDss。对所有测井属性参数来说，这些预测结果在深度方向上基本都显示出了较高的分辨率。

为了能够更加清楚地看到预测结果的局部细节，本章选取了一个沿横测线-深度方向的二维地震剖面（如图 5.19 第一列所示），并展示相对应的基于 RGT 插值的初始模型（第二列）和基于卷积神经网络的预测结果（第三列）。首先，本章的结果显示基于 CNN 的预测结果与插值的结果相比更为合理，也显露了更多的高频信息特征。这也证明了具有不同卷积核大小的多尺度模块可以提取更丰富的特征（图 5.19 中白色箭头所示）。此外，预测结果与地震构造相一致，与插值的结果相比横向更加合理。例如，我们可以看到在地震剖面中存在一个断层（图 5.19 第一列图像中的黑色虚线），反演剖面中的砂岩层和泥岩层的分布受到该断层的控制。结果表明，基于 CNN 的预测结果更加吻合层序地层格架和构造

(如图 5.19 c,i,l,o 所示)。

本章还比较了深度学习和基于稀疏脉冲的传统方法的结果。图 5.20 展示了一个波阻抗反演的例子。如图 5.20a 所示,在横向-深度方向上提取了一个二维地震切片。图 5.20b 是基于稀疏脉冲方法的反演结果,结果更符合地质特征,但在深度方向上分辨率较低。然而,预测出的波阻抗在深度方向上揭示了更多的细节(图 5.20c)。

Volve 数据集中的 Hugin 储层主要是由海相砂岩,粘土岩和石灰岩组成(Varadi et al., 1998; Kieft et al., 2010)。Hugin 储层主要分布在深度范围 2750 m 到 3120 m 之间(在 TVDSS 中),厚度变化从 20 m 到 100 m(Sen et al., 2019)。与周围地层相比,Hugin 储层具有相对较高的速度,高密度,高阻抗,低伽马值以及低孔隙度等特征。岩石物理分析表明,细粒至粗粒砂岩的伽马值为 10 至 46(API),DT 值为 175 至 315 (us/m),RHOB 的范围为 2.280 至 2.820 (kg/m³)(Sen et al., 2019)。本章的结果表明,反演得到的五中属性基本符合 Hugin 储层的特征,进一步证明了所提出的工作流程的有效性。

在本章的实际算例中,训练数据集是基于来自井的可用信息生成的。测井数据的质量对反演结果的准确性有着重要的影响。但是,由于 Volve 油气田的测井都是倾斜的,因此该区域的数据分析解释面临极大地挑战。当提取井位附近的地震道时,由于插值处理,可能会产生一些假象。而且当多个井之间的距离较小时,我们认为这些井所在区域的地质情况不会改变。因此,只选择了一小部分井来生成训练数据集。增加训练井的数量不能显著提高反演结果的准确性和垂向分辨率,反而可能会在反演过程中带来一些假象。

从测试结果可以得出,我们认为在反演过程中数据本身比网络起着更重要的作用。即使使用简单的 CNN 网络,但数据集更合理,也可以提高结果的准确性。此外,在构建初始模型中同时考虑断层的分布,可以更符合地质特征,从而提供更合理的约束。总体上来说,本研究使用基于层序和结构的深度学习方法提出了一种更快,更好的地下建模流程。这种数据驱动的反演方法还可以应用于其他更复杂的建模问题中,但要引入严格的层序地层约束,例如相建模。

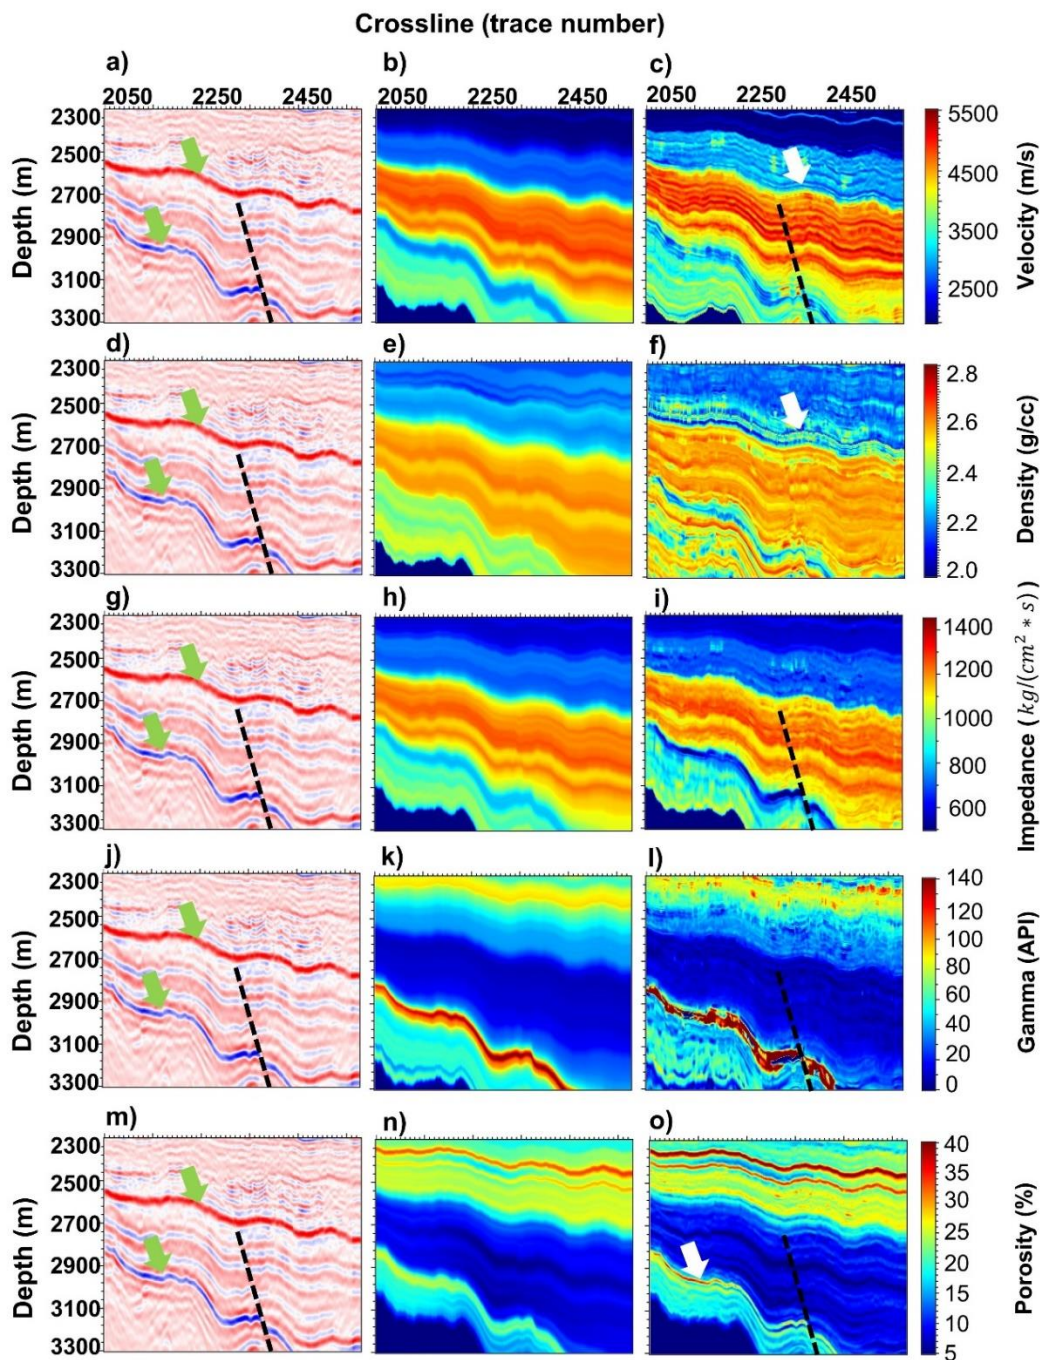


图 5.19 为了更加清楚地显示预测结果的局部详细信息，显示了二维地震切片（第一列），基于 RGT 插值的初始模型（第二列），以及通过本章的 CNN 方法预测的最终结果（第三列）。结果显示基于 CNN 的预测结果与插值的结果相比更为合理，也显露了更多的高频信息特征。说明具有不同卷积核大小的多尺度模块可以提取更丰富的特征（白色箭头所示）。此外，预测结果与地震构造相一致，与插值的结果相比横向更加合理（例如，黑色虚线的断层处）。




图 5.20 基于稀疏脉冲的传统方法(b)与基于深度学习的结果(c)的对比。基于稀疏脉冲的方法可以追踪地震结构，但在深度方向上分辨率较低。

5.5 本章小结

本章提出了一个完整的包含地震结构解释，层位导向的测井数据解释以及基于深度学习的岩石属性估计的工作流程，以构建合理的地下储层参数模型。本章已将整套该工作流程应用到公开的 Volve 数据集上，首先通过预处理和井震联合分析去除异常数据，并使测井曲线与地震成像结果垂向上对齐。其次，本章使用自动化方法优化层位以填补缺失区域和符合地质特征，提取更多的层位。然后用这些可以表示地震构造和地层特征的层位对 RGT 体进行插值。第三，本章使用基于 RGT 的插值来获得初始模型，以与测井特性和地震构造保持一致。最后，本章使用多尺度 CNN 借助低频约束的初始模型，从地震和测井数据中预测最终的模型。结果表明，本章的工作流程可以获取可靠的储层参数模型并显示出较高的垂向分辨率。

第6章 结论和展望

6.1 结论

建立精确的地下模型对精确的储层预测至关重要。本文提出了一个完整的包含地震层位解释,层位导向的地层模型的建立以及基于深度学习的岩石属性估计的工作流程,以构建合理的储层参数模型。本文中所研究的内容主要有以下几个方面:

1. 针对目前提取地震层位的方法中存在的问题(耗时长;地震数据中同相轴不连续的区域(例如,断层、噪音等),无法自动提取相位一致的精确的地震层位,并且往往由于过度平滑而缺失一些地质结构的细节信息等),本文提出了基于动态规划的方法,解决上述问题,以获得更加准确的层位。在这种方法中,本文首先使用自动方法、人工拾取或用几个控制点插值来计算一个初始层位。该初始层位可以不准确,只需要符合目标层位的总体趋势即可。然后提取以初始层位为中心的子区域,并根据初始层位使子区域整体拉平。最后,利用动态规划来有效地选择整个子区域中的最优路径,即全局最大或最小振幅值得路径。通过此方式,我们能够将初始的不准确层位更新为一个更精确的层位,该结果遵循一致的振幅峰值、谷值或零交叉。由于本文的方法并不严格依赖于初始层位,因此我们更倾向于直接从有限数量的控制点插值得到初始层位,这比自动或手动提取初始层位时在计算上更有效。此外,本文的方法可以通过编辑或移动控制点时进而实时交互实现更新层位的目的。更重要的是,这些控制点不需要精确的放置在目标的层位上,在其附近即可,这能够大大降低计算成本,节约时间,可以有效且快速地实施人工交互功能。本文利用多个二维和三维的复杂实际数据来验证提出的方法,结果也表明本文提出的方法能够有效地拾取正确的地震层位,甚至在地震数据中复杂的不连续区域(例如,断层、噪音等),依然能够准确地自动追踪相位一致的地震层位,能够很好地揭示详细的地质结构信息,在地震解释中有很好的应用前景。

2. 本文利用二维卷积网络(CNN)实现基于深度学习的波阻抗预测,并将初始波阻抗模型的作为低频约束引入到该网络中,该初始模型可以从几个测井曲线利用地震构造导向的插值方法得到。大量的测试例子证明,加入约束条件能够使1D和2D的CNN网络产生稳定的波阻抗预测结果。本文提出的二维的卷积神经网络的架构非常简单,但是由于我们利用特殊的方式得到很多的训练数据,解决了二维波阻抗标签的问题。首先定义一个随机路径可以穿过一定数量的测井位置,

然后沿着这个路径去提取一个二维的地震剖面和对应的初始模型剖面作为二维网络的输入,穿过该路径的所有测井作为波阻抗剖面相对应的部分标签。有了这些随机抽取得到的二维训练数据集,并定义自适应损失函数,即网络输出的二维波阻抗模型仅在有井的地方进行验证评估。由于二维的数据训练集是从最原始的三维数据中从各个方向随机选择的,所以能够保证其空间的连续性。合成和实际的例子也表明,相对于一维卷积神经网络,本文提出的二维卷积神经网络不仅对噪音的干扰反应更加稳定、能够更好得恢复出薄层(分辨率高),而且具有较好的横向连续性。

3. 以 Volve 油田的数据为例,本文提出了一套完整工作流程,充分利用地震振幅、测井属性和地震构造特征来建立合理的储层参数模型。首先,对所提供的 Volve 地区的地震资料、层位和测井曲线进行预处理,去除异常值并进行井震关系匹配。其次,使用文中提出的基于动态规划的方法来填补层位所缺失的地方,并改进所提供的层位的准确度,同时获取更多的层位。然后根据地震数据和提取的层位计算相对地质年代体(RGT),它被认为是一个隐含的结构模型,代表地震构造和地层特征。然后,以相对地质年代体为导向,融合测井数据,插值得到初始的储层参数模型。但由于井的稀疏性,该模型往往是不够准确的,因此本文进一步利用深度学习方法结合地震和测井数据预测最终的模型,同时将初始模型作为低频约束引入网络。结果表明,本文所提出的工作流程能够产生合理的储层参数模型模型,而且在垂向上具有更高的分辨率,在横向上也能够得到更加一致的结果。

6.2 展望

1. 本文提出的基于动态规划的地震层位提取方法,只需要少量的控制点,而且对控制点不敏感,可以高效、方便地进行层位解释。因此它很适合作为一种人工交互式的方法来实现,以便在编辑控制点的同时快速更新层位,我们也正在计划将该方法嵌入到人工交互的公开平台。但是该方法中存在一定缺陷,本文使用地震振幅图像作为输入,通过假设一个层位遵循一致的相位或振幅值来提取层位。然而,一些复杂的情况下,相位可能沿着层位发生改变,此时这个假设不一定是成立的。在这些情况下,可能需要使用一些其它更合适的地震属性代替振幅属性。在新属性中,目标层位可以被转换成全局最大或最小路径(二维)或曲面(三维),因此我们需要考虑更多的属性来完善该方法。此外,本文提出的方法一次只能从地震图像中提取一个单一的层位,因此在后续的研究中将考虑改进方法来实现可以一次同时提取多个层位的目的。

2. 本文提出的利用二维神经网络来进行波阻抗的预测,并引入初始波阻抗模

型的约束到该网络。结果表明在测井路径为直井的时候比斜井有更好的效果。这是因为在直井的情况下，在准备训练数据集时，可以选择一个随机路径穿过一定数量的测井位置，然后沿着这个路径去提取一个二维的地震剖面和对应的初始模型剖面作为二维网络的输入，同时穿过该路径的所有测井作为波阻抗剖面相对应的部分标签。利用此方法可以大大增加训练数据的数量，因此可以得到预测结果也会更加准确。而在 Volve 油田的例子当中，所有的井都是倾斜的，无法按照此方法去随机提取多个二维剖面，因此训练数据集是非常有限的。测井校正的准确性很大程度上影响着反演结果，可以进一步考虑将斜井映射到地震剖面上转化成直井后反演的做法。另外由于测井的位置离得很近，在反演属性的时候如何更加有效地选择测井的位置和数量也值得继续研究。

3. Volve 油田的数据非常丰富，目前本文只利用了地震数据、层位和测井数据。我们将考虑把断层构造加入到相对地质年代体的计算过程和地质建模，期望能够获得更加准确的储层模型。该数据集中也包含了丰富的岩性划分信息，考虑可以结合已提供的信息，融入地质学家丰富的经验，对该地区进一步进行研究。另外，该地区也提供了叠前数据，其包含的信息更加丰富，因此如何利用叠前数据进行地震反演也值得进一步探究。

参考文献

- 边树涛. 2008. 高精度储层反演技术及含气检测方法的研究与应用[D]. 中国地质大学 (北京).
- 方磊. 2008. 地震波阻抗反演及其在储层预测中的应用研究[D]. 成都理工大学.
- 井斯亮. 2017. 基于模型的波阻抗反演在辽河地区的应用[D]. 吉林大学.
- 付庆云. 2012. 求解非线性反问题的稀疏约束正则化方法研究[D]. 大连海事大学.
- 刘凤, 张瑞香, 张广旭, 等. 2017. 基于模型测井约束地震反演[J]. 内江科技, 11.
- 刘喜武, 年静波, 吴海波, 等. 2005. 几种地震波阻抗反演方法的比较分析与综合应用[D].
- 刘百红, 李建华, 魏小东, 等. 2009. 随机反演在储层预测中的应用[J]. 地球物理学进展, 24(2):581-589.
- 叶云飞, 崔维, 张益明, 等. 2014. 低频模型对波阻抗反演结果定量解释的影响[J]. 中国海上油气, 26(6):32-36.
- 吴华. 2015. 地震储层反演方法研究及应用[D]. 中国地质大学 (北京).
- 周竹生, 周熙襄. 1993. 宽带约束反演方法[D].
- 姚逢昌, 甘利灯. 2000. 地震反演的应用与限制[J]. 石油勘探与开发, 27(2):2-0.
- 安鸿伟, 李正文, 李仁甫, 等. 2002. 稀疏脉冲波阻抗反演在 YX 油田开发中的应用[J]. 石油物探, 41(1):56-60.
- 张宏兵, 杨长春, 尚作萍, 等. 2006. 基于软约束模式的波阻抗反演[D].
- 张永刚. 2002. 地震波阻抗反演技术的现状和发展[J]. 石油物探, 41(4):385-390.
- 李宏兵. 1996. 具有剔除噪音功能的多道广义线性反演[J]. 石油物探, 35(4):11-17.
- 李方明, 计智锋, 赵国良, 等. 2007. 地质统计反演之随机地震反演方法——以苏丹 M 盆地 P 油田为例[J]. 石油勘探与开发, 34(4): 451-455.
- 潘昱洁, 李大卫, 杨锴. 2011. 确定性反演和随机反演对井约束条件的需求分析[J]. 石油物探, 50(4):345-349.
- 王权锋, 郭科. 2008. 约束稀疏脉冲反演在储层预测中的应用[J]. 测井技术, 2008(01):33-36.
- 郭朝斌, 杨小波, 陈红岳, 等. 2006. 约束稀疏脉冲反演在储层预测中的应用[J]. 石油物探, 45(4):397-400.
- 韦瑜, 陈同俊, 江晓雨, 等. 2017. 基于褶积模型的地震反演方法在煤田地质勘探中的应用[J]. 地球物理学进展, 32(3):1258-1265.
- 高扬. 2018. 基于地质统计学的地震反演方法研究[D]. 中国石油大学 (北京).
- Ahmad M, Motaz A, Ghassan A. 2019. Estimation of acoustic impedance from seismic data using temporal convolutional network[C/OL]//89th Annual International Meeting, SEG, Expanded Abstracts. 2554-2558. DOI: 10.1190/segam2019-3216840.1.
- Al-Anazi A F, Gates I D. 2012. Support vector regression to predict porosity and permeability: Effect

- of sample size[J]. *Computers & geosciences*, 39:64-76.
- Alfarraj M, AlRegib G. 2018. Petrophysical property estimation from seismic data using recurrent neural networks[C/OL]//88th Annual International Meeting, SEG, Expanded Abstracts. 2141-2146. DOI: 10.1190/segam2018-2995752.1.
- Anderson T. 2009. History of geologic investigations and oil operations at teapot dome[C]//Wyoming: Presented at the 2009 AAPG Annual Convention.
- Araya-Polo M, Jennings J, Adler A, et al. 2018. Deep-learning tomography[J]. *The Leading Edge*, 37(1):58-66.
- Arias E. 2016. Estimating seismic reflection slopes[D]. Colorado School of Mines.
- Bakker P, van Vliet L J, Verbeek P W. 1999. Edge preserving orientation adaptive filtering[C/OL]//Computer Vision and Pattern Recognition, 1999. IEEE Computer Society Conference on.: volume 1. 540 Vol. 1. DOI: 10.1109/CVPR.1999.786989.
- Bakker P. 2002. Image structure analysis for seismic interpretation[D]. Delft University of Technology.
- Bakulin A, Zdraveva O. 2010. Building geologically plausible anisotropic depth models using borehole data and horizon-guided interpolation[M]//SEG Technical Program Expanded Abstracts, 2010. Society of Exploration Geophysicists: 4118-4122.
- Biswas R, Sen M K, Das V, et al. 2019. Prestack and poststack inversion using a physics-guided convolutional neural network[J]. *Interpretation*, 7(3):SE161-SE174.
- Bobach T, Umlauf G. 2006. Natural neighbor interpolation and order of continuity[J]. *GI Lecture Notes in Informatics: Visualization of Large and Unstructured Data Sets*:69-86.
- Borgos H G, Skov T, Randen T, et al. 2003. Automated geometry extraction from 3d seismic data[C/OL]//73rd Annual International Meeting, SEG, Expanded Abstracts. 1541-44. DOI:10.1190/1.1817590.
- Bosch M, Mukerji T, Gonzalez E F. 2010. Seismic inversion for reservoir properties combining statistical rock physics and geostatistics: A review[J]. *Geophysics*, 75(5):75A165-75A176.
- Bugge A J, Clark S R, Lie J E, et al. 2018. A case study on semiautomatic seismic interpretation of unconformities and faults in the southwestern barents sea[J/OL]. *Interpretation*, 6(2):SD29–SD40. DOI: 10.1190/INT-2017-0152.1.
- Bugge A J, Lie J E, Evensen A K, et al. 2019. Automatic extraction of dislocated horizons from 3D seismic data using nonlocal trace matching[J]. *Geophysics*, 84(6):1ND-Z34.
- Buland A, Omre H. 2003. Bayesian linearized avo inversion[J]. *Geophysics*, 68(1):185-198.
- Carr J C, Fright W R, Beatson R K. 1997. Surface interpolation with radial basis functions for medical imaging[J]. *IEEE transactions on medical imaging*, 16(1):96-107.

- Caumon G, Collon-Drouaillet P, Le Carlier de Veslud C, et al. 2009. Surface-based 3D modeling of geological structures[J]. *Mathematical Geosciences*, 41(8):927-945.
- Cooke D A, Schneider W A. 1983. Generalized linear inversion of reflection seismic data[J]. *Geophysics*, 48(6):665-676.
- Cormen T H, Leiserson C E, Rivest R L, et al. 2001. *Introduction to algorithms*[M]. 2nd ed. Cambridge, MA, USA: MIT Press.
- Das V, Pollack A, Wollner U, et al. 2018. Convolutional neural network for seismic impedance inversion[C]//88th Annual International Meeting, SEG, Expanded Abstracts. 2071-2075.
- Das V, Pollack A, Wollner U, et al. 2019. Convolutional neural network for seismic impedance inversion[J]. *Geophysics*, 84(6):R869-R880
- de Groot P, Huck A, de Bruin G, et al. 2010. The horizon cube: A step change in seismic interpretation![J]. *The Leading Edge*, 29(9):1048-1055.
- de Groot P, Huck A, de Bruin G, et al. 2010. The horizon cube: A step change in seismic interpretation![J]. *The Leading Edge*, 29(9):1048-1055.
- Detrixhe M, Gibou F, Min C. 2013. A parallel fast sweeping method for the Eikonal equation[J]. *Journal of Computational Physics*, 237: 46-55.
- Di H, Gao D, AlRegib G. 2018. 3D structural-orientation vector guided autotracking for weak seismic reflections: A new tool for shale reservoir visualization and interpretation[J/OL]. *Interpretation*, 6(4):SN47-SN56. DOI: 10.1190/INT-2018-0053.1.
- Di H, Gao D, AlRegib G. 2019. Developing a seismic texture analysis neural network for machineaided seismic pattern recognition and classification[J]. *Geophysical Journal International*, 218(2):1262-1275.
- Dorn G A. 2011. A review of “global” interpretation methods for automated 3d horizon picking[J]. *The Leading Edge*, 30(1):38-47.
- Dorn G A. 2013. Domain transform: A tool for imaging and interpreting geomorphology and stratigraphy in seismic volumes[J]. *The Leading Edge*, 32(2):146-153.
- Dramsch J S, Lüthje M. 2018. Deep-learning seismic facies on state-of-the-art CNN architectures[C]//88th Annual International Meeting, SEG, Expanded Abstracts. 2036-2040.
- Dyn N. 1987. *Interpolation of scattered data by radial functions*[M]//Topics in multivariate approximation. Elsevier: 47-61.
- E.Bellman R, Dreyfus S E. 1962. *Applied dynamic programming*[M]. Princeton: Princeton University Press.
- Equinor. 2018. Volve data village dataset[J]. released under a license based on CC BY 4.0. [Online]. Available: <https://data.equinor.com/>.
- Fehmers G C, Höcker C F W. 2003. Fast structural interpretation with structure - oriented

- filtering[J]. *Geophysics*, 68(4):1126-1422.
- Fomel S. 2002. Applications of plane-wave destruction filters[J]. *Geophysics*, 67(6):1946-1960.
- Fomel S. 2010. Predictive painting of 3D seismic volumes[J]. *Geophysics*, 75(4):A25-A30.
- Fu L Y. 2004. Joint inversion of seismic data for acoustic impedance[J]. *Geophysics*, 69(4):994-1004.
- Geng Z, Wu X, Shi Y, et al. 2020. Deep learning for relative geologic time and seismic horizons[J]. *Geophysics*, 85(4):WA87-WA100.
- Gholami A, Sacchi M D. 2012. A fast and automatic sparse deconvolution in the presence of outliers[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 50(10):4105-4116.
- González E F, Mukerji T, Mavko G. 2008. Seismic inversion combining rock physics and multiplepoint geostatistics[J]. *Geophysics*, 73(1):R11-R21.
- Guitton A, Verschuur D. 2004. Adaptive subtraction of multiples using the l1-norm[J]. *Geophysical Prospecting*, 52(1):27-38.
- Hale D. 2009a. Image-guided blended neighbor interpolation of scattered data[C]//79th Annual International Meeting, SEG, Expanded Abstracts. 1127-1131.
- Hale D. 2009b. Structure-oriented smoothing and semblance[J]. CWP Report 635.
- Hale D. 2010a. Image - guided 3D interpolation of borehole data[C]//80th Annual International Meeting, SEG, Expanded Abstracts. 1266-1270.
- Hale D. 2010b. Image-guided 3D interpolation of borehole data[J]. CWP Report 656.
- Hale D. 2013. Dynamic warping of seismic images[J]. *Geophysics*, 78(2):S105-S115.
- Hampson D, Todorov T, Russell B. 2000. Using multi-attribute transforms to predict log properties from seismic data[J]. *Exploration Geophysics*, 31(3):481-487.
- Hampson D P, Schuelke J S, Quirein J A. 2001. Use of multiattribute transforms to predict log properties from seismic data[J]. *Geophysics*, 66(1):220-236.
- Hansen T M, Mosegaard K, Pedersen-Tatalovic R, et al. 2008. Attribute-guided well-log interpolation applied to low-frequency impedance estimation[J]. *Geophysics*, 73(6):R83-R95.
- He K, Zhang X, Ren S, et al. 2016. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 770-778.
- He M, He D. 2017. Deep learning based approach for bearing fault diagnosis[J]. *IEEE Transactions on Industry Applications*, 53(3):3057-3065.
- Huck A, Quiquerez G, de Groot P. 2010. Improving seismic inversion through detailed low frequency model building[C]//72nd EAGE Conference and Exhibition incorporating SPE EUROPEC 2010. European Association of Geoscientists & Engineers: cp-161.
- Jayr S, Gringarten E, Tertois A L, et al. 2008. The need for a correct geological modelling support:

- the advent of the uvt-transform[J]. *First Break*, 26(10).
- Jeong W K, Fletcher P T, Tao R, et al. 2007. Interactive visualization of volumetric white matter connectivity in dt-mri using a parallel-hardware hamilton-jacobi solver[J/OL]. *IEEE Transactions on Visualization and Computer Graphics*, 13(6):1480-1487. DOI: 10.1109/TVCG.2007.70571.
- Karimi P, Fomel S, Zhang R. 2017. Creating detailed subsurface models using predictive imageguided well-log interpolation[J]. *Interpretation*, 5(3):T279-T285.
- Kieft R, Jackson C L, Hampson G, et al. 2010. Sedimentology and sequence stratigraphy of the hugin formation, quadrant 15, norwegian sector, south viking graben[C]//Geological Society, London, Petroleum Geology Conference series: volume 7. Geological Society of London: 157-176.
- Kingma D P, Ba J. 2014. Adam: A method for stochastic optimization.[J/OL]. CoRR, abs/1412.6980. <http://dblp.uni-trier.de/db/journals/corr/corr1412.html#KingmaB14>.
- Konukoglu E, Sermesant M, Clatz O, et al. 2007. A recursive anisotropic fast marching approach to reaction diffusion equation: Application to tumor growth modeling[C]//Biennial International Conference on Information Processing in Medical Imaging. Springer: 687-699.
- Labrunye E, Carn C. 2015. Merging chronostratigraphic modeling and global horizon tracking[J]. *Interpretation*, 3:SN59-SN67.
- Labrunye E, Winkler C, Borgese C, et al. 2009. New 3d flattened space for seismic interpretation [C/OL]//79th Annual International Meeting, SEG, Expanded Abstracts. 1132-1136. DOI:10.1190/1.3255052.
- Lacaze F P S, Valding T. 2009. A global approach in seismic interpretation based on cost function minimization[C/OL]//79th Annual International Meeting, SEG, Expanded Abstracts. 2592-2596. DOI: 10.1190/1.3255384.
- Latimer R B, Davidson R, Van Riel P. 2000. An interpreter's guide to understanding and working with seismic-derived acoustic impedance data[J]. *The leading edge*, 19(3):242-256.
- LeCun Y, Bengio Y, Hinton G. 2015. Deep learning[J]. *nature*, 521(7553):436-444.
- Lemon A M, Jones N L. 2003. Building solid models from boreholes and user-defined cross-sections [J]. *Computers & Geosciences*, 29(5):547 - 555.
- Levy S, Fullagar P K. 1981. Reconstruction of a sparse spike train from a portion of its spectrum and application to high-resolution deconvolution[J]. *Geophysics*, 46(9):1235-1243.
- Lindseth R O. 1979. Synthetic sonic logs—a process for stratigraphic interpretation[J]. *Geophysics*, 44(1):3-26.
- Lomask J, Guitton A, Fomel S, et al. 2006. Flattening without picking[J]. *Geophysics*, 71(4):P13-

- P20.
- Lou Y, Zhang B, Lin T, et al. 2019. Accurate seismic dip and azimuth estimation using semblance dip guided structure tensor analysis[J]. *Geophysics*, 84(5):O103-O112.
- Lowell J, Paton G. 2018. Application of deep learning for seismic horizon interpretation[M]//88th Annual International Meeting, SEG, Expanded Abstracts. Society of Exploration Geophysicists: 1976-1980.
- Lucas A, Iliadis M, Molina R, et al. 2018. Using deep neural networks for inverse problems in imaging: beyond analytical methods[J]. *IEEE Signal Processing Magazine*, 35(1):20-36.
- Luo S, Hale D. 2013. Unfaulting and unfolding 3D seismic images[J]. *Geophysics*, 78(4):O45-O56.
- Lv F, Wen C, Bao Z, et al. 2016. Fault diagnosis based on deep learning[C]//2016 American Control Conference (ACC). IEEE: 6851-6856.
- Ma X Q. 2002. Simultaneous inversion of prestack seismic data for rock properties using simulated annealing[J]. *Geophysics*, 67(6):1877-1885.
- Mallet J L L. 2002. *Geomodeling*[M]. Oxford University Press, Inc.
- Mallet J. 2014. *Elements of mathematical sedimentary geology: The geochron model*[M/OL]. EAGE publications. <https://books.google.com/books?id=26zcoAEACAAJ>.
- Mallick S. 1995. Model-based inversion of amplitude-variations-with-offset data using a genetic algorithm[J]. *Geophysics*, 60(4):939-954.
- Marfurt K J. 2006. Robust estimates of 3D reflector dip and azimuth[J]. *Geophysics*, 71(4):P29-P40.
- Marfurt K J, Kirlin R L, Farmer S L, et al. 1998. 3-D seismic attributes using a semblance-based coherency algorithm[J]. *Geophysics*, 63(4):1150-1165.
- Marquardt D W. 1963. An algorithm for least-squares estimation of nonlinear parameters[J]. *Journal of the society for Industrial and Applied Mathematics*, 11(2):431-441.
- Monniron M, Frambati S, Quillón S, et al. 2016. Seismic horizon and pseudo-geological time cube extraction based on a riemannian geodesic search[C/OL]//2016 IEEE 12th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP). 1-5. DOI: 10.1109/IVMSPW.2016.7528178.
- Morelato R, Biloti R. 2013. Structure enhancing filtering with the structure tensor[C/OL]//83rd Annual International Meeting, SEG, Expanded Abstracts. 4352-4356. DOI: 10.1190/segam2013-0615.1.
- Mosser L, Dubrule O, Blunt M J. 2020. Stochastic seismic waveform inversion using generative adversarial networks as a geological prior[J]. *Mathematical Geosciences*, 52(1):53-79.
- Motaz A, Ghassan A. 2019. Semi-supervised learning for acoustic impedance inversion [C/OL]//89th Annual International Meeting, SEG, Expanded Abstracts. 2298-2302. DOI:

- 0.1190/segam2019-3215902.1.
- Naeini E Z, Hale D. 2015. Image- and horizon-guided interpolation[J]. *Geophysics*, 80(3):V47-V56.
- Oldenburg D, Scheuer T, Levy S. 1983. Recovery of the acoustic impedance from reflection seismograms[J]. *Geophysics*, 48(10):1318-1337.
- Parks D. 2010. Seismic image flattening as a linear inverse problem[D]. Colorado School of Mines.
- Pedersen-Tatalovic R, Uldall A, Jacobsen N L, et al. 2008. Event-based low-frequency impedance modeling using well logs and seismic attributes[J]. *The Leading Edge*, 27(5):592-603.
- Phillips M, Fomel S. 2016. Seismic time-lapse image registration using amplitude-adjusted planewave destruction[C/OL]//86th Annual International Meeting, SEG, Expanded Abstracts. 5473-5478. DOI: 10.1190/segam2016-13773139.1.
- Posamentier H, Davies R, Cartwright J, et al. 2007. Seismic geomorphology - an overview[C]//in: R.J. Davies, H.W. Posamentier, L.J. Wood, J.A. Cartwright (Eds.), *Seismic Geomorphology: volume 277*. Geological Society of London Special Publication: 1-14.
- Puzyrev V, Egorov A, Pirogova A, et al. 2019. Deep neural networks for 1d impedance inversion[J]. *ASEG Extended Abstracts*, 2019(1):1-4.
- Qayyum F, de Groot P, Hemstra N. 2012. Using 3D Wheeler diagrams in seismic interpretation-the HorizonCube method[J]. *First Break*, 30:103-109.
- Qayyum F, Catuneanu O, de Groot P. 2015. Historical developments in Wheeler diagrams and future directions[J]. *Basin Research*, 27(3):336-350.
- Qayyum F, Betzler C, Catuneanu O. 2017. The Wheeler diagram, flattening theory, and time[J/OL]. *Marine and Petroleum Geology*, 86:1417-1430. DOI: 10.1016/j.marpetgeo.2017.07.034.
- Qayyum F, Betzler C, Catuneanu O. 2018. Space-time continuum in seismic stratigraphy: Principles and norms[J/OL]. *Interpretation*, 6(1):T97-T108. DOI: 10.1190/INT-2017-0061.1.
- Qian J, Zhang Y T, Zhao H K. 2007. A fast sweeping method for static convex hamilton-jacobi equations[J]. *Journal of Scientific Computing*, 31(1):237-271.
- Richardson A. 2018. Seismic full-waveform inversion using deep learning tools and techniques[J]. arXiv preprint arXiv:1801.07232.
- Russell B, Hampson D. 1991. Comparison of poststack seismic inversion methods[M]//SEG Technical Program Expanded Abstracts 1991. Society of Exploration Geophysicists: 876-878.
- Sambridge M, Braun J, McQueen H. 1995. Geophysical parametrization and interpolation of irregular data using natural neighbours[J]. *Geophysical Journal International*, 122(3):837-857.
- Saufi S R, Ahmad Z A B, Leong M S, et al. 2019. Challenges and opportunities of deep learning models for machinery fault detection and diagnosis: A review[J]. *IEEE Access*, 7:122644-122662.

- Sen M K, Stoffa P L. 1991. Nonlinear one-dimensional seismic waveform inversion using simulated annealing[J]. *Geophysics*, 56(10):1624-1638.
- Sen S, Ganguli S S, et al. 2019. Estimation of pore pressure and fracture gradient in volve field, norwegian north sea[C]//SPE Oil and Gas India Conference and Exhibition. Society of Petroleum Engineers.
- Sethian J A. 1999. Fast marching methods[J]. *SIAM review*, 41(2):199-235.
- Sethian J A, Vladimirsky A. 2003. Ordered upwind methods for static hamilton–jacobi equations: Theory and algorithms[J]. *SIAM Journal on Numerical Analysis*, 41(1):325-363.
- Shafiq M, Wang Z, Amin A, et al. 2015. Detection of salt-dome boundary surfaces in migrated seismic volumes using gradient of textures[C/OL]//85th Annual International Meeting, SEG, Expanded Abstracts. 1811-1815. DOI: 10.1190/segam2015-5927230.1.
- Shafiq M, AlRegib G. 2016. Interpreter-assisted tracking of subsurface structures within migrated seismic volumes using active contour[C]//78th EAGE Conference & Exhibition 2015.
- Sheriff R E, Geldart L P. 1995. *Exploration seismology*[M]. Cambridge university press.
- Shi Y, Wu X, Fomel S. 2020. Waveform embedding: Automatic horizon picking with unsupervised deep learning[J]. *Geophysics*, 85(4):WA67-WA76.
- Sibson R. 1981. A brief description of natural neighbour interpolation[J]. *Interpreting multivariate data*.
- Smith G, Gidlow P. 1987. Weighted stacking for rock property estimation and detection of gas[J]. *Geophysical prospecting*, 35(9):993-1014.
- Souche L, Lepage F, Iskenova G. 2013. Volume based modeling-automated construction of complex structural models[C]//75th EAGE Conference & Exhibition incorporating SPE EUROPEC 2013.
- Souche L, Iskenova G, Lepage F, et al. 2014. Construction of structurally and stratigraphically consistent structural models using the volume-based modelling technology: Applications to an australian dataset[C]//International Petroleum Technology Conference. International Petroleum Technology Conference.
- Stark T J. 2003. Unwrapping instantaneous phase to generate a relative geologic time volume[C]//73rd Annual International Meeting, SEG, Expanded Abstracts. Soc. of Expl. Geophys.: 1707-1710.
- Stark T J. 2005a. Generation of a 3d seismic “wheeler diagram” from a high resolution age volume[C/OL]//75th Annual International Meeting, SEG, Expanded Abstracts. 782-785. DOI:10.1190/1.2148275.
- Stark T J. 2005b. System for multi-dimensional data analysis[M]. Google Patents.

- Sui Y, Ma J. 2019. A nonstationary sparse spike deconvolution with anelastic attenuation[J]. *Geophysics*, 84(2):R221-R234.
- Tikhonov A. 1963. Solution of incorrectly formulated problems and the regularization method [J/OL]. *Soviet Math. Dokl.*, 5:1035/1038. <http://ci.nii.ac.jp/naid/10004315593/en/>.
- Tikhonov A N, Goncharsky A, Stepanov V, et al. 2013. Numerical methods for the solution of ill-posed problems: volume 328[M]. Springer Science & Business Media.
- Tsai Y H R, Cheng L T, Osher S, et al. 2003. Fast sweeping algorithms for a class of hamilton–jacobi equations[J]. *SIAM journal on numerical analysis*, 41(2):673-694.
- Tschannen V, Delescluse M, Ettrich N, et al. 2020. Extracting horizon surfaces from 3d seismic data using deep learning[J]. *Geophysics*, 85(3):N17-N26.
- Vail P R, Todd R G, Sangree J B. 1977. Seismic stratigraphy and global changes of sea level: Part 5. chronostratigraphic significance of seismic reflections: Section 2. application of seismic reflection configuration to stratigraphic interpretation[C]//M 26: Seismic Stratigraphy–Applications to Hydrocarbon Exploration: volume 26. AAPG Memoirs: 99-116.
- Van Vliet L J, Verbeek P W. 1995. Estimators for orientation and anisotropy in digitized images [C]//Proceedings of the first annual conference of the Advanced School for Computing and Imaging ASCI'95, Heijen (The Netherlands). 442-450.
- Varadi M, Antonsen P, Eien M, et al. 1998. Jurassic genetic sequence stratigraphy of the Norwegian block 15/5 area, south viking graben[J]. *Sequence Stratigraphy–Concepts and Applications*. Norwegian Petroleum Society, Trondheim, Special Publications:373-401.
- Veeken P, Silva D, M. 2004. Seismic inversion methods and some of their constraints[J]. *First break*, 22(6).
- Velis D R. 2008. Stochastic sparse-spike deconvolution[J]. *Geophysics*, 73(1):R1-R9.
- Wang K, Wei K, Deal K, et al. 2015a. A new method of generating horizons from seismic images with geologic constraints[C]//77th EAGE Conference & Exhibition 2015.
- Wang K, Wei K, Deal K, et al. 2015b. 3d seismic horizon extraction with horizon patch constraints [C/OL]//85th Annual International Meeting, SEG, Expanded Abstracts. 1754-1758. DOI: 10.1190/segam2015-5877422.1.
- Wang K, Bandura L, Bevc D, et al. 2019. End-to-end deep neural network for seismic inversion [C/OL]//89th Annual International Meeting, SEG, Expanded Abstracts. 4982-4986. DOI: 10.1190/segam2019-3216464.1.
- Wang L, Zhao Q, Gao J, et al. 2016. Seismic sparse-spike deconvolution via toeplitz-sparse matrix factorization[J]. *Geophysics*, 81(3):V169-V182.
- Wang Z, Long Z, AlRegib G. 2015c. Tensor-based subspace learning for tracking salt-dome

- boundaries[C/OL]//2015 IEEE International Conference on Image Processing (ICIP). 1663-1667. DOI: 10.1109/ICIP.2015.7351083.
- Wang Z, AlRegib G. 2014a. Automatic fault surface detection using 3D Hough Transform [C/OL]//84th Annual International Meeting, SEG, Expanded Abstracts. 1439-1444. DOI: 10.1190/segam2014-1590.1.
- Wang Z, Long Z, AlRegib G, et al. 2014b. Automatic fault tracking across seismic volumes via tracking vectors[J]. IEEE International Conference on Image Processing (ICIP).
- Wu X. 2017a. Building 3D subsurface models conforming to seismic structural and stratigraphic features[J/OL]. GEOPHYSICS, 82(3):IM21-IM30. DOI: 10.1190/geo2016-0255.1.
- Wu X. 2017b. Structure-, stratigraphy-, and fault-guided regularization in geophysical inversion[J]. Geophysical Journal International, 210(1):184-195.
- Wu X, Fomel S. 2018a. Least-squares horizons with local slopes and multigrid correlations[J/OL]. Geophysics, 83(4):IM29-IM40. DOI: 10.1190/geo2017-0830.1.
- Wu X, Hale D. 2013. Extracting horizons and sequence boundaries from 3D seismic images[C]//83rd Annual International Meeting, SEG, Expanded Abstracts. Society of Exploration Geophysicists: 1440-1445.
- Wu X, Hale D. 2015. Horizon volumes with interpreted constraints[J]. Geophysics, 80(2):IM21-IM33.
- Wu X, Zhong G. 2012. Generating a relative geologic time volume by 3D graph-cut phase unwrapping method with horizon and unconformity constraints[J]. Geophysics, 77(4):O21-O34.
- Wu X, Luo S, Hale D. 2016. Moving faults while unfaulting 3D seismic images[J]. Geophysics, 81(2): IM25-IM33.
- Wu X, Liang L, Shi Y, et al. 2019a. Faultseg3d: Using synthetic data sets to train an end-to-end convolutional neural network for 3d seismic fault segmentation[J]. Geophysics, 84(3):IM35-IM45.
- Wu X, Shi Y, Fomel S, et al. 2019b. Faultnet3d: Predicting fault probabilities, strikes, and dips with a single convolutional neural network[J]. IEEE Transactions on Geoscience and Remote Sensing, 57(11):9138-9155.
- Wu Y, McMechan G A. 2018b. Feature-capturing full waveform inversion using a convolutional neural network[C]//88th Annual International Meeting, SEG, Expanded Abstracts. 2061-2065.
- Yan S, Wu X. 2021. Seismic horizon extraction with dynamic programming[J]. Geophysics, 86(2): IM51-IM62.
- Yu Y, Kelley C, Mardanova I. 2013. Volumetric seismic dip and azimuth estimation with 2D

- logGabor filter array[C]//83rd Annual International Meeting, SEG, Expanded Abstracts. 1357-1362.
- Yuan S, Wang S, Luo C, et al. 2015. Simultaneous multitrace impedance inversion with transformdomain sparsity promotion[J]. *Geophysics*, 80(2):R71-R80.
- Zhang G, Wang Z, Chen Y. 2018. Deep learning for seismic lithology prediction[J]. *Geophysical Journal International*, 215(2):1368-1387.
- Zhang R, Castagna J. 2011. Seismic sparse-layer reflectivity inversion using basis pursuit decomposition[J]. *Geophysics*, 76(6): R147-R158.
- Zhang R, Sen M K, Srinivasan S. 2013. A prestack basis pursuit seismic inversion[J]. *Geophysics*, 78(1):R1-R11.
- Zhao H. 2005. A fast sweeping method for eikonal equations[J]. *Mathematics of computation*, 74(250): 603-627.
- Zheng Y, Zhang Q, Yusifov A, et al. 2019. Applications of supervised deep learning for seismic interpretation and inversion[J]. *The Leading Edge*, 38(7):526-533.
- Zhu L, Zhang C, Li M, et al. 2012. Building 3D solid models of sedimentary stratigraphic systems from borehole data: An automatic method and case studies[J]. *Engineering Geology*, 127:1 - 13.
- Zinck G, Donias M, Daniel J, et al. 2013. Fast seismic horizon reconstruction based on local dip transformation[J/OL]. *Journal of Applied Geophysics*, 96:11-18.
- Zwartjes P, Gisolf A. 2007. Fourier reconstruction with sparse inversion[J]. *Geophysical Prospecting*, 55(2):199-221.

致 谢

桃花谢了春红，太匆匆。五载时光恍如昨日又绵长难忘。美好的校园生活即将正式结束，即将要奔赴新的征程，在这里里程碑的日子里，我怀着激动、不舍和忐忑细细品味过往的点滴时光，那些求知路上的甘苦，老师教诲时的殷切，同窗情谊的深厚乃至于一草一木，一楼一字皆在心里泛起些许涟漪，如昨日历历在目。

我特别感谢我的博士导师伍新明教授。第一次见到伍老师，是在一次课题组交流会上，那时候伍老师还未归国任教，为人谦和友善是我对伍老师的第一印象。之后在我转博的时候，有幸在伍老师的指导下学习。当时我对地震解释方面知之甚少，伍老师经常抽出时间耐心给予指导和讲解，每次都愿意花费大量的时间和我们讨论科研，解决困难，甚至是经常亲自来到我们的办公室亲自给我们讲解如何写代码、如何做学术PPT。我最佩服的一点是，伍老师对科研的精力好像永远用不完，对科研永远有着无限的激情和热情，总能收到老师凌晨四五点的消息，能看到老师在一整天的会议上一直认真聆听讨论。老师欢迎每一位跟他讨论的学生，并用心地解决每一个问题，更是经常主动了解我们的科研进展，提醒我们应该注意的问题，让我们少走了很多弯路。除了科研，在生活上伍老师更像朋友一样，会分享他看到的美好事物、品尝到的美食，更关心着我们每一位同学的身心健康，了解每个人的精神和心理状态，因为伍老师常说“我希望你们每一个人在做科研的时候是非常快乐的，这样才能真正得到成就感和满足感”。因此，老师很注重课题组内的氛围，教导我们要懂得分享和互帮互助，事实上这对我们的帮助确实很大，同学们之间相处的很愉快。除此之外，要感谢伍老师推荐我取得去华为实习的机会，学到了不少技能。感谢伍老师对我未来发展的多次指导和宝贵建议，在找工作的时候不仅帮助我分析利弊，而且竭尽全力的帮我了解每一家单位，真心的为我将来的发展考虑。如今学有所成必须感激恩师的传道授业解惑。

我要感谢我的硕士导师张捷教授。依然清楚地记得，五年前在我焦急地等待之后收到张老师录取通知的那一时刻的兴奋，自此踏入中国科学技术大学继续在地球物理学专业学习。在张老师的带领下，我们不仅能够开拓国际视野，每年都能去国外参加国际会议，而且在个人科研上有很大的自主空间。在第一年的研究生学习中，我已经意识到本科和研究生无论是在学习内容还是学习方式上都有很大的区别，在一开始的阶段我还不能很好的适应研究生的生活，科研进展也非常不顺利，曾经内心非常沮丧和失落。张老师却一直鼓励我关心我，每次回国都会跟我们进行交流谈心，解决我们学习和生活上的各种困难，所以

我很感谢张老师的耐心指导和从未放弃。另外，也是在张老师的带领下，我完成了人生的第一场马拉松，老师用这种方式锻炼我们坚持不懈的精神，告诉我们只有到终点才是最终的赢家。在张捷老师的课题组，我最大的收获是做人要谦和、诚实、自律，做事要坚持、求实。我相信这将会使我以后不管遇到何事都能从容处之，冷静解决。此外，也很感谢张伟老师的指导和帮助。在我的记忆中，张伟老师一直特别的认真细致，我还清楚记得张老师在夏令营面试我的时候认真的记录，在教我们地震勘探课程时候的耐心讲解，在指导我微地震课题的时候发的一封封长篇邮件，不仅详尽地阐述课题并用心地推荐相关文章。这才使得快速的进入科研状态，了解相关的前沿进展，对我的学习提供了很大的帮助。

感谢罗小梅老师、郝志锋老师和田瑞红老师，为我们的科研和生活提供了便利和支持，每一次报销都非常复杂繁琐，每一个项目的手续也很多，但你们每次都很耐心的完成，事无巨细的提醒和帮助，才让我们可以专心的科研。

在这五年多的时间，伴随我的还有和课题组的伙伴们的帮助和无数欢乐时光。感谢张雄师兄、田宵师姐、袁聪聪师兄对我微地震课题的帮助和指导；感谢王月师姐、刘志洋师兄对我在 GeoTomo 和 MiVu 软件的使用上的指导；感谢邓宇龙师兄对在服务器的使用上对我的帮助；感谢朱慧宇师兄对天然地震数据的处理帮助；感谢孙梦瑶师姐、高晗师姐、江文彬师兄和李子昂师兄在勘探数据处理和算法理解上对我的帮助；感谢同一级的沈杨、段旭东、王艺豪陪我一起找工作，一起参加活动，在学习和生活上给与我提醒和帮助，以及我的室友张春丽在与我合租期间的包容和帮助；感谢马洋洋师妹辛苦帮我寄东西；感谢薛智文师弟作为答辩秘书辛苦组织答辩；感谢刘宇师妹陪我一起住宿买东西；感谢王函师妹给我推荐各种好物；感谢王康、王章钰、张基、丁香军师弟们经常组织有趣的的活动，带我参加体验。难忘课题组一起聚餐、过生日、玩狼人杀桌游、去漂流……这一个个的欢声笑语为我艰难的科研生涯增添了无限的乐趣和美好的回忆。

也要感谢去年遇到的活泼可爱的师弟们，他们不仅是课题组的新鲜血液，更是未来的顶梁柱，他们努力认真、风华正茂，未来可期。瀚林-文娱担当，认真策划我们的每一次活动，调动着大家的积极性，更是把办公室管理的井井有条；高航-技术担当，各项技能大佬，进步神速，而且更是耐心地帮助我的每次求助；金涛-身份担当，作为科大本科生从不逊色，性格直爽易相处，乐于助人；子健-可爱担当，虽然话少但不失可爱风趣；司旭-幽默担当，无聊之际的玩笑总能带来意想不到的幽默感。是你们的到来迅速壮大了课题组的力量，活跃了气氛。另外，要特别感谢晓明师兄对我写作上的帮助，感谢师兄帮我修改论文，指导

致 谢

使用软件处理反演结果；感谢亚星师弟陪我一起去南京参加会议，帮助完成项目；感谢认识了即将入学的江蕾、戴传力、李游、高晖，你们的热情和乐观再次感染了我，仿佛看到了我当年刚入学的模样。与大家相遇，让我的博士期间增添了更多温暖和珍贵回忆，谢谢！

万爱千恩百苦，疼我孰知父母。所以特别感谢我的父母和家人，感谢你们这么多年对我的培育和教导，感谢你们给我的空间和信任，感谢你们在我前行道路上坚定的支持，在我受挫时的鼓励和怀抱，你们一直是我奋斗的最大动力，路漫漫其修远兮，吾将上下而求索。

有人出现，有人离开，有人还在，有无随缘，得失在心。惟愿以余生之全部精彩报与你们相遇之恩。

月有盈亏，花有开落，山水一程，三生有幸，金寨路 96 号，期待重逢，行文至此，落笔为终。

2021 年 4 月

在读期间发表的学术论文与取得的其他研究成果

已发表期刊论文:

1. Yan, S. and Wu, X., 2021, Seismic horizon extraction with dynamic programming. *Geophysics*, 86(2), IM51-IM62.
2. Wu, X., Yan, S., Bi, Z., Zhang, S., and Si, H., 2021, Deep learning for multi-dimensional seismic impedance inversion. *Geophysics*, accepted.
3. Wu, X., Yan, S., Qi, J., and Zeng, H., 2020, Deep Learning for Characterizing Paleokarst Collapse Features in 3-D Seismic Images. *Journal of Geophysical Research: Solid Earth*, 125(9), e2020JB019685.

已发表会议论文:

1. Yan, S. and X. Wu, 2020, Seismic horizon refinement with dynamic programming. 90th Annual Meeting of the Society of Exploration Geophysics, Expanded Abstracts.
2. Wu, X., S. Yan, J. Qi, and H. Zeng, 2020, Deep learning for characterizing paleokarst collapse features in 3D seismic images. 90th Annual Meeting of the Society of Exploration Geophysics, Expanded Abstracts.
3. Yan, S. and J. Zhang, 2017, Comparison of stacking methods with a depth model or with a RMS velocity for automated microseismic event location from surface monitoring, SEG workshop, Microseismic Technologies and applications.

待发表期刊论文:

1. Yan, S. and Wu, X., Zhang, S., and Si, H., 2021, Building subsurface models with horizon-guided interpolation and deep learning: applied to the Volve data. *Geophysics*, submitted.
2. Zhang, S., Si, H., X. Wu, and Yan, S., 2021, A comparison of deep learning methods for seismic impedance inversion. *Petroleum Science*, submitted.

专利:

基于动态规划的地震层位自动提取装置及方法，专利编号：202010023331.7