



刘豪杰, 龚敏, 王林, 等. 2026. 基于 ResUNet 的波阻抗反演及其在复杂地质区的精度提升. 地球物理学进展, 41 (1): 0372-0387, doi:10. 6038/pg2026JJ0130.

LIU HaoJie, GONG Min, WANG Lin, et al. 2026. Wave impedance inversion based on ResUNet and its accuracy improvement in complex geological areas. *Progress in Geophysics* (in Chinese), 41 (1): 0372-0387, doi:10. 6038/pg2026JJ0130.

基于 ResUNet 的波阻抗反演及其在复杂地质区的精度提升

Wave impedance inversion based on ResUNet and its accuracy improvement in complex geological areas

刘豪杰, 龚敏, 王林, 韩奕

LIU HaoJie, GONG Min, WANG Lin, HAN Yi

中海石油(中国)有限公司天津分公司渤海石油研究院, 天津 300459

Bohai Oilfield Research Institute of China National Offshore Oilfield Corporation Limited-Tianjin, Tianjin 300459, China

摘要 地震反演是一种通过地震数据推断地下岩层物性参数(如波阻抗)的关键方法,在油气勘探与地质研究中具有重要作用。然而,传统地震反演方法依赖于低频背景模型,容易受到噪声影响,且计算效率较低,难以满足复杂地质条件下的高精度反演需求。近年来,卷积神经网络(CNN)凭借其强大的非线性建模能力和端到端学习方法,在地震波阻抗反演中得到广泛应用,能够有效地将地震数据映射到波阻抗值。然而,深度 CNN 网络仍然面临梯度消失、梯度爆炸和过拟合等问题,影响反演结果的稳定性和精度。为克服这些局限性,本文提出了一种基于 ResUNet 的反演方法,通过在 UNet 结构中引入残差块,缓解梯度消失和信息丢失问题,从而提高反演的准确性和稳定性。本文采用正演建模生成合成地震数据,并利用这些数据训练 ResUNet,随后将地震数据输入训练好的网络,以获得阻抗反演结果。然而,智能反演结果在复杂地质特征(如断层)附近可能会出现离散伪影和“尖峰”现象,影响反演结果的平滑性和连续性。为此,本文进一步引入平滑技术以优化反演结果,减少异常,提高稳定性。通过理论模型测试和实际数据验证,结果表明,结合平滑技术的 ResUNet 能够有效提高地震波阻抗反演的精度和稳定性,为智能地震反演提供了一种可行的新方法。

关键词 地震波阻抗反演;非线性;ResUNet;平滑滤波

中图分类号 P631

Abstract Seismic inversion, a critical method for inferring subsurface petrophysical parameters (acoustic impedance) from seismic data, plays a vital role in hydrocarbon exploration and geological research. However, conventional seismic inversion methods heavily rely on low-frequency background models, exhibit sensitivity to noise interference, and suffer from low computational efficiency, making them inadequate for high-precision inversion under complex geological conditions. In recent years, Convolutional Neural Networks (CNN) have been widely adopted in seismic impedance inversion due to their strong nonlinear modeling capabilities and end-to-end learning approaches, enabling effective mapping of seismic data to impedance values. Nevertheless, deep CNN architecture still face challenges such as gradient vanishing, gradient explosion, and overfitting, which compromise the stability and accuracy of inversion results. To address these limitations, this study proposes a ResUNet-based inversion approach by integrating residual blocks into a UNet framework, thereby mitigating gradient vanishing and information loss issues while enhancing inversion accuracy and stability. Synthetic seismic data generated through forward modeling were used to train the ResUNet model, and real seismic data were subsequently input into the trained network to derive impedance inversion results. However, the intelligent inversion outputs may exhibit discrete artifacts and “spiking” phenomena near complex geological features (fault), impairing the smoothness and continuity of the results. To optimize the inversion outputs, a post-processing smoothing technique was further introduced to suppress anomalies and improve stability. Theoretical model testing and real-data validation demonstrate that the ResUNet combined with smoothing effectively enhances the precision and stability of seismic

文献标识码 A

doi:10.6038/pg2026JJ0130

CSTR:32085.14.pg2026JJ0130

acoustic impedance inversion, offering a feasible novel method for intelligent seismic inversion applications.



Keywords Seismic impedance inversion; Nonlinear; ResUNet; Smooth filtering

0 引言

地震反演是储层预测中最重要的方法之一. 其目的是通过分析地震波在地下介质中的传播特性, 从地震数据中提取地下岩层的弹性参数, 如声波阻抗、密度和速度等. 这一过程有助于推断地下储层的物理性质及流体的分布情况. 地震阻抗反演是地震反演的关键组成部分, 旨在提取地下介质的声波阻抗信息, 以识别不同岩层之间的界面及其性质变化. 地震阻抗反演的概念最早提出于 20 世纪 70 年代 (卢占武和韩立国, 2002), 此后, 叠后地震反演取得了显著成功, 并发展出多种成熟的技术, 从直接反演到基于模型的反演, 从局部优化到全局优化 (李红等, 2007; Conti *et al.*, 2013; 撒利明等, 2015). 这些方法包括地震直接反演、测井约束地震反演、井震联合反演以及地震约束测井反演等, 并在油气勘探的不同阶段得到广泛应用 (张永刚, 2002; 杨立强, 2003). 直接反演算法简单, 但受地震带宽限制, 导致分辨率不足, 反演精度较低. 基于模型的反演原理是在低频模型的约束下, 对合成地震记录进行调整, 以最小化与真实地震数据之间的误差. 该方法通过迭代优化, 提高地震阻抗反演的精度. 非线性方法通常采用随机搜索算法, 以摆脱局部最优并实现全局优化. 然而, 其计算复杂度较高, 限制了在高维反演问题中的应用.

近年来, 智能算法蓬勃发展, 深度学习通过增加网络深度增强了传统神经网络的能力, 使其能够处理和构建更复杂的映射关系, 自动提取并学习数据中的复杂特征, 从而降低对高质量初始模型的依赖. 通过多层非线性变换、深度网络结构以及迭代优化技术, 深度学习模型能够充分探索参数空间, 降低陷入局部最优的风险. 为解决复杂、高度非线性的地球物理问题提供了有效手段. 目前, 深度学习已应用于多个地球物理问题的解决, 如地震数据插值、油气储层预测、断层检测和地质体识别等. 自 2019 年以来, 基于神经网络的随机地震反演方法被提出 (赵鹏飞等, 2019). 该方法采用单隐层前馈神经网络, 在多阻抗参数的反演问题上取得了一定成效, 尤其是在处理 500 个阻抗参数时表现出显著优势. 然而, 由于

该方法仍然依赖于无监督学习的特性, 无法充分利用标注数据来优化反演精度, 因此研究兴趣逐渐转向监督神经网络. 同时, 基于传统卷积神经网络 (CNN) 和全卷积网络 (FCN) 的地震阻抗反演方法也被提出 (Das *et al.*, 2019; Wu *et al.*, 2020). FCN 主要由卷积层组成, 具有无需全连接层、可接受任意尺寸的地震数据、并引入跳跃连接 (skip connections) 等优点, 这些特点提高了反演模型的鲁棒性和精度, 从而优化了基于传统 CNN 的反演结果. 然而, 在训练过程中, FCN 未能充分考虑特征之间的因果关系, 导致地震数据与阻抗数据之间的映射关系不够精确. 2021 年以后, 许多研究者针对地震阻抗反演中传统网络结构的局限性提出了相应的改进方法 (Yu and Ma, 2021). 例如, 为了弥补传统 FCN 在处理特征因果关系方面的不足, Dixit 等 (2021) 提出了一种基于遗传进化自适应矩估计 (G-ADAM) 优化器的改进方法. FCN 在训练过程中容易忽略特征之间的关系, 导致反演精度较低, 而 G-ADAM 优化器的引入能够有效改善这一问题, 特别是在提升反演精度和稳定性方面取得了显著成效, 使反演精度达到 98%. 此外, Wang 等 (2022) 针对传统 CNN 和 FCN 方法的不足, 提出了一种基于循环一致生成对抗网络 (Cycle-GAN) 的地震阻抗反演方法. 通过引入生成对抗网络 (GAN), Cycle-GAN 能够有效克服传统网络结构在处理复杂数据集时的不足, 尤其在处理实际地震数据时, 能够生成更准确的反演结果. 与传统 CNN 方法相比, Cycle-GAN 在合成数据与真实数据之间的映射精度上表现出更强的适应性和鲁棒性. 在网络结构和超参数优化方面, Zhang 等 (2022) 深入研究了不同网络结构和超参数对地震阻抗反演性能的影响. 他们发现, 传统网络结构在处理复杂地震数据时容易出现过拟合或局部最优问题. 因此, 他们提出了一系列结构优化方法, 并通过实验验证了这些方法在提高反演精度和计算效率方面的有效性. 这些研究表明, 自 2021 年以来, 研究人员基于深度学习、生成对抗网络以及优化算法提出了一系列创新解决方案. 通过改进网络结构、优化训练方法以及调整超参数, 成功克服了以往方法的局限性, 显著提升了地震阻抗反演的精度和稳定



(a) 反演网络整体结构图;(b) 模型中残差块 1 具体结构;(c) 模型中残差块 2 具体结构.
Fig.2 Network structure diagram
(a) Overall architecture of the inversion network;(b) Detailed structure of ResNet block 1 in the model;
(c) Detailed structure of ResNet block 2 in the model.




图 3 平滑处理实现过程

Fig.3 Smoothing implementation process




图 4 40 Hz、0°相位雷克子波产生的倾斜层波阻抗 (a) 和合成地震记录 (b)

Fig. 4 Inclined-layer impedance (a) and synthetic seismic record (b) generated by a 40 Hz, 0° phase Ricker wavelet




图 5 40 Hz、0°相位雷克子波产生的楔形波阻抗 (a) 和合成地震记录 (b)

Fig. 5 Wedge-shaped impedance (a) and synthetic seismic record (b) generated by a 40 Hz, 0° phase Ricker wavelet




图 6 20 Hz、0°相位雷克子波产生的复杂地区波阻抗 (a) 和合成地震记录 (b)

Fig. 6 Complex region impedance (a) and synthetic seismic record (b) generated by a 20 Hz, 0° phase Ricker wavelet




图 7 数据归一化后地震数据 (a) 和对应阻抗分布 (b)
Fig. 7 Seismic data after normalization (a) and corresponding impedance (b)




图 8 倾斜地层地震数据 (a) 和对应阻抗分布 (b) 抽取道
Fig. 8 Extracted traces of the inclined-layer seismic data (a) and the corresponding impedance (b)




图 9 楔形地层地震数据 (a) 和对应阻抗分布 (b) 抽取道
Fig. 9 Extracted traces of the wedge-shaped seismic data (a) and the corresponding impedance (b)




图 10 复杂地层地震数据 (a) 和对应阻抗分布 (b) 抽取道
Fig. 10 Extracted traces of the complex-layer seismic data (a) and the corresponding impedance (b)




图 11 (a) ResUNet 反演倾斜层阻抗训练损失值变化曲线; (b) ResUNet 反演倾斜层阻抗训练损失值变化: epoch 从 100 到 499 放大图; (c) ResUNet 反演倾斜层阻抗 (反归一化后) 剖面; (d) ResUNet 反演倾斜层真实阻抗分布; (e) ResUNet 反演倾斜层阻抗绝对误差; (f) ResUNet 反演倾斜层阻抗相对误差

Fig. 11 (a) The training loss curve of the ResUNet for inverting the inclined-layer impedance; (b) The magnified view of the ResUNet training loss for the inclined-layer impedance inversion from epoch 100 to 499; (c) The profile of the inclined-layer impedance (after denormalization) inverted by the ResUNet; (d) The true impedance distribution of the inclined layer; (e) The absolute error of the ResUNet-inverted inclined-layer impedance; (f) The relative error of the ResUNet-inverted inclined-layer impedance

性. 进入 2023 年后, 研究人员进一步针对地震阻抗反演中以往网络结构的局限性提出了改进方案. Tao 等 (2023) 提出了一种自注意力 (Self-Attention) U-Net 模型, 该模型结合地震剖面与背景阻抗来预测声波阻抗. 该模型在 1158 对局部成像剖面数据集上训练, 并在约 300 次迭代后收敛, 显著提高了阻抗预测的精度. 此外, 王康等 (2023) 提出了一种基于通道阈值的全卷积残差收缩网络 (FCRSN-CW) 方法, 该方法通过引入软阈值和注意力机制, 提高了网络的学习能力和抗噪性. 与传统方法相比, 该方法在理论模型和实际数据上均表现出更优越的反演效果. 这些基于自注意力机制、全卷积网络和残差网络的创新方法, 在提升地震阻抗反演的精度、稳定性和抗噪性方面取得了显著进展 (Dodda *et al.*, 2023; Fu *et al.*, 2023; Li *et al.*, 2023).

在智能反演过程中, 离散现象频繁出现, 许多研究人员正在探索各种解决方案. 随着图像处理技术的不断进步, 智能反演结果的剖面处理可以被视为一种特殊的图像处理任务 (Li *et al.*, 2021). 图像处理技术正在快速发展. 例如, 在 Rahman 和 Hasan (2003) 创新性地 将中值滤波与小波变换相结合, 并将其应用于图像滤波领域, 成功克服了单一方法的局限性. 在刘小征等 (2008) 开展的研究中, 他们将神经网络与小波变换结合, 用于磁共振成像 (MRI) 图像的去噪, 并取得了令人满意的效果. 同年, Zhao 等 (2007) 也将小波变换滤波应用于合成孔径雷达 (SAR) 图像的去噪. 然而, 每种滤波方法都有其特定的适用范围. 在实际应用场景中, 确定最优的去噪算法并非易事. 如果某种滤波算法能够实现预期的平滑效果, 并满足特定任务的要求, 那么它就可以被认




图 12 (a)ResUNet 反演楔形地层阻抗训练损失值变化曲线;(b)ResUNet 反演楔形地层阻抗训练损失值变化:epoch 从 100 到 499 放大图;(c) ResUNet 反演楔形地层阻抗(反归一化后)剖面;(d)ResUNet 反演楔形地层真实阻抗分布;(e) ResUNet 反演楔形地层阻抗绝对误差;(f) ResUNet 反演楔形地层阻抗相对误差

Fig. 12 (a) The training loss curve of the ResUNet for inverting the wedge-shaped-layer impedance; (b) The magnified view of the ResUNet training loss for the wedge-shaped-layer impedance inversion from epoch 100 to 499; (c) The profile of the wedge-shaped-layer impedance (after denormalization) inverted by the ResUNet; (d) The true impedance distribution of the wedge-shaped layer; (e) The absolute error of the ResUNet-inverted wedge-shaped-layer impedance; (f) The relative error of the ResUNet-inverted wedge-shaped-layer impedance

为是一种合适且高效的滤波方法,这无疑为解决智能反演后离散现象的有效途径之一.

本文采用深度学习算法与平滑滤波相结合的方法,实现叠后阻抗反演.深度学习部分采用基于 ResNet 和 U-Net 的复合模型 ResUNet (Residual U-Net)进行阻抗反演.随后,对预测的阻抗结果应用平滑滤波技术,以进一步提高准确性.引入残差块可以在不增加额外参数的情况下加深模型层数,从而提升模型的表达能力,使其更好地拟合复杂数据分布. U-Net 结构充分利用了低层和高层特征,减少信息损失,显著提升了阻抗反演预测结果的质量.该复合网络模型不仅具备深度网络强大的特征提取能力,还能有效保留重要的细节信息,从而实现高精度的深度学习阻抗反演.在完成深度学习反演后,进一步采用平滑滤波优化预测结果.具体而言,平滑滤波

能够减少预测结果中的随机噪声,消除局部极值,使反演结果更加平滑和连续.通过将平滑滤波与深度学习反演相结合,我们可以在保持高分辨率细节的同时显著降低噪声干扰,从而得到更加准确可靠的阻抗反演结果.

实验结果表明,采用该方法的阻抗反演在复杂地区的应用表现更加显著.将该反演方法应用实际工区数据,结果表明,该波阻抗反演方法能够更准确预测波阻抗剖面,验证了该方法的实用性和优越性.

1 方法原理

1.1 ResUNet 反演及复杂地质区精度提升工作流程

其主要流程共分为 4 个步骤(图 1):




图 13 (a)ResUNet 反演复杂地层阻抗训练和验证损失值变化曲线;(b)ResUNet 反演复杂地层阻抗(反归一化后)剖面;(c)ResUNet 反演复杂地层阻抗与真实阻抗差值分布;(d)ResUNet 反演复杂地层真实阻抗分布;
(e)ResUNet 反演复杂地层阻抗绝对误差;(f)ResUNet 反演复杂地层阻抗相对误差

Fig. 13 (a) Training and validation loss curves of the ResUNet for inverting the complex-layer impedance;
(b) Profile of the complex-layer impedance (after denormalization) inverted by the ResUNet;
(c) Difference distribution between the ResUNet-inverted complex-layer impedance and the true impedance;
(d) True impedance distribution of the complex layer; (e) Absolute error of the ResUNet-inverted complex-layer impedance; (f) Relative error of the ResUNet-inverted complex-layer impedance

- (1)通过正演得到合成地震数据,构成数据集;
- (2)从训练集中抽取数据训练 ResUNet 网络;
- (3)训练完毕,将地震数据输入 ResUNet 网络,直接得到反演结果;

(4)对预测的反演结果再处理,进一步提升预测结果的精度和稳定性.

1.2 ResUNet 网络结构

实验开始前,首先测试了 UNet 及其 UNet 改进模型的泛化能力,表 1 显示了 UNet 网络与其改进模型在泛化能力方面的对比.结果表明,ResNet 和 UNet 结合的复合网络具有更好的预测效果.因此,最终选择 ResUNet 模型来进行地质区的深度学习阻抗反演,本实验所采用的网络结构如上图 2 所示.

表 1 UNet 网络及其改进模型泛化能力对比			
Table 1 Comparison of the generalization capabilities between UNet and its improved models			
Model	Correlation	MSE	RMSE
UNet	0.98320	0.19300	0.43932
ResUNet	0.99357	0.07558	0.27491
M2S-UNet	0.99024	0.11247	0.33536

1.3 平滑处理方法

在实际情况下,我们只能通过测井数据获得部分储层信息,无法完全掌握工区的真实地下储层参数.由于数据噪声、断层及其他地质不连续性的影响,反演方法获得的地层信息在复杂区域的预测精度较低,横向连续性不高,特别是在断层附




图 14 带噪声数据倾斜地层的反演预测阻抗

(a)35 dB 噪声条件下的反演结果;(b)35 dB 噪声条件下的反演结果;(c)25 dB 噪声条件下的反演结果;(d)25 dB 噪声条件下的反演结果;
(e)15 dB 噪声条件下的反演结果;(f)15 dB 噪声条件下的反演结果;(g)5 dB 噪声条件下的反演结果;(h)5 dB 噪声条件下的反演结果。

Fig. 14 Inversion-predicted impedance for the inclined layer with noisy data

(a) Inversion results under 35 dB noise conditions;(b) Inversion results under 35 dB noise conditions;(c) Inversion results under 25 dB noise conditions;(d) Inversion results under 25 dB noise conditions;(e) Inversion results under 15 dB noise conditions;(f) Inversion results under 15 dB noise conditions;(g) Inversion results under 5 dB noise conditions;(h) Inversion results under 5 dB noise conditions.

近容易出现“尖峰”现象,而横向上本应是连续的.这种现象会影响数据的准确性和可靠性,因此本文采用基于统计特性的平滑滤波技术,以提高反演预测的阻抗数据的精确性和可靠性(谢勤岚, 2009).

平滑,也称为模糊或滤波,是一种空间域滤波技术,旨在增强低频成分.它通过处理信号使其整体更加平滑,减少噪声的影响,并提高信号质量(Gonzalez and Woods, 2009; Guo *et al.*, 2023).数字信号通常

表示为一维数据,而图像信号则表示为二维数据.常见的平滑技术包括均值滤波、中值滤波和高斯滤波,它们的原理相似:指定一个滑动窗口,计算窗口内的均值、中值或卷积值,并将其输出到当前位置.需要在深度学习反演结果之后重新处理的数据是二维数据,如图 3 为平滑处理实现过程.

对于图像信号:

(1)均值滤波.将一个像素点的值设置为其邻域像素值的平均值.这种方法可以有效地减少图像中的




图 15 带噪声数据楔形地层的反演预测阻抗

(a) 35 dB 噪声条件下的反演结果; (b) 35 dB 噪声条件下的反演结果; (c) 25 dB 噪声条件下的反演结果; (d) 25 dB 噪声条件下的反演结果;
(e) 15 dB 噪声条件下的反演结果; (f) 15 dB 噪声条件下的反演结果; (g) 5 dB 噪声条件下的反演结果;
(h) 5 dB 噪声条件下的反演结果。

Fig. 15 Inversion-predicted impedance for the wedge-shaped layer with noisy data

(a) Inversion results under 35 dB noise conditions; (b) Inversion results under 35 dB noise conditions;
(c) Inversion results under 25 dB noise conditions; (d) Inversion results under 25 dB noise conditions;
(e) Inversion results under 15 dB noise conditions; (f) Inversion results under 15 dB noise conditions;
(g) Inversion results under 5 dB noise conditions; (h) Inversion results under 5 dB noise conditions.

随机噪声,但可能会使图像变得模糊.通常邻域都取成 $N \times N$ 的方形窗口,将其降噪平滑后的图像为:

$$\bar{g}(x,y) = \frac{1}{M} \sum_{(i,j) \in s} g(i,j) \quad (1)$$

其中, s 是点 (x,y) 邻域内的点集, M 是点集 s 中的总点数.

(2) 中值滤波. 将一个像素点的值设置为其邻域像素值的中值,是一种典型的排序滤波器. 对于异

常值具有很好的抑制,保护边缘信息也具有一定的优势:

$$V_{\text{out}} = \text{median} \{ a_1, a_2, a_3, \dots, a_n \} \quad (2)$$

$a_1, a_2, a_3, \dots, a_n$ 是邻域各点像素值. 中值滤波后的图像 $g(x,y)$ 是以 (x,y) 为中心的 $N \times N$ 窗口的各像素值.

(3) 高斯滤波. 其基本原理是对目标图像的像素进行加权平均,针对图像某个点像素值,计算其本




图 16 带噪声数据复杂地层的反演预测阻抗

(a)35 dB 噪声条件下的反演结果;(b)35 dB 噪声条件下的反演结果;(c)25 dB 噪声条件下的反演结果;(d)25 dB 噪声条件下的反演结果;
(e)15 dB 噪声条件下的反演结果;(f)15 dB 噪声条件下的反演结果;(g)5 dB 噪声条件下的反演结果;
(h)5 dB 噪声条件下的反演结果。

Fig. 16 Inversion-predicted impedance for the complex layer with noisy data

- (a) Inversion results under 35 dB noise conditions;(b) Inversion results under 35 dB noise conditions;
(c) Inversion results under 25 dB noise conditions;(d) Inversion results under 25 dB noise conditions;
(e) Inversion results under 15 dB noise conditions;(f) Inversion results under 15 dB noise conditions;
(g) Inversion results under 5 dB noise conditions;(h) Inversion results under 5 dB noise conditions.

身及其相邻像素值的加权平均值来确定. 设定大小为 $N \times N$ 的平滑窗口,对窗口预设一个符合高斯分布的卷积核,用卷积核遍历图像每个像素,将卷积运算出的加权平均值替代卷积核的中心像素,以此完成高斯滤波平滑处理.

平滑滤波方法的选取依数据而定,多种平滑滤波方法可能导致信号损失. 本文采用基于局部均值和中值滤波的平滑技术来改善反演预测的阻

抗数据,避免单一方法或多种方法过度平滑. 该方法有效压制噪声,减轻断层等不连续性对预测阻抗的影响,同时保留主要的地质特征,从而提高数据的准确性.

2 实验

2.1 正演数值模拟

本文实验使用的波阻抗数据和合成地震记录成




图 17 平滑处理流程

Fig. 17 Smoothing implementation process

图如图 4、图 5、图 6 所示,分别为倾斜层模型、楔形模型以及复杂地区模型.

波阻抗数据是由各模型纵波速度产生的,其数值等于介质密度 ρ 与波速 v 的乘积. 阻抗分布如图 4a、5a、6a 所示,倾斜层模型和楔形模型由 750 条阻抗数据组成,每列阻抗有 750 个采样点,采样间隔为 1 ms. 复杂工区模型由 681 条阻抗数据组成,每列阻抗有 321 个采样点,采样间隔为 3 ms. 正演计算得到合成地震数据集,具体计算方法是首先根据波阻抗求出反射系数 R ,再将地震子波和反射系数进行卷积运算. 根据褶积原理可得:

$$R_i = \frac{Z_{i+1} - Z_i}{Z_{i+1} + Z_i}, \tag{3}$$

$$Seis = W * R, \tag{4}$$

式中: R_i 为反射系数 $R(t)$ 的第 i 个采样点; Z_i 为阻抗 $Z(t)$ 的第 i 个采样点. 倾斜层和楔形波阻抗采用频率为 40 Hz,相位为 0° ,幅度为 $-0.44 \sim 1$ ms 的雷克子波与反射系数进行褶积运算,复杂地区波阻抗采用频率为 20 Hz,相位为 0° ,幅度为 $-0.44 \sim 0.97$ ms 的雷克子波与反射系数进行褶积运算,分别得到地震合成记录分布如图 4b、5b、6b 所示,从波阻抗和地震记录中抽取数据作为网络的训练集.

2.2 反演实验

在地震勘探中,地震数据质量良莠不齐,为确保数据的有效性并加快网络在训练过程中的收敛速




图 18 (a)ResUNet 反演复杂地层阻抗平滑处理后的剖面;(b)ResUNet 反演与平滑处理结果和真实阻抗差值; (c) ResUNet 反演与平滑处理结果和 ResUNet 反演结果差值

Fig. 18 (a) Smoothed profile of the ResUNet-inverted complex-layer impedance;(b) Difference between the ResUNet inversion & smoothing result and the true;(c) Difference between the ResUNet inversion & smoothing result and the ResUNet inversion result




图 19 ResUNet 反演平滑处理的单道时域频域对比

Fig. 19 Time-domain and frequency-domain comparison of a single trace from the smoothed ResUNet inversion result




图 20 Volve 油田的位置 (a) 和 Volve 油田的地震数据和测井数据 (b)

Fig. 20 Location of the Volve field (a) and the seismic data and well log data from the Volve field (b)

度,在将地震数据及其对应的波阻抗标签输入网络之前,需要对地震样本进行预处理. 数据归一化方法采用最大最小归一化,归一化方程为:

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (5)$$

模型数据归一化过程中,可以根据数据的分布范围确定归一化所用数值参数,参数 $x_{\max}$ 和 $x_{\min}$ 取数据最大值和最小值,如图 7 显示了归一化后的地震数据及其对应的阻抗分布.

倾斜层和楔形模型每隔 25 道均匀抽取一道地震道和对应阻抗序列作为训练样本,全部地震道和对应阻抗序列作为测试样本. 复杂地区模型数据量较小,为了进一步模拟实际工区,采取每隔 35 道均匀抽取地震道及其对应的阻抗序列作为训练




图 21 真实和预测阻抗及地震记录的比较

Fig. 21 Comparison of the true and predicted impedance and seismic records




图 22 工区中间测线地震切片噪声压制后的结果

Fig. 22 Results after noise suppression of the mid-line seismic slice in the survey area




图 23 基于 ResUNet 与平滑处理结合预测的阻抗分布

Fig. 23 Impedance distribution based on the combined method of ResUNet and smoothing processing

样本,选取第 200 道和第 400 道地震道及其对应阻抗序列作为验证集,全部地震道及其对应阻抗序列作为测试样本.如图 8、图 9、图 10 所示,分别展示了倾斜地层、楔形地层以及复杂地层模型的抽取道.

网络基于 PyTorch 搭建,初始学习率、批处理量 (batch_size) 等超参数根据不同地区模型进行相应调节.针对地震波阻抗反演问题,采用的目标损失函数为均方误差 (Mean Square Error, 简称 MSE) 损失函数:

$$\text{MSE} = \frac{1}{n} \sum (y_i - \hat{y}_i)^2, \tag{6}$$

式中, n 为样本的个数; y_i 是地震波阻抗预测值; $\hat{y}_i$ 是地震波阻抗标签值.

网络训练完毕后用全部地震数据进行预测.预测结果进行反归一化处理,假设需要归一化的数据为 x ,归一化得到的数据是 y ,反归一化方程:

$$y = x \cdot (x_{\max} - x_{\min}) + x_{\min}, \tag{7}$$

以此得到网络预测的波阻抗结果.图 11 至图 13 分别展示了倾斜地层、楔形地层和复杂地层模型基于 ResUNet 模型的波阻抗反演结果.

在真实环境中,地震道数据通常带有不同程度的噪声,这些噪声会直接影响网络的反演结果,因此抗噪能力分析也是评估网络质量的重要步骤.本文通过加噪地震数据的反演实验测试了 ResUNet 的抗

噪性能,给合成地震数据分别加上信噪比 35、25、15、5 dB 高斯噪声,与上面实验方法相同,倾斜层和楔形地层取 45 和 650 道,复杂地层取 198 和 545 道,观察其反演预测的阻抗与真实阻抗之间的差距.图 14a—h、图 15a—h、图 16a—h 所示分别为信噪比在 35、25、15、5 dB 的高斯噪声环境下预测阻抗和真实阻抗的对比.

实验结果表明:简单地层相对复杂地层,信噪比大小对反演结果影响较小,模型具有较强的抗噪声能力.在复杂地层下,当信噪比小于等于 5 dB 时,噪声比较大,本方法反演结果明显变差,当信噪比大于 5 dB 时,反演结果与真实阻抗曲线大体一致.因此用本方法处理实际资料的时候,应该尽量控制数据噪声的信噪比大于 5 dB,以确保得到较准确的反演结果.

3 对预测结果的再处理

实验所用数值模拟的复杂模型存在多个断层以及薄储层等特征,使用深度学习方法预测的阻抗剖面在复杂特征处预测不够精准,因此我们考虑使用地球物理方法对复杂区域做进一步处理,减小噪声,增强信号的连续性和稳定性,并保留主要的地质特征,实验结果显示,使用平滑处理方法对深度学习预测结果进一步处理后,剖面的分辨率和连续性得到了显著提高.

本文选用基于局部均值和中值滤波的平滑处理技术来改进反演预测的阻抗数据,实验在 MATLAB 中实现,处理框架流程如图 17 所示.图 18 展示了深度学习反演的再处理结果、再处理结果与真实阻抗之间的差值,以及再处理结果与初始反演结果的差值.图 19 显示了再处理结果中第 104、212、400 和 500 道的时域与频域对比.表 2 对比了深度学习方法预测与深度学习方法预测后再处理的评估指标,结果表明,再处理后的预测结果精度更高.

表 2 深度学习方法预测和深度学习与平滑处理方法预测结果评估指标对比

Model	Correlation	R^2	MSE	RMSE
ResUNet	0.993569	0.986936	0.0755778	0.274914
ResUNet_Reprocess	0.998387	0.996486	0.0203311	0.142587

4 实际资料应用

我们使用挪威近海的 Volve 实测数据来验证所提出的方法的有效性.如图 20 所示,Volve 油田是一个碎屑岩储层,位于挪威近海.网络训练的数据集是根据图 20b 中所示测井数据特性使用数据扩充方法生成的,最后得到一个大小为 $151 \times 151 \times 160$ 的三维数据集,地震道长度为 160,随机选择 750 个地震道作为标记的训练数据,模型得以充分学习和泛化.将训练好的模型应用到实测地震数据中获得阻抗分布,图 21a 显示了真实阻抗生成的合成地震记录(黑色实线)和预测阻抗生成的合成地震记录(红色虚线),图 21b 显示了预测阻抗与真实测井阻抗的比较,由图可以看出预测的阻抗与真实测井阻抗匹配度较高,相关系数为 0.86,表明预测阻抗与真实阻抗之间具有较强的线性相关性.将训练好的模型应用到该工区中间测线的切片数据中,获得对应的地下阻抗分布,图 22 展示了工区中间测线地震切片噪声压制后的结果,图 23 显示了对预测结果平滑处理后的阻抗分布,通过红色矩形区域可以看出,平滑处理后的阻抗分布在精度和横向连续性上均优于仅使用深度学习算法预测的阻抗分布.

5 结 论

本文提出了一种结合 ResUNet 和平滑滤波方法的地震波阻抗反演技术. ResUNet 具备深层网络的强大特征提取能力,并能有效保留重要细节信息.经过模型泛化能力的比较, ResUNet 更能够非线性地实现地震波阻抗反演.平滑滤波技术进一步处理了预测区域的“尖峰”、横向连续性差等不精确现象,显著提升了区域的精度和分辨率.正演模型数据测试和实际资料应用表明,该方法能够得到较高精度的波阻抗反演结果,为智能化地震储层预测提供了一种有效的技术手段.

因为深层神经网络需要大量已知样本对其进行训练,尽管尽量模拟实际工区,但仍与地震勘探领域的实际情况不符,后续研究将进一步构建小样本下的深度学习波阻抗反演方法.

致 谢 感谢审稿专家提出的修改意见和编辑部的大力支持!

References

Conti C R, Roisenberg M, Neto G S, et al. 2013. Fast seismic inversion

- p>methods using ant colony optimization algorithm.
- IEEE Geoscience and Remote Sensing Letters*
- , 10(5): 1119-1123.
- Das V, Pollack A, Wollner U, *et al.* 2019. Convolutional neural network for seismic impedance inversion. *Geophysics*, 84(6): R869-R880.
- Dixit A, Mandal A, Sanyal S, *et al.* 2021. A Genetic-Evolutionary ADAM (G-ADAM) optimizer for semisupervised convolutional neural network-based acoustic impedance inversion. //*Proceedings of the First International Meeting for Applied Geoscience & Energy. SEG.*
- Dodda V C, Kuruguntla L, Mandpura A K, *et al.* 2023. Deep convolutional neural network with attention module for seismic impedance inversion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16: 8076-8086.
- Fu J C, Fan R, Cao J X, *et al.* 2023. Seismic impedance inversion using a joint deep learning model based on convolutional neural network and transformer. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16: 8913-8922.
- Gonzalez R C, Woods R E. 2009. *Digital Image Processing*. 3rd ed. Pearson Education.
- Guo J W, Ma J M, García-Fernández á F, *et al.* 2023. A survey on image enhancement for Low-light images. *Heliyon*, 9(4): e14558, doi: 10.1016/J.HELİYON.2023.E14558.
- Li H, Lü J Y, Wang H Y. 2007. Exploration logging-constrained inversion technique predicting coal-thickness. *Coal Geology & Exploration (in Chinese)*, 35(1): 74-77.
- Li M, Yan X S, Zhang M Z. 2023. A comprehensive review of seismic inversion based on neural networks. *Earth Science Informatics*, 16(4): 2991-3021.
- Li P, Wang H J, Yu M B, *et al.* 2021. Overview of image smoothing algorithms. *Journal of Physics: Conference Series*, 1883(1): 012024, doi: 10.1088/1742-6596/1883/1/012024.
- Liu X Z, Fu C X, Yang G. 2008. An MRI image denoising algorithm using neural network analysis and wavelet transformation. *Chinese Journal of Magnetic Resonance (in Chinese)*, 25(2): 234-242.
- Lu Z W, Han L G. 2002. The development of the research of the wave impedance inversion technique. *World Geology (in Chinese)*, 21(4): 372-377.
- Rahman S M M, Hasan K. 2003. Wavelet-domain iterative center weighted median filter for image denoising. *Signal Processing*, 83(5): 1001-1012.
- Sa L M, Yang W Y, Yao F C, *et al.* 2015. Past, present, and future of geophysical inversion. *Oil Geophysical Prospecting (in Chinese)*, 50(1): 184-202.
- Tao L R, Ren H R, Gu Z W. 2023. Acoustic impedance inversion from seismic imaging profiles using self attention U-Net. *Remote Sensing*, 15(4): 891, doi: 10.3390/rs15040891.
- Wang K, Liu C Y, Xiong J, *et al.* 2023. Seismic wave impedance inversion based on the fully convolutional residual shrinkage network. *Geophysical and Geochemical Exploration (in Chinese)*, 47(6): 1538-1546, doi: 10.11720/wtyht.2023.1569.
- Wang Y Q, Wang Q, Lu W K, *et al.* 2022. Seismic impedance inversion based on cycle-consistent generative adversarial network. *Petroleum Science*, 19(1): 147-161.
- Wu B Y, Meng D L, Wang L L, *et al.* 2020. Seismic impedance inversion using fully convolutional residual network and transfer learning. *IEEE Geoscience and Remote Sensing Letters*, 17(12): 2140-2144.
- Xie Q L. 2009. Adaptive Gaussian smoothing filter for image denoising. *Computer Engineering and Applications (in Chinese)*, 45(16): 182-184.
- Yang L Q. 2003. A review of well log constrained seismic inversion. *Progress in Geophysics (in Chinese)*, 18(3): 530-534.
- Yu S W, Ma J W. 2021. Deep learning for geophysics: current and future trends. *Reviews of Geophysics*, 59(3): e2021RG000742, doi: 10.1029/2021RG000742.
- Zhang S B, Si H J, Wu X M, *et al.* 2022. A comparison of deep learning methods for seismic impedance inversion. *Petroleum Science*, 19(3): 1019-1030.
- Zhang Y G. 2002. The present and future of wave impedance inversion technique. *Geophysical Prospecting for Petroleum (in Chinese)*, 41(4): 385-390.
- Zhao J, Cao Z W, Zhou M Q. 2007. SAR image denoising based on wavelet-fractal analysis. *Journal of Systems Engineering and Electronics*, 18(1): 45-48.
- Zhao P F, Liu C, Feng X, *et al.* 2019. Stochastic seismic inversion based on neural network. *Chinese Journal of Geophysics (in Chinese)*, 62(3): 1172-1180, doi: 10.6038/cjg2019M0064.

附中文参考文献

- 李红, 吕进英, 王宏友. 2007. 波阻抗约束反演技术预测煤层厚度. *煤田地质与勘探*, 35(1): 74-77.
- 刘小征, 傅彩霞, 杨光. 2008. 基于神经网络和小波变换的 MRI 图像去噪方法. *波谱学杂志*, 25(2): 234-242.
- 卢占武, 韩立国. 2002. 波阻抗反演技术研究进展. *世界地质*, 21(4): 372-377.
- 撒利明, 杨午阳, 姚逢昌, 等. 2015. 地震反演技术回顾与展望. *石油地球物理勘探*, 50(1): 184-202.
- 王康, 刘彩云, 熊杰, 等. 2023. 基于全卷积残差收缩网络的地震波阻抗反演. *物探与化探*, 47(6): 1538-1546, doi: 10.11720/wtyht.2023.1569.
- 谢勤岚. 2009. 图像降噪的自适应高斯平滑滤波器. *计算机工程与应用*, 45(16): 182-184.
- 杨立强. 2003. 测井约束地震反演综述. *地球物理学进展*, 18(3): 530-534.
- 张永刚. 2002. 地震波阻抗反演技术的现状和发展. *石油物探*, 41(4): 385-390.
- 赵鹏飞, 刘财, 冯恒, 等. 2019. 基于神经网络的随机地震反演方法. *地球物理学报*, 62(3): 1172-1180, doi: 10.6038/cjg2019M0064.