

9-25-2024

A method for reconstructing consecutively missing seismic data based on recurrent feature reasoning

LI Zijuan

School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China,
zijuanli07@163.com

CHANG Guangyao

School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China

JIA Yongna

School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China,
jiayongna@hebut.edu.cn

Follow this and additional works at: <https://cge.researchcommons.org/journal>



Part of the [Earth Sciences Commons](#), [Mining Engineering Commons](#), [Oil, Gas, and Energy Commons](#), and the [Sustainability Commons](#)

Recommended Citation

LI Zijuan, CHANG Guangyao, JIA Yongna, et al. (2024) "A method for reconstructing consecutively missing seismic data based on recurrent feature reasoning," *Coal Geology & Exploration*: Vol. 52: Iss. 9, Article 17.
DOI: 10.12363/issn.1001-1986.24.02.0140

Available at: <https://cge.researchcommons.org/journal/vol52/iss9/17>

This Coal Geophysical Exploration, Mine Geophysical Exploration is brought to you for free and open access by Coal Geology & Exploration. It has been accepted for inclusion in Coal Geology & Exploration by an authorized editor of Coal Geology & Exploration. For more information, please contact 380940179@qq.com.



移动阅读

李紫娟, 常光耀, 贾永娜. 基于循环特征推理的大间距缺失地震数据重建方法[J]. 煤田地质与勘探, 2024, 52(9): 176–183. doi: 10.12363/issn.1001-1986.24.02.0140
LI Zijuan, CHANG Guangyao, JIA Yongna. A method for reconstructing consecutively missing seismic data based on recurrent feature reasoning[J]. Coal Geology & Exploration, 2024, 52(9): 176–183. doi: 10.12363/issn.1001-1986.24.02.0140

基于循环特征推理的大间距缺失地震数据重建方法

李紫娟, 常光耀, 贾永娜*

(河北工业大学人工智能与数据科学学院, 天津 300401)

摘要: 【目的】由于急流、裂谷、高山等自然环境的限制, 采集的地震数据会出现大间距缺失的现象, 影响后续的地震数据处理和地质分析工作, 需要对缺失数据进行插值重建。【方法】为解决大间距地震数据缺失问题, 提出一种基于循环特征推理的重建方法。首先缺失的地震数据经过部分卷积运算, 在计算过程中根据感受野内有效特征图数据的占比, 自适应地调整卷积运算结果的权重, 避免在连续缺失的地震道上执行无效的卷积操作。然后采用循环特征推理的方式, 逐步对缺失部分进行渐进式重建。部分卷积运算和循环特征推理交替进行, 直至所有缺失数据重建完成。最后特征融合每次迭代产生的重建特征, 以保证推理的准确性。为增强模型对大间距缺失区域纹理细节的学习能力, 结合纹理损失和均方误差函数作为复合损失函数, 进一步提高重建精度。【结果和结论】结果显示: (1) 基于循环特征推理的方法可以有效重建大间距缺失的地震数据, 信噪比在原缺失数据的 14.89 dB 的基础上提升至 28.15 dB。(2) 连续缺失 30 道至 80 道的多次重建实验中, 本方法的重建结果信噪比、结构相似性、均方误差等评价指标均优于 U-Net 方法。采用 6 种不同公开数据集测试了本方法的重建效果, 进一步证明了本方法的有效性。(3) 对比实验探究部分卷积核大小对重建结果的影响表明, 当部分卷积核大小为 3×3 时重建结果信噪比更高并且迭代时间更短。研究成果为大间距缺失地震数据的重建方法提供了新的解决思路。

关键词: 地震数据重建; 部分卷积; 循环特征推理; 复合损失函数

中图分类号: P631 文献标志码: A 文章编号: 1001-1986(2024)09-0176-08

A method for reconstructing consecutively missing seismic data based on recurrent feature reasoning

LI Zijuan, CHANG Guangyao, JIA Yongna*

(School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China)

Abstract: [Objective] Due to the constraints of natural environments like rapids, rifts, and high mountains, the acquired seismic data are often challenged by consecutive missing, affecting subsequent seismic data processing and geologic analysis. Hence, it is necessary to reconstruct the missing data through interpolation. [Methods] This study proposed a method for reconstructing consecutively missing seismic data based on recurrent feature reasoning. First, the missing seismic data undergo partial convolution operations, in which the weight of the convolution results is adaptively adjusted based on the proportion of valid feature map data in the receptive field, avoiding invalid convolution operations on consecutively missing seismic channels. Second, the missing parts are progressively reconstructed through recurrent feature reasoning. Partial convolution operations and recurrent feature reasoning are alternated until all missing data are reconstructed. Finally, the reconstructed features generated in each iteration are integrated through feature fusion, ensuring accurate reasoning. To enhance the model's ability to learn the texture details of consecutively missing areas, the texture

收稿日期: 2024-02-29; 接收日期: 2024-08-14

基金项目: 河北省自然科学基金项目(D2022202006); 国家自然科学基金项目(41804118)

第一作者: 李紫娟, 1999 年生, 女, 四川成都人, 硕士研究生。E-mail: zijuanni07@163.com

*通信作者: 贾永娜, 1988 年生, 女, 河北定州人, 博士, 副教授。E-mail: jiyongna@hebut.edu.cn

© Editorial Office of Coal Geology & Exploration. OA under CC BY-NC-ND

loss and mean square error (MSE) functions are combined as a hybrid loss function to further increase the reconstruction accuracy. [Results and Conclusions] Key findings are as follows: (1) The proposed method based on recurrent feature reasoning can effectively reconstruct the consecutively missing seismic data, with the signal-to-noise ratio (SNR) increased to 28.15 dB on top of the original 14.89 dB for the missing data. (2) In multiple reconstruction experiments focusing on 30 to 80 consecutively missing seismic channels, the reconstruction results demonstrate that the proposed method outperforms the U-Net method in terms of assessment indices like SNR, structural similarity, and MSE. The effectiveness of the proposed method is further verified by the reconstruction effects of the proposed method tested on six different public datasets. (3) As revealed by the impacts of the size of the partial convolution kernel on the reconstruction results investigated through comparative experiments, the reconstruction results manifest a higher SNR and a shorter iteration time when the partial convolution kernel measures 3×3 . The results of this study provide a novel approach for the reconstruction of consecutively missing seismic data.

Keywords: seismic data reconstruction; partial convolution; recurrent feature reasoning; hybrid loss function

地震勘探是石油资源勘探的主要方法, 受限于采样环境、地质条件、采样成本等自然和人为因素, 实际采集到的地震数据会出现地震道缺失的现象。随着开发程度的不断提高, 地震勘探目标周围的地理环境逐渐复杂, 在地震数据采集工作中会出现无法连续放置检波器的区域, 导致采集到大间距缺失地震数据。不完整的数据将严重影响后续的成像、分析工作, 不利于地震资料的解释^[1], 因此, 对有缺失的地震数据进行重建具有现实意义。

现有的地震数据重建法可分为模型驱动和数据驱动两类。基于模型驱动的传统地震数据重建方法通常依赖于地震数据的先验信息, 采用数学建模的方式, 通过解反问题来还原地震波形数据, 主要包括: 预测滤波重建方法^[2-3], 波动方程重建方法^[4-5], 低秩完备重建方法^[6-7], 稀疏变换重建方法^[8-9]。这类方法依赖先验知识与参数设置, 面对复杂地质环境下的数据, 尤其是数据间相关性弱的大间距缺失地震数据, 其重建效果受到限制。近年来, 深度学习作为一种流行技术, 在地球物理领域得到广泛应用^[10-12]。基于数据驱动的重建方法也随着兴起, 这类方法通过学习地震数据自身的特征分布规律, 对缺失部分进行插值。为了解决大间距缺失地震数据重建问题, 许多基于深度学习的重建方法被提出, 比如通过引入注意力模块和复合损失函数建立长距离依赖进行大间距地震数据插值^[13-14]; 构造多级 U-Net 网络模型插值低振幅缺失分量处缺失的大间距地震道^[15]; 在生成对抗网络中引入深度残差结构进行高精度插值^[16]; 通过离散小波变换的可逆性保留大间距内细节特性^[17]; 通过大量模拟数据训练 U-Net 卷积神经网络重建大间距缺失的地震数据^[18-19]。然而, 针对大间距缺失数据的重建问题, 现有深度学习方法仍面临信息相关性弱、远距离依赖建立困难等挑战。

由于大间距缺失区域内信息的相关性和约束性弱, 常规的卷积操作难以从中学习到有效信息, 更适合通过

渐进式的填充进行重建, 在特征图层面的循环渐进方法可以在减少计算量的前提下建立远距离联系。使用部分卷积在数据的有效区域进行运算, 可以在渐进式递归过程中识别需要更新的区域, 在含有大间距缺失的数据重建方面可以取得很好的效果^[20]。循环特征推理利用部分卷积算法, 可以逐渐从缺失边缘推理出特征数据, 并将其用作下一步推理的线索, 加强对缺失中心位置的约束, 最终重建出连续缺失的区域块^[21]。在深度学习的训练阶段, 通过损失值的反向传播, 消弱渐进推理过程中的误差累积。综上所述, 提出一种基于循环特征推理的地震数据重建算法, 利用感受野内的有效数据推理出缺失数据, 通过部分卷积运算逐步插值缺失数据, 循环执行以上操作, 直至重建出所有缺失区域的地震数据。另外, 为了保证推理结果的准确性, 对循环推理过程中生成的地震数据进行特征融合, 在像素级和特征空间级共同构建损失函数。期望通过高效、准确的重建算法提高大间距缺失数据重建精度, 为地震勘探提供高质量的地震数据支持。

1 网络结构

针对大间距缺失地震数据的重建问题, 提出一种基于循环特征推理的重建方法, 该方法以改进 U-Net 网络为基础架构, 利用部分卷积和特征融合算法特性解决问题, 网络整体结构如图 1 所示。

本文提出的网络结构分为 3 个部分。第一部分是区域识别模块, 用来识别本次循环中可进行特征推理的区域, 其中部分卷积算法是该模块的基础运算。第二部分是特征推理模块, 根据区域识别的结果, 推断识别区域内的内容, 使用改进后的 U-Net 网络进行特征学习, 能够在保证重建质量的同时加快训练速度。如图 1 所示, 区域识别模块和特征推理模块交替工作, 通过循环直至将所有缺失数据重建完成。第三部分是特征融合模块, 将每次区域识别和循环特征推理模块中生成的特

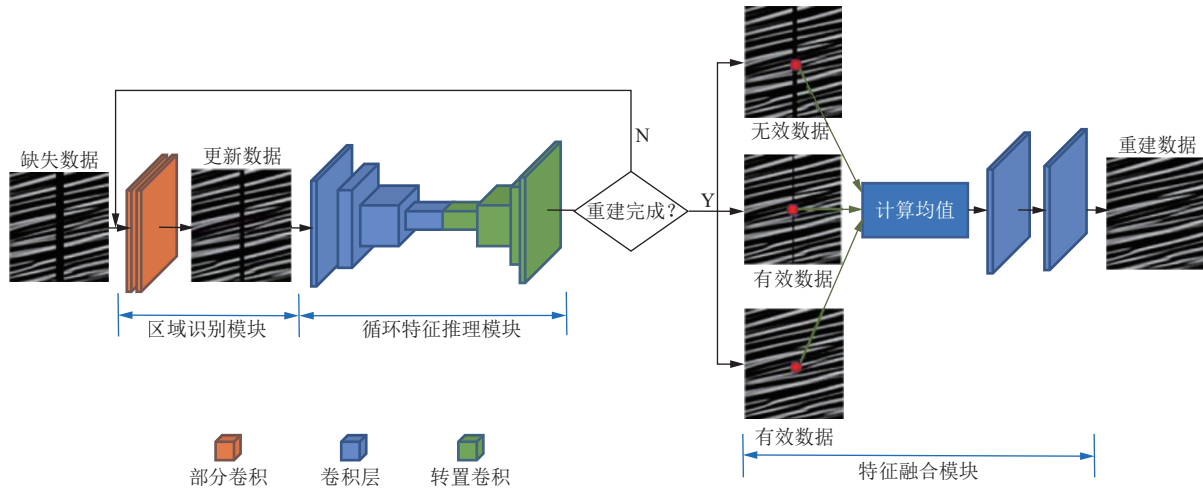


图 1 循环特征推理网络结构
 Fig.1 Network architecture for recurrent feature reasoning

征数据赋权并计算均值, 经过自适应融合并作为本轮循环的推理结果。为更好地重建大间距缺失地震数据的细节特征, 提高信噪比和重建精度, 本方法在像素级和特征空间级共同建立损失函数来优化网络模型, 结合均方误差(Mean square error, MSE) 函数和基于 VGG 网络的纹理损失函数, 有效提高重建质量。

1.1 改进 U-Net 网络基本结构

为更符合大间距缺失地震数据重建问题, 提出一种改进的 U-Net 网络结构, 如图 2 所示。首先, 将跳跃连接中级联操作改为加和操作, 可以在保证不丢失特征的前提下降低训练时长, 同时能够有效避免梯度消失的问

题。其次, 使压缩路径和扩展路径中对称部分的特征图尺寸相同, 在传统 U-Net 网络中, 扩展路径上的特征图尺寸都略小于压缩路径上相对称的特征图尺寸, 在级联操作时需要将特征图进行裁剪, 这种处理方式更符合图像分割任务。而在大间距缺失地震数据的重建问题上, 缺失数据主要集中在中间部分, 对边缘信息的依赖程度有限, 使两条路径上对应的特征图尺寸完全相同, 提高重建速度。最后, 在深层特征提取时使用了空洞卷积, 空洞卷积在常规卷积的基础上引入了膨胀率, 在扩大有效感受野的同时并不会增加过多的参数量和计算量, 有助于集成更广泛的上下文信息, 并且更好地保留图像的

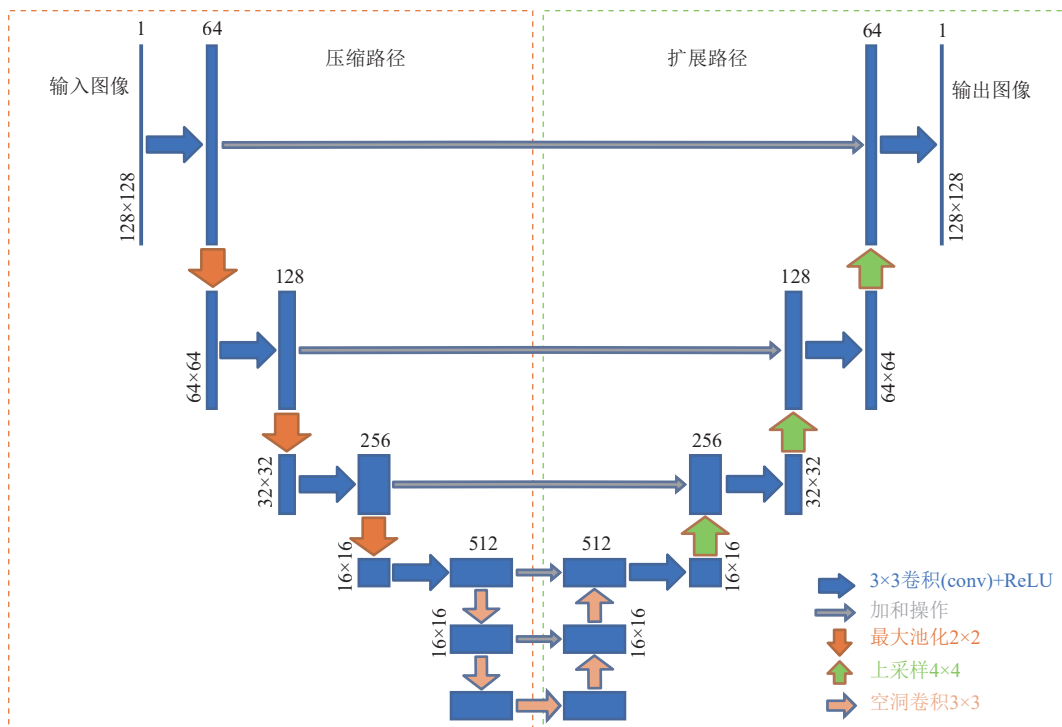


图 2 改进 U-net 网络结构
 Fig.2 Improved U-Net architecture

空间特征。

1.2 部分卷积算法

部分卷积算法用于识别每次迭代中需要更新的可推理区域并进行卷积运算,部分卷积的计算公式如下:

$$y = \begin{cases} Q^T(X \odot M \frac{\text{sum}(J)}{\text{sum}(M)}) + b, & \text{sum}(M) \neq 0 \\ 0, & \text{其他} \end{cases} \quad (1)$$

通过式(1)可以看出输出值 y 取决于未被屏蔽的输入特征区域,缩放因子 $\text{sum}(J)/\text{sum}(M)$ 可以适当调整有效输入区域。在进行卷积操作之后,对掩码进行更新,如果输出结果中至少有一个有效值,则将该位置标记为有效,标记矩阵的更新规则如下式:

$$M^* = \begin{cases} 1, & \text{sum}(M) \neq 0 \\ 0, & \text{其他} \end{cases} \quad (2)$$

标记矩阵是由0和1组成的二值矩阵,其尺寸与当前参与计算的特征图相同,其中1代表该索引位置对应的特征数据已知,0则代表该索引位置对应的特征数据处于待推理状态,在循环推理过程中会一直被保留,作为下次推理判定的依据,只要输入中包含任何有效信息,最终标记矩阵将变为全1矩阵。部分卷积操作的推理过程如图3所示,缺失数据的推理过程和标记矩阵的变化过程上下对应且同步变化,对应输入数据的缺失部分,在标记矩阵中将其标记为0,表示该部分特征区域数据缺失,在图3b中显示为黑色区域,标记矩阵的其余部分标记为1,表示有效数据区域,在图3b中显示为白色区域。首先提取有效数据,推理出相邻的缺失数据,将标记矩阵中对应位置标记为1,再重复进入循环。完成缺失地震数据的补全工作所需的循环次数取决于部分卷积核尺寸和缺失区域大小,因此自适应决定循环次数,当标记矩阵为全1矩阵时终止循环。




图3 部分卷积推理过程

Fig.3 The reasoning process of partial convolution

1.3 特征融合

在大间距缺失的地震数据中,由于缺失数据周围缺

乏足够的上下文信息来辅助缺失区域重建,推理结果存在不确定性。若直接使用循环结束后生成的特征图作为最终的推理结果,往往会因信息不足导致重建数据与实际数据间存在偏差。特别是在权重参数随机初始化不理想时,可能导致梯度弥散,影响之前迭代生成信号的质量。为了解决以上问题,采用一种自适应的方法,融合循环过程中的中间特征,仅计算对应位置处存在有效值的中间特征图,以确保融合结果的准确性和可靠性。特征融合的计算如下式:

$$\bar{f} = \frac{\sum_{j=1}^N f^j}{\sum_{j=1}^N M^j} \quad (3)$$

从上式可以得出,特征融合仅对有效的数据点求均值。基于循环特征推理的地震数据重建算法流程见表1,其中初始标记矩阵 M_0 为二值矩阵,将与大间距缺失地震数据 D_0 的缺失部分相同位置的数值设置为0,其余部分设置为1;输入数据为大间距缺失的地震数据 D_0 ,初始标记矩阵 M_0 ;输出数据为重建后的地震数据 D_{rec} 。

表1 基于循环特征推理的地震数据重建算法流程
Table 1 The algorithm process of seismic data reconstruction based on recurrent feature reasoning

步骤	具体算法
1	通过部分卷积层构成的区域识别模块更新缺失地震数据 D_r 和标记矩阵 M_r ,得到更新的地震数据 D_r^{ide} 和 M_{r+1}
2	将 D_r^{ide} 输入到改进U-Net网络进行特征推理,得到推理结果 D_{r+1}
3	将推理结果 D_{r+1} 加入特征集合FeatureCollection,若缺失数据还未完全补全,即标记矩阵 M_{r+1} 不是全1矩阵,则返回步骤1循环更新 D_{r+1} 和 M_{r+1} ;若所有缺失数据均完成推理,即标记矩阵 M_{r+1} 为全1矩阵,则执行步骤4
4	对特征集合FeatureCollection中所有推理结果进行特征融合,得到融合后的地震数据 D_{merge}
5	对 D_{merge} 输入卷积层中得到最终重建结果 D_{rec}

1.4 损失函数

在大间距缺失的地震数据重建任务中,距离缺失区域中心越近的地震数据越容易损失纹理细节,重建难度越大。广泛使用的MSE损失函数在像素级层面计算每两个点的误差,容易产生过度平滑的结果,导致地震数据结构细节的丢失或失真。仅依靠MSE损失函数很难重建出纹理特征,因此本算法结合MSE损失和特征空间级纹理损失,提高网络模型的重建精度。

MSE函数计算预测值与目标值差值平方和的均值,有助于加快收敛速度,是在高分辨率图像上的一种像素级损失。因此MSE损失函数 L_m 如下式:

$$L_m = \frac{1}{P} \|d_i - \hat{d}_i\|_F^2 \quad (4)$$

纹理损失是将地震数据映射到特征空间,利用高层

次的语义信息计算纹理特征之间的差异。本算法使用预训练的卷积神经网络捕捉地震数据中的语义信息, 损失网络是 16 层的 VGG 网络模型^[22], 其网络模型结构如图 4 所示。其中 3×3 conv 模块表示对输入数据使用 3×3 的卷积运算, 后面的数字表示特征图数量, pool/2

模块表示对数据进行最大池化。VGG16 在每次池化操作后都将特征通道数量翻倍, 同时特征图尺寸减半, 使模型架构更深更宽的同时控制计算量的规模, 提取更多深层次的信息, 最后在输出层通过三个全连接层融合特征信息, 图 4 中表示为 fc 模块。




图 4 VGG16 网络结构

Fig.4 VGG16 network architecture

纹理重建损失的核心在于度量重建数据与原始数据 Gram 矩阵的差异。Gram 矩阵是特征之间的协方差矩阵, 其构建基于特征图中的特征值, 而每个特征值都是滤波器在指定位置上的卷积运算结果, 因此, 特征值直接反映了相对应特征的强度, Gram 矩阵中的元素就代表两两特征之间的相关性, 有助于地震数据的纹理重建。基于 VGG 网络特征空间的 Gram 表达式如下:

$$\Phi_i^* = \Phi_i \Phi_i^T \quad (5)$$

则重建数据和原始数据的纹理重建损失 L_t 如下式:

$$L_t = \sum_{i=1}^N \frac{1}{C_i H_i W_i} |\Phi_i^* - \hat{\Phi}_i^*|_1 \quad (6)$$

将像素级损失和特征空间级损失相结合, 得出总体损失函数 L 表达式如下:

$$L = L_m + L_t \quad (7)$$

2 数据测试与结果分析

2.1 参数设置

使用循环特征推理网络对多组地震数据进行测试实验, 证明循环特征推理网络中部分卷积运算和特征融合对大间距缺失地震数据重建的积极作用。在训练时, 模型均使用 Python 3.8 上的 PyTorch 框架, 在 ubuntu 环境下的 NVIDIA RTX3080 服务器上计算, 设置初始学习率为 0.002, 模型优化器采用 ADAM 优化器。为平衡训练速度和收敛速度, 所有模型都以 32 个批处理大小和最多 150 个 epoch 进行训练。实验采用公开的合成和实际地震数据集, 针对连续缺失道数为 30% 的数据进行深度学习。在训练过程中采用公开数据集, 从中随机选择 20 000 个大小为 128×128 的 patch, 使用 Min-Max 归一化方法将 patch 的值归一化为 [-1,1]。其中 12 000 个数据块用于网络训练, 6 000 个数据块用于验证, 剩下的 2 000 个数据块用于测试。

为了评价重建效果, 使用信噪比(Signal to noise ratio, SNR)、MSE 和结构相似度 (Structural similarity, SSIM) 作为衡量标准, MSE 的定义如式(4)所示, SNR

的定义如下:

$$SNR = 10 \lg \frac{\delta^2(d)}{\delta(d - \hat{d})} \quad (8)$$

SSIM 可以比较 2 个数据在结构上的相似性, 从全局范围评判数据差异, 符合大间距地震数据重建的任务目标, SSIM 的表达式如下:

$$SSIM(d, \hat{d}) = \frac{(2\mu_d \mu_{\hat{d}} + K_1)(2\sigma_{d\hat{d}} + K_2)}{(\mu_d^2 + \mu_{\hat{d}}^2 + K_1)(\sigma_d^2 + \sigma_{\hat{d}}^2 + K_2)} \quad (9)$$

2.2 重建结果分析

在实验过程中根据地震勘探的实际情况, 以连续缺失 30 条地震道的数据作为大间距缺失数据, 该部分数据来源为公开的 Model94 数据集, 部分卷积核尺寸为 3×3, 可视化本方法重建结果如图 5 所示。实验结果中, 图 5a 为原始数据, 尺寸大小为 128×128, 图 5b 为大间距缺失地震数据, 其 SNR 为 14.89 dB, 图 5c 展示了使用循环特征推理网络重建的地震数据, SNR 为 28.15 dB, 图 5d 展示了重建数据与原始数据的残差结果。该实验结果表明, 本方法在对大间距缺失地震数据进行重建时可以达到恢复缺失数据的目的, SNR 在缺失数据的基础上提升了 13.26 dB, 观察图 5d 可以看出重建结果与原图的误差并不明显, 缺失数据能够被精确重建出来, 证明了本方法在重建大间距缺失数据中的有效性。

为了证明循环特征推理的有效性, 在实验中比较了本方法和 U-Net 网络的重建能力, 在对比实验中 U-Net 模型的参数设置与本方法一致。图 6a 和图 6d 分别表示原始数据和缺失数据, 图 6b 为使用 U-Net 网络重建出的地震数据, SNR 为 26.10 dB, 图 6e 为基于 U-Net 网络的重建结果与原始数据的残差结果, 图 6c 为使用循环特征推理网络重建出的地震数据, SNR 为 27.69 dB, 图 6f 为本方法的重建结果与原始数据的残差结果。根据实验结果, 两种方法均能恢复缺失地震道, 但对比残差结果图可以看出, U-Net 网络重建出的地震数据丢失了更多的细节信息, 而本方法的重建结果虽然与原始数

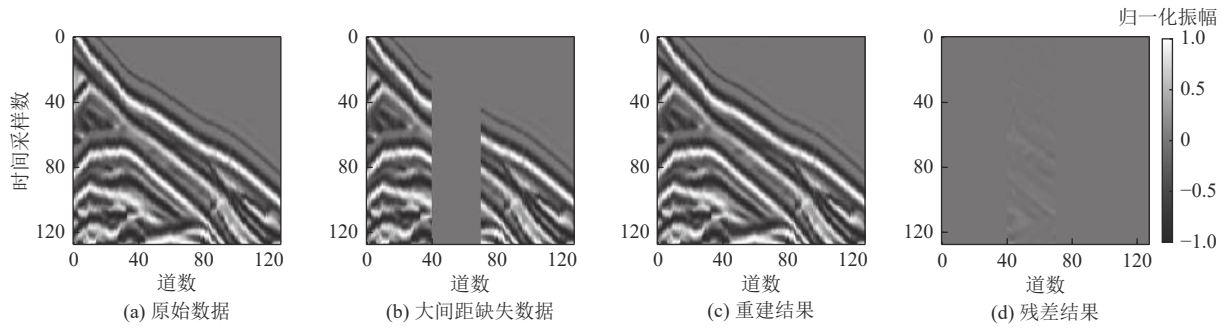


图 5 大间距缺失地震数据重建结果

Fig.5 Reconstruction results of consecutively missing seismic data

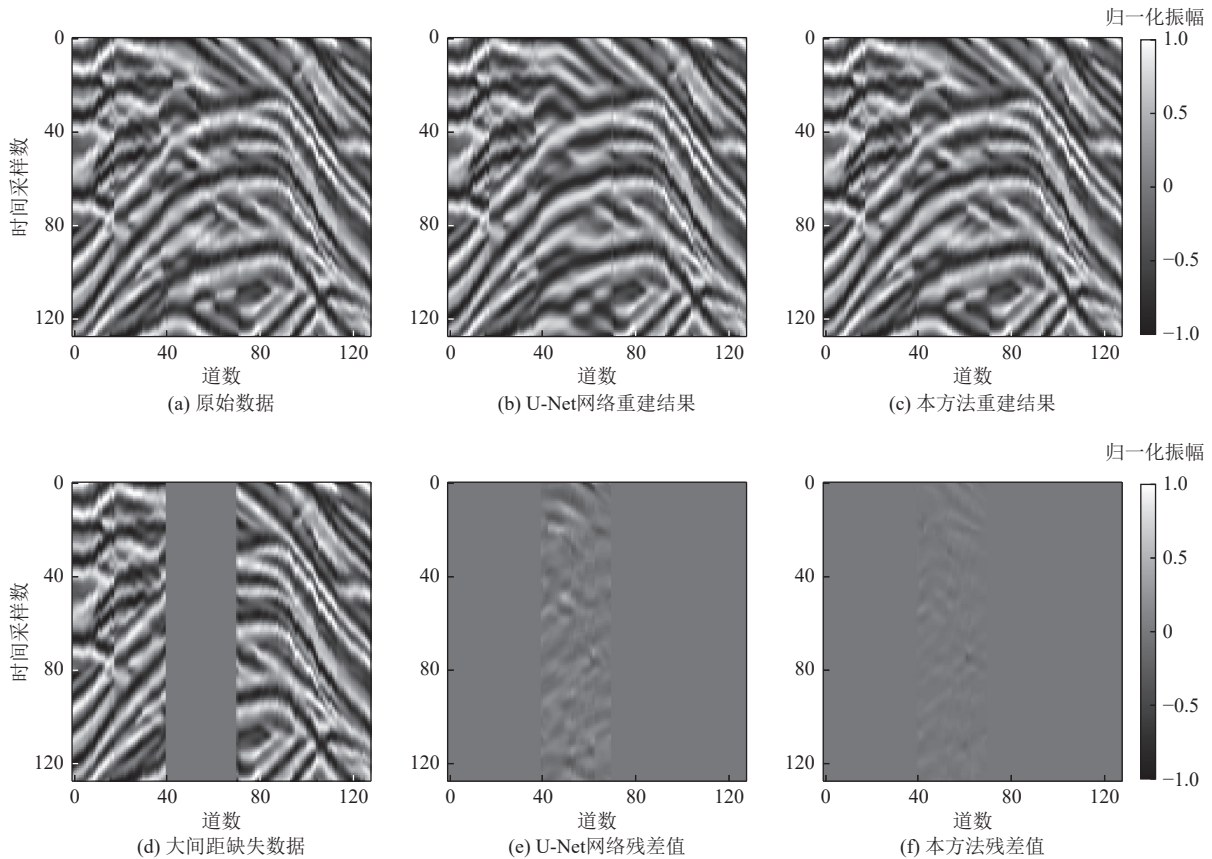


图 6 不同方法重建结果对比

Fig.6 Comparison of reconstruction results based on the U-Net and the proposed methods

据有一定差距,但重建效果明显优于 U-Net 网络,重建数据更加准确,具有更高的信噪比,证明了循环特征推理方法在解决大间距缺失地震数据重建问题上的有效性。

2.3 对比实验分析

为探究不同采样下的重建效率,进一步证明所提出模型对于不同缺失道数数据的重建有效性,针对 128 道地震数据中连续缺失 30 至 80 道的情形进行重建实验,并计算使用本方法与 U-Net 方法下重建结果的定量指标见表 2,可以看出本方法的各项指标均优于 U-Net 重建方法。随着连续缺失道数的增多,重建难度也随之增加,当连续缺失道数达到约 60 道时,重建结果的信噪比提升较弱,表明当数据缺失程度达到或超过这一阈值时,重建任务将面临更加严峻的挑战。

同时从图 7 所示的损失值曲线图可以看出随着训练的进行,本方法能够更快地达到收敛状态,且收敛到

表 2 本方法与 U-Net 网络在不同缺失道数下综合数值
Table 2 Synthetic data derived from the U-Net and the proposed methods under different numbers of missing channels

评价指标	模型	缺失道数					
		30	40	50	60	70	80
SNR/dB	U-Net	27.10	24.08	19.78	18.21	13.17	9.06
	本方法	27.84	25.13	21.22	19.80	15.86	12.49
SSIM	U-Net	0.978 4	0.973 6	0.960 1	0.926 7	0.902 8	0.874 8
	本方法	0.984 5	0.980 4	0.973 5	0.941 9	0.934 6	0.906 0
MSE/10 ⁻⁵	U-Net	4.39	4.62	4.86	5.24	5.76	6.43
	本方法	4.05	4.23	4.59	4.98	5.17	5.93




图 7 不同方法损失值曲线

Fig.7 Loss curves derived from the U-Net and the proposed methods

更低的损失值,证明经过训练本方法的模型能获得更接近原始数据的重建结果。

另外,为了证明本方法对不同地震数据均具有良好的重建效果及泛化能力,使用本方法和 U-Net 网络在 6 种数据集上进行了测试。测试结果如图 8 所示,本方法在不同数据集上重建后的 SNR 分别达到了 28.64 dB、25.79 dB、25.26 dB、18.97 dB、29.62 dB 及 26.19 dB,相比使用 U-Net 网络进行重建,本方法的 SNR 均高于 U-Net 网络,SNR 平均提升了 0.97 dB。可以应对多种地层结构的大间距缺失问题,再次证明了本方法在重建大间距缺失数据方面的良好性能。

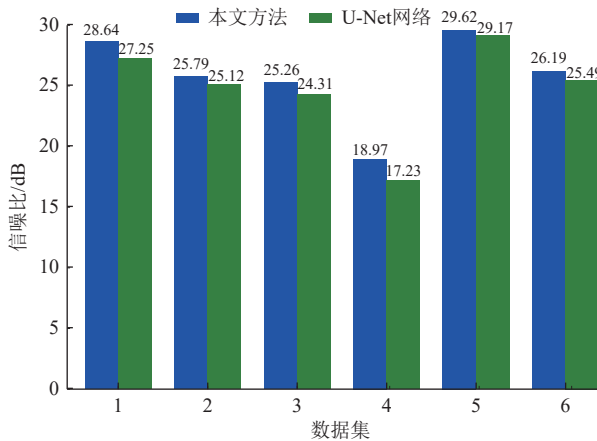


图 8 6 种数据集下不同方法重建结果

Fig.8 Reconstruction results from the U-Net and the proposed methods based on six different datasets

感受野内至少含有一个有效特征图数据是执行部分卷积的条件,为深入探究感受野中有效数据的占比对地震数据重建结果的影响,设置了不同大小的卷积核在相同训练条件下的对比实验。调整卷积核大小为常用的 3×3、5×5 和 7×7 的部分卷积进行区域识别并推理,为了保证有效输入数据的有效性,设置初始有效数据的占比分别为 1/3、1/5 和 1/7,随着迭代的进行,有效数据的占比将越来越大。实验结果如图 9 所示,使用 3×3 的部分卷积核重建出的地震数据结果信噪比为 28.68 dB

高于其他尺寸,而平均迭代时间为 4.58 s 低于其他尺寸,从区域识别的规则可以得出,部分卷积的尺寸不宜设置过大,否则会导致仅一次迭代就完成了对所有缺失数据的填充工作,使部分卷积退化为普通卷积。简单地增大卷积核通常会导致网络参数骤增,增大计算量,从而带来较低的性能和速度,不一定能够获得更好的效果。




图 9 不同部分卷积核尺寸间信噪比与迭代时间对比

Fig.9 SNRs and average iteration time based on partial convolution kernels with different sizes

3 结论

(1) 提出一种基于循环特征推理的方法,有针对性地解决大间距缺失地震数据重建问题。该方法利用缺失区域边缘的有效信息,渐进式地重建缺失部分,将推理出的数据作为新的输入条件参与下一次推理。同时利用改进后的 U-Net 网络结构的高效性,降低训练时长并且提高重建精度。将像素级损失和特征空间级损失函数相结合,使网络能学习到更多的结构信息,有助于重建大间距缺失区域的纹理特征。

(2) 模拟实验结果表明,本方法在保证重建质量的前提下,降低计算复杂性,有效完成大间距缺失地震数据的重建工作,信噪比提升至 28.15 dB。对比 U-Net 网络,本方法重建结果的信噪比明显提高,对细节部分的重建效果更好。增加连续缺失地震道数,本方法在信噪

比、均方误差、结构相似性各指标均由于 U-Net 网络, 当连续缺失道数达到约 60 道时, 两种方法的重建效果均有所降低, 最后在多个数据集的重建实验中验证了本方法的泛化性, 并且当部分卷积核大小为 3×3 时重建结果信噪比更高, 迭代时间更短。

(3) 为应对实际勘探过程中复杂的地震数据处理需求, 在未来工作中聚焦于三维、五维等高级地震数据重建任务, 提升算法的性能, 实现高维大间距缺失地震数据的精准重建, 为后续的地质解释工作提供高质量的数据支持。

符号注释:

b 为卷积操作的偏置值; d 为真实高分辨率地震图像; \hat{d} 为重建后地震图像; \bar{f} 为特征融合结果; f^j 为第 j 次循环的重建数据; \mathbf{J} 为全 1 矩阵; K_1 、 K_2 为保持稳定性的常数, 取 $K_1=0.001$, $K_2=0.009$; \mathbf{M} 为对应区域的标记矩阵; \mathbf{M}^j 为第 j 次循环的标记矩阵; \mathbf{M}^* 为更新后的标记矩阵; i 为当前特征图编号, $i=0, 1, \dots, N$; N 为特征值个数; P 为 d 中元素总个数; C_i 、 H_i 和 W_i 分别为特征图的通道数、高度和宽度; \mathbf{X} 为输入的特征矩阵; r 为特征推理的循环次数; \mathbf{Q} 为卷积核矩阵; Φ_i^* 为第 i 个池化层的 Gram 矩阵; Φ_i 为该池化层输出的特征矩阵; $\hat{\Phi}_i^*$ 为实际数据的 Gram 矩阵; μ 为平均值; δ 为方差; δ_{dd} 为 d 和 \hat{d} 的协方差; \odot 为元素点乘运算; $\|\cdot\|_F$ 为 Frobenius 范数。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

参考文献(References)

- [1] YU Siwei, MA Jianwei. Deep learning for geophysics: Current and future trends[J]. *Reviews of Geophysics*, 2021, 59(3): e2021RG000742.
- [2] WANG Yanghua. Seismic trace interpolation in the f - x - y domain[J]. *Geophysics*, 2002, 67(4): 1232–1239.
- [3] 吴庚, 刘财, 刘殿秘, 等. 连续缺失地震数据的高阶流式预测滤波插值方法[J]. *地球物理学报*, 2023, 66(3): 1220–1231.
WU Geng, LIU Cai, LIU Dianmi, et al. Seismic data interpolation beyond continuous missing data using high-order streaming prediction filter[J]. *Chinese Journal of Geophysics*, 2023, 66(3): 1220–1231.
- [4] CLAERBOUT J, ZHANG Lin. Wave Equation Resampling of Unevenly Spaced Traces[J]. Stanford Exploration Project, 1997, 75(17): 263–271.
- [5] FOMEL S. Seismic reflection data interpolation with differential offset and shot continuation[J]. *Geophysics*, 2003, 68(2): 733–744.
- [6] YANG Yi, MA Jianwei, OSHER S. Seismic data reconstruction via matrix completion[J]. *Inverse Problems & Imaging*, 2013, 7(4): 1379–1392.
- [7] OROPEZA V, SACCHI M. Simultaneous seismic data denoising and reconstruction via multichannel singular spectrum analysis[J]. *Geophysics*, 2011, 76(3): V25–V32.
- [8] 刘保童. 一种基于傅里叶变换的去假频内插方法及应用[J]. *煤田地质与勘探*, 2009, 37(2): 63–67.
LIU Baotong. Dealiasing interpolation based on Fourier transform and its application[J]. *Coal Geology & Exploration*, 2009, 37(2): 63–67.
- [9] KIM B, JEONG S, BYUN J. Trace interpolation for irregularly sampled seismic data using curvelet-transform-based projection onto convex sets algorithm in the frequency–wavenumber domain[J]. *Journal of Applied Geophysics*, 2015, 118: 1–14.
- [10] 李康楠, 吴雅琴, 杜锋, 等. 基于卷积神经网络的岩爆烈度等级预测[J]. *煤田地质与勘探*, 2023, 51(10): 94–103.
LI Kangnan, WU Yaqin, DU Feng, et al. Prediction of rockburst intensity grade based on convolutional neural network[J]. *Coal Geology & Exploration*, 2023, 51(10): 94–103.
- [11] MOUSAVI S M, ELLSWORTH W L, ZHU Weiqiang, et al. Earthquake transformer: an attentive deep-learning model for simultaneous earthquake detection and phase picking[J]. *Nature Communications*, 2020, 11(1): 3952–3963.
- [12] SIAHKOHI A, LOUBOUTIN M, HERRMANN F J. The importance of transfer learning in seismic modeling and imaging[J]. *Geophysics*, 2019, 84(6): A47–A52.
- [13] YU Jiaxu, WU Bangyu. Attention and hybrid loss guided deep learning for consecutively missing seismic data reconstruction[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5902108.
- [14] LI Xinze, WU Bangyu, ZHU Xu, et al. Consecutively missing seismic data interpolation based on coordinate attention unet[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 3005005.
- [15] HE Tao, WU Bangyu, ZHU Xu. Seismic data consecutively missing trace interpolation based on multistage neural network training process[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 7504105.
- [16] CHANG Dekuan, YANG Wuyang, YONG Xueshan, et al. Generative adversarial networks for seismic data interpolation[C]//SEG 2018 Workshop: SEG Maximizing Asset Value Through Artificial Intelligence and Machine Learning, Beijing, China, 17–19 September 2018. Beijing, China. Society of Exploration Geophysicists and the Chinese Geophysical Society, 2018: 40–43.
- [17] LIU Naihao, WU Lukun, WANG Jiale, et al. Seismic data reconstruction via wavelet-based residual deep learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4508213.
- [18] 欧炳霖, 曾同生, 柳天成, 等. 基于 Huber-U-Net 网络的地震数据重建与去噪[J]. *地球物理学进展*, 2023, 38(6): 2540–2552.
OU Binglin, ZENG Tongsheng, LIU Tiancheng, et al. Seismic data reconstruction and de-noising based on Huber-U-Net network[J]. *Progress in Geophysics*, 2023, 38(6): 2540–2552.
- [19] CHAI Xintao, GU Hanming, LI Feng, et al. Deep learning for irregularly and regularly missing data reconstruction[J]. *Scientific Reports*, 2020, 10: 3302.
- [20] LI Jingyuan, WANG Ning, ZHANG Lefei, et al. Recurrent feature reasoning for image inpainting[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA. IEEE, 2020: 7757–7765.
- [21] LIU Guilin, REDA F A, SHIH K J, et al. Image inpainting for irregular holes using partial convolutions[M]//Lecture notes in computer science. Cham: Springer International Publishing, 2018: 89–105.
- [22] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *CoRR*, 2014: 1409–1556.

(责任编辑 郭东琼)