

基于ControlVAE的约束嵌入稠密时变阵列构建

孙文力¹, 原达^{1*}, 姜新波²

(1. 山东工商学院山东高校智能信息处理重点实验室, 山东烟台 264005; 2. 山东大学齐鲁交通学院, 山东济南 250002)

摘要: 在对探地雷达(Ground Penetrating Radar, GPR)数据进行三维建模与可视化分析过程中, 其所依赖的三维时变阵列通常是由一维数据道或二维阵列间接生成的. 由于采集到的数据往往比较稀疏, 且存在不规则偏移, 需要进行稠密处理, 以获得高密度三维时变阵列. 本文提出了一种基于可控变分自编码(Controllable Variational AutoEncoder, ControlVAE)的约束嵌入稠密时变阵列构建方法. 使用基于ControlVAE的时变数据重构网络, 通过隐空间采样插值和深浅层特征信息的融合, 生成接近真实分布的伪道数据来增加阵列密度. 构建了基于尺度不变特征变换的数据配准模块, 提取道间梯度特征与结构对称性特征, 可以在时空域内完成数据配准. 同时将浅层特征作为约束信息嵌入数据重构网络, 以消除数据道偏移对阵列生成的影响. 实验结果表明, 本文方法仅使用单测线二维B-scan数据集即可重建稠密时变阵列, 可以有效降低重构模型累积误差, 提高面对复杂真实数据时的鲁棒性.

关键词: 时变阵列; 数据生成; 探地雷达; 约束嵌入; 可控变分自编码模型

基金项目: 国家自然科学基金(No.62072285); 山东省重点研发计划(No.2019GGX101040)

中图分类号: TP751.1 **文献标识码:** A **文章编号:** 0372-2112(2024)01-0354-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20221144

Construction of Dense Time-Varying Array with Constraint Embedded Based on ControlVAE

SUN Wen-li¹, YUAN Da^{1*}, JIANG Xin-bo²

(1. Key Laboratory of Intelligent Information Processing, Shandong Technology and Business University, Yantai, Shandong 264005, China;
2. School of Qilu Transportation, Shandong University, Jinan, Shandong 250002, China)

Abstract: In the 3D modeling and visualization analysis of ground penetrating radar (GPR) data, the 3D time-varying arrays they rely on are usually generated indirectly from 1D data channels or 2D arrays. Since these data are often sparse and irregularly shifted, dense processing is required to obtain high-density 3D time-varying arrays. This paper proposes a constrained embedding dense time-varying array construction method based on controllable variational autoencoder (ControlVAE). A time-varying data reconstruction network based on the ControlVAE is used to increase the array density by generating pseudo-channel data close to the natural distribution through the fusion of hidden space sampling interpolation and deep and shallow feature information. A data alignment module based on scale-invariant feature transformation is constructed to extract the inter-channel gradient features and structural symmetry features to complete the data alignment in the spatial domain. The shallow features are also embedded as constraint information in the data generation network to eliminate the influence of data channel offset on array generation. The experimental results show that the proposed method can efficiently reconstruct a time-varying array with a single scan direction using a two-dimensional B-scan data set. This method can effectively reduce the cumulative error of the reconstructed model and improve the robustness in the face of complex actual data.

Key words: time-varying array; data generation; ground penetrating radar; constrained embedding; controllable variational autoencoder model

Foundation Item(s): National Natural Science Foundation of China (No.62072285); Shandong Provincial Key Research and Development Program (No.2019GGX101040)

1 引言

探地雷达(Ground Penetrating Radar, GPR)是一种利用电磁波探测地下介质分布,确定其内部结构或形状位置的电磁技术,近年来被广泛应用于地下结构勘测等众多领域^[1].在大范围地质勘测应用中,使用GPR数据构建高密度阵列,形成具有连续物理结构的三维视觉模型,可以提供多观察视角,增强分析的可靠性^[2,3].

探地雷达采集到的数据是依据电磁场散射获得的反射数据,通常有 A-Scan, B-Scan 和 C-Scan 三种形式.在现有的三维地下结构分析应用中,基于二维剖面数据(B-scan)构建高密度时变阵列是主要方法之一^[4].然而,在使用 B-scan 构建三维时变阵列时,如下问题尚未得到解决:

(1)构建三维稠密时变阵列首先需要高质量的时变数据,目前已有方法中,主要策略是从连续 B-scan 阵列的配准和重建开始逐渐增加新的道数据(A-scan)直至重建整个序列^[5].但是,在进行大范围地质勘测时,受地形、测线和勘测状态参数变化的影响,采集到的 B-scan 阵列存在空间数据稀疏问题. B-scan 数据集合的切片间隔不规则,并且切片间数据密度远低于道间数据密度,在构建三维模型的过程中,容易产生痕迹缺失,导致三维模型空间结构变形^[6].为此,需对扫描导线未覆盖的空间区域进行数据生成,提高切片间的数据密度.

(2)B-scan 数据集合的采集并非同步进行,时间零点位置的不同导致时变数据间存在不规则偏移,在时变数据插值重构过程中,重构误差不断累计,导致生成数据质量下降.因此,需要对测得数据进行数据配准,消除数据间的不规则偏移.

基于目前工作存在的问题,本文提出了一种基于可控变分自编码网络的约束嵌入稠密时变阵列构建方法,利用可控变分自编码器隐空间特征连续的特点对隐空间数据采样并插值重构,对数据稀疏区域进行数据插补,提高空间数据密度.通过控制器动态调整损失权重,平衡解码器的生成质量与特征学习能力,直至生成精度逼近真实数据.然后,使用改进的联合位置、尺度、方向的尺度不变特征变化(Position Scale Orientation Scale-Invariant Feature Transform, PSO-SIFT)算法^[7]进行数据配准.在空间域和时间域上对时变数据进行联合配准,通过设计符合 GPR 时变数据结构特征与梯度变化的特征描述符提取约束信息,有效消除了不规则偏移对数据重构的影

响.实验结果表明,本文方法与主流算法相比,具有较高的鲁棒性.生成的稠密时变阵列过渡自然,面对结构复杂、多干扰的真实数据,能有效表征真实地下环境.

2 相关工作

GPR 稠密时变阵列的重建方法,简而言之,即提高空间数据密度,利用道数据间的时空相关性对已有数据序列进行插值,对稀疏阵列进行插补以达到构建稠密阵列的目的.当前,针对时变数据插值算法的主要策略为使用稀疏空间数据两个相邻有效值的移动平均值插补有效数据间隙和利用稀疏空间数据周边数据的时空关联性进行插值.文献[8]使用三次样条插值进行时变数据重构,任意两信息点间用直线或光滑曲线连接.但 GPR 数据是一种波动强烈的非线性时变数据,该方法掩盖了相邻插值点的局部特征变化,因此用于 GPR 时变数据效果并不理想.文献[9]基于时间序列谐波分析(Harmonic ANalysis of Time Series, HANTS)重构时变数据,采用基于谐波分量的最小二乘曲线拟合方法,在时间序列插值中展示了良好的性能.文献[10]使用奇异谱分析(Singular Spectral Analysis, SSA)对数据间隙进行迭代估计,通过交叉验证来优化窗口宽度和 SSA 主模态的数量,以填补稀疏数据间隙.此类算法基于数学模型得到,在应用中具有良好的泛化性能.然而,由于其方法缺乏空间参考信息,对大范围勘测数据进行插值所得结果的全局一致性不高.文献[11]同时利用频谱和空间信息,提出了一种基于稀疏表示的方法来重建时变信号中丢失数据的分析方法.文献[12]使用 DAISY 特征描述符进行数据配准以生成稠密的空间数据,然后在此基础上抽取候选平面集构建稠密时变阵列.此类方法可以参考多个维度的更多信息,但是基于空间信息对大面积缺失数据插值时的时间成本一般较高.此外,道数据在短距离内变化可能很大,导致此类方法无法表征真实数据.

近年来,国内外学者在保持对以往方法研究的同时,将新兴的深度学习技术融入其中,创新地优化了已有模型.最近涌现出了 GRU^[13], LSTM^[13], GAN^[14], VAE^[15]等不同结构的稀疏数据插补深度学习神经网络. GRU(Gate Recurrent Unit)和 LSTM(Long Short-Term Memory)这两种结构神经网络在数据插补应用中,都可以通过不同的阈值保留重要的特征,确保重要的特征在长期传输过程中不会丢失,并且可以从已观测数

据之中学习规律,同时也可从插补数据中进一步学习,提高数据插补精度.但GRU和LSTM亦各自存在局限性,GRU只在长时变数据和小样本集的场景下具有优势;LSTM在面对超出长度限制的序列时,梯度仍然会消失,并且LSTM要求序列数据是严格时间相关的,并不适用于存在时间零点问题的GPR数据.GAN(Generative Adversarial Networks)网络用于学习时变数据的总体分布,从而对稀疏数据的间隙进行数据插补.但由于信息量固定,GAN网络在生成复杂数据如GPR时变数据时,生成的数据在频谱或时频谱上表现较差,存在插补精度不高、模型不稳定等问题.Kingma等^[15]于2014年提出变分自编码器(Variational AutoEncoder, VAE)模型.VAE包括编码器和解码器两部分.编码器将输入数据推断为符合正态分布的变分概率分布;解码器将变分概率分布还原逼近原始数据的近似概率分布,通过将KL散度加入损失函数强制学习连续隐空间分布.因此,变分自编码器的隐空间是连续且有意义的,这为获取特征连续的序列数据提供了非常好的解决思路.不过,VAE在数据生成过程中散度增加,由此导致特征学习能力降低,使输出模糊^[16].Denton等^[17]针对这一问题提出的 β -VAE通过增加散度权重,人为地减少散度使其具有更好的学习能力,相比VAE,该方法

虽然通过控制系统调整了散度,但代价是有较高的重构误差.在 β -VAE的基础上,Shao等^[18]提出了可控变分自编码器(Controllable Variational AutoEncoder, ControlVAE),通过引入非线性比例积分导数控制器以自适应超参数 β ,使重构数据和隐空间向量之间的互信息最大化,实现了重构误差和KL散度权重分配的平衡.但是,作为一种无监督学习方法,使用ControlVAE生成时变序列时,无法捕捉输入序列的匹配关系,实现对稀疏数据的准确插值.

针对以上问题,本文设计了一种基于可控变分自编码器的约束嵌入时变数据生成模型.相比其他方法,该模型能更好地平衡重构误差和KL散度的权重分配,提高网络模型学习特征的能力和重建隐空间数据的质量,利用约束信息消除不规则偏移,最终生成稠密时变阵列.

3 GPR稠密时变阵列数据场重构算法

本文提出的基于ControlVAE的GPR时变数据生成网络模型如图1所示,它通过动态调整生成网络损失来提高解码器生成时变数据的质量,利用ControlVAE隐空间特征连续的特点对隐空间数据采样并插值重构.使用数据配准生成包含浅层约束信息的特征描述符,将约束信息嵌入隐变量用于消除时变数据间的不规则偏移.

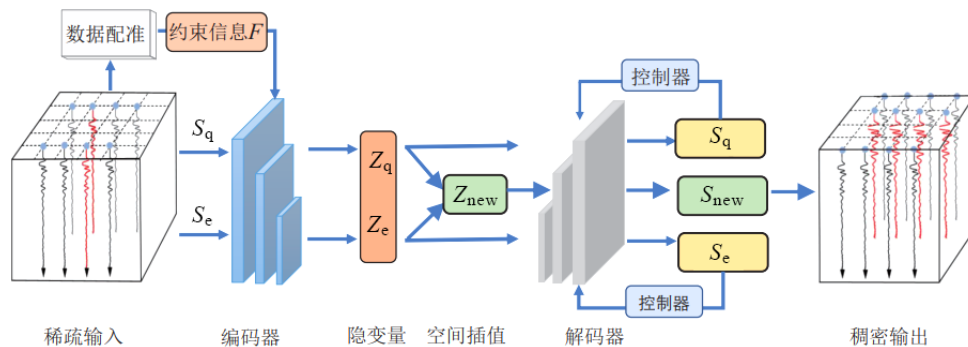


图1 基于可控变分自编码器的GPR时变数据生成网络模型

3.1 基于区域联合特征约束的时变数据配准

GPR的成像原理是向地下发射探测电磁脉冲并接受对应具有时变特点的回波信号^[19].从时变阵列分析的角度,将由多道平行时变信号排列构成的C-scan视为三维时变阵列,如图2所示.当探测脉冲遇到目标物体时回波发生明显变化,在B-scan数据中反映为双曲波.由于采集GPR数据时,受时间零点、测量环境等因素影响,B-scan中双曲波发生不规则偏移,同一目标物体表现不同双曲波结构.因此,需对B-scan中的道数据进行配准,减少重建产生的累计误差.原始B-scan数据可表示为

$$\text{B-scan} = X(i, j) \quad (1)$$

其中, $i = 1, 2, 3, \dots, n; j = 1, 2, 3, \dots, m$. 将其按照位移方向

进行分块,得到的一维A-scan数据为

$$\begin{aligned} W_j &= X_j[1, 2, \dots, n] \\ &= \{W_j(1), W_j(2), W_j(3), \dots, W_j(n)\} \end{aligned} \quad (2)$$




图2 GPR时变阵列空间构成

由于 GPR 数据在空间域和时间域都具有复杂的相关性,因此本文从两方面对 A-scan 道数据进行配准^[20,21]. 在空间域上,由于数据采集通常需要设计多条平行测线,很难确定各测线的起始位置,因此需要在水平空间位置上对连续 B-scan 数据进行数据拼接. 由于阵列天线的相对位置不发生变化,B-scan 数据的剖面起始位置始终相等,可以通过计算相邻 B-scan 数据梯度方向与梯度幅度作为配准依据,将连续 B-scan 数据内对应道数据依次对齐. 将 $W_j(i)$ 的梯度方向和梯度幅度定义为

$$R = \arctan\left(\frac{G_y}{G_x}\right) \quad (3)$$

$$G = \sqrt{(G_x)^2 + (G_y)^2} \quad (4)$$

$$G_x = ([W_{j+1}(i-1) + 2W_{j+1}(i) + W_{j+1}(i+1)] - [W_{j-1}(i-1) + 2W_{j-1}(i) + W_{j-1}(i+1)]) \quad (5)$$

$$G_y = ([W_{j-1}(i-1) + 2W_j(i-1) + W_{j+1}(i-1)] - [W_{j-1}(i+1) + 2W_j(i+1) + W_{j+1}(i+1)]) \quad (6)$$

其中, G_x 表示 $X_j(i)$ 水平导数; G_y 表示垂直导数.

经典的 SIFT 算法使用特征之间的相关性来确定最佳配准关系,但当 SIFT 直接用于道数据配准时,由于回波信号强度映射的显著差异,正确对应的数量不足以确认匹配精度. 因此,本文结合改进的 PSO-SIFT 算法^[21]区域划分思想,充分利用 B-scan 阵列内道数据间结构特征及梯度变化,设计回型特征描述符如图 3 所示,改进后的特征描述符包含更多邻域信息. 由于 B-scan 数据中目标区域表现为双曲波结构,具有结构对称性,相对于原始 SIFT 算法,区域划分思想对道数据的不规则偏移现象具有更好的优势,添加的邻域信息使描述符更加稳定. 使用 9×9 的正方形邻域作为数据梯度统计范围,分别计算每一点的梯度方向和梯度幅度累加值,依次得到维度为 $9 \times 8 = 72$ 维的特征向量. 最后经过多次特征匹配完成配准,配准效果如图 4 所示,清晰体现了 B-scan 阵列内道数据的对应关系.

在时间域上,由于阵列天线收发距相等且不会发




图 3 回型特征描述符




图 4 空间域配准结果

生变化,因此理想情况下连续 A-scan 数据的起跳点应完全一致. 依次计算 B-scan 阵列中参考道与配准道的相关系数 C , 设参考道数据为 W_r , 配准道数据为 W_c , 可将 C 表示为

$$C[W_c, W_r] = \frac{\sum(W_c - \bar{W}_c)(W_r - \bar{W}_r)}{\sqrt{\sum(W_c - \bar{W}_c)^2 \cdot \sum(W_r - \bar{W}_r)^2}} \quad (7)$$

匹配结果如图 5 所示,将系数最大值对应的两道 A-scan 数据视为最近似道,作为后续数据生成模型的输入进行采样,进而经插值计算生成伪道数据.




图 5 时间域配准结果

在连续 B-scan 中分别提取得到两个配准道集合 $W = (W_1, W_2, \dots, W_N)$ 和 $W' = (W'_1, W'_2, \dots, W'_N)$. 配准道 W 和 W' 在对应 B-scan 数据中的位置、幅度和主方向用 $(x, y), \sigma, \theta$ 和 $(x', y'), \sigma', \theta'$ 分别表示. 在后续内容中,我们将提取到特征点对之间的位置、幅度和主方向三类信息保留作为数据重构模型中的附加特征信息 F , 在循环迭代过程中作为浅层特征约束与从 ControlVAE 中提取的深层特征信息拼接为隐向量 Z . 拼接后的隐向量不仅拥有更高级抽象的隐空间特征,同时具备空间位置、幅度和主方向等浅层特性,在解码器重构数据时可有效消除数据间不规则偏移,提高重建阵列场精度.

3.2 基于 ControlVAE 的时变数据生成模型

本文提出基于 ControlVAE 的约束嵌入稠密时变阵列构建方法. ControlVAE 共训练两次. 第一次为训练解码器逼近真实数据的后验分布, 生成高质量的重构数据. 第二次将隐空间采样插值的隐向量映射回道数据, 提高空间数据密度. 其中隐向量嵌入了约束信息, 削弱了不规则偏移现象.

3.2.1 可控变分自编码器

针对 VAE 无法平衡重建损失和 KL 散度的问题, 本文引入可控变分自编码器 (ControlVAE)^[22], 其通过动态调整 KL 散度的权重来稳定 KL 散度的值. 受控制系统启发, ControlVAE 使用反馈控制思想对每个训练步骤的 KL 散度进行采样, 通过迭代算法相应的调整超参数 $\beta(t)$, 使 KL 散度稳定在期望值.

在模型训练时, 对训练步骤 t 输出的 KL 散度进行采样, 用 $V'_{\text{KL}}(t)$ 表示. 求采样的 KL 散度与设定的期望 V_{KL} 的差值 $e(t)$, 如下式:

$$e(t) = V_{\text{KL}} - V'_{\text{KL}}(t) \quad (8)$$

将 $e(t)$ 作为反馈来计算超参数 $\beta(t)$, 此时 ControlVAE 的变分下界函数为

$$L_{\text{ConVAE}} = E_{Q(z|x)}[\log P_{\theta}(x|z)] - \beta(t) \text{KL}(Q_{\Phi}(z|x) \| P_{\theta}(z)) \quad (9)$$

其中超参数 $\beta(t)$ 定义为

$$\beta(t) = \frac{K_p}{1 + \exp(e(t))} - K_i \sum_{j=0}^t e(j) + \beta_{\min} \quad (10)$$

K_p 和 K_i 是由先验知识设置的常数. 当 KL 散度下降到期望值以下时, 控制器通过减小超参数 $\beta(t)$ 即减小变分下界函数中对 KL 散度的惩罚来减缓 KL 散度的下降. 同时, 减小的超参数 $\beta(t)$ 会使变分下界函数增加从而使 KL 散度增加, 直至超越期望值. 于此同理, 当 KL 散度超越期望值时, 控制器通过增大超参数 $\beta(t)$ 即增加变分下界函数中对 KL 散度的惩罚使其减小.

超参数 $\beta(t)$ 的计算流程如图 6 所示. $\beta(t)$ 的第一项根据差值 $e(t)$ 的值动态影响 $\beta(t)$ 的值, 促使 KL 散度向有利的方向动态增减. $\beta(t)$ 的第二项对训练采样产生的累计差值求和, 产生一个逐渐增强的矫正直到差值符号改变. 这就保证了 $\beta(t)$ 逐渐向有利于 KL 散度接近期望值的方向变化.

3.2.2 约束嵌入隐向量构建

对于 GPR 伪道数据生成而言, 输入解码器的隐向量中包含的特征信息若足够多, 则不仅能够有效保留原始数据中的结构信息, 而且能够尽可能地削弱数据间的不规则偏移现象. 因此, 本文设计了一种约束嵌入的 ControlVAE 对 A-scan 道数据进行特征提取与约束重构, 构建包含多重特征信息的隐向量.




图6 控制器动态反馈计算流程

在特征提取这项工作中, ControlVAE 的卷积层与池化层会对输入的道数据进行卷积和二次采样, 将数据压缩为低维向量 S , 对第二节中提取的配准道集合对应的位置 (x, y) 、幅度 σ 和主方向 θ 做归一化处理, 令 $F = ((x, y), \sigma, \theta)$ 作为约束条件向量同步输入. 将压缩后的低维向量 S 与条件向量输入编码器, 对其做多元高斯分布处理, 将输入向量分解为符合多元高斯分布的均值向量 μ 和标准差向量 λ , 使用重参数化技巧, 标准差乘以一个符合标准正态分布的随机噪声 e_1 , 再加均值得到重构参数的正态分布 h . 最后从重构参数中采样并与条件向量拼接, 得到同时包含浅层信息与深层特征的隐向量 Z , 如图 7 所示. 隐向量符合正态分布, 由输入数据与条件向量联合分布采样生成.




图7 输入数据与条件向量处理过程

实质上, 本文可控变分自编码器通过一个可学习分布 $P = (Z|F, S)$, 将数据集样本映射到一个具有约束特征的潜在向量, 相当于求解输入符合条件向量的隐数据的概率分布, 概率函数 E_{μ, σ^2} 可表示为

$$E_{\mu, \sigma^2} = \frac{1}{2} \sum_{i=1}^d [(\mu_{(i)} - \mu_{(i)}^F)^2 + \sigma_{(i)}^2 - \log \sigma_{(i)}^2 - 1] \quad (11)$$

其中, $\mu_{(i)}$ 代表一般正态分布的均值, $\mu_{(i)}^F$ 代表对应条件向量 F 的均值, $\sigma_{(i)}^2$ 代表方差向量的第 i 个分量, d 代表隐变量的维度.

最后, 解码器将混合参数的隐向量作为输入, 在训练过程中逼近原始数据的真实后验分布, 直至生成精度较高的重构数据 S_{new} .

3.3 连续隐空间插值

训练过程中, 编码器每次输入两道连续 A-scan, 产生两个对应隐向量并投影到一个与约束近似的隐变量空间中. 解码器每次输入一个隐向量并产生一个重构道数据. 训练完成后, 解码器能够尽可能将隐特征空间中的特征映射回重构的 A-scan 道数据. 之后, 我们使用

上述 ControlVAE 进行采样,相当于把两道数据的基本单元打散,编码器将这些元素在隐空间中一个先验分布区域的点与输入之间建立一个映射,这个映射是通过解码器重建损失以及在隐变量重参数约束下实现的.通过在两道输入数据对应隐空间中的向量之间插值采样形成新的时变序列合成向量 \mathbf{Z}_{new} ,后经解码器重建生成空间区域内的伪道数据 S_{new} .插值过程如图 8 所示,同时向编码器输入 S_q 和 S_c ,会产生两个隐向量 \mathbf{Z}_q 和 \mathbf{Z}_c .由于隐特征空间具有连续性,因此在隐特征空间中插值是合理的^[23].解码器重构产生的道数据 S_{new} 及其对应的隐特征向量 \mathbf{Z}_{new} 由以下方程推导:

$$\mathbf{Z}_{\text{new}} = \mathbf{Z}_q + \text{rand}(0, 1) \cdot (\mathbf{Z}_c - \mathbf{Z}_q) \quad (12)$$

$$S_{\text{new}} = \text{decoder}(\mathbf{Z}_{\text{new}}) \quad (13)$$

对其选取的所有配准道集合进行隐空间插值重构后,就得到了完整的隐空间稠密时变阵列.




图8 隐空间插值重构流程图

4 实验结果与分析

4.1 实验数据集

本文实验使用了3组 GPR 模拟数据和7组探测地下埋藏管线获得的真实数据对所提方法进行验证分析.其中7组真实数据的扫描间隙为1 m;3组模拟数据由 GPRMAX 仿真得到,数据间隙为0.5 m.这些 B-scan 切片组成10组样本数据集,用来训练基于 ControlVAE 的时变数据生成网络.在进行网络训练时为减少冗余特征和缩短运算时间,将原始数据统一裁剪为512像素×512像素.

4.2 实验细节及评价指标

实验的硬件平台为 Intel (R) Core (TM) i7-10700 CPU @ 2.90 GHz 内存 32 GB RAM, 图像处理采用 NVIDIA GTX2070. 软件环境为 Windows 10 操作系统.训练时,将 K_p 和 K_i 分别设置为 0.01 和 0.001, 依次输入一对序列 B-scan 数据进行训练,通过验证损失函数的变化情况和人工观察生成图像的效果来调整网络的结构和参数,损失函数的值越低,证明生成数据与真实数据的差距越小,直至生成质量较好的时变数据.

实验采用互信息 (Mutual Information, MI)、结构相似度 (Structural SIMilarity index, SSIM)、均方根误差 (Root Mean Square Error, RMSE) 对生成的序列时变数

据进行质量评价.其中 RMSE 衡量生成图像与原始数据之间的误差;MI 显示生成数据中包含的原始数据信息量;SSIM 反映了结构信息相似度,其将 B-scan 定义为具有独立结构信息的,由亮度、对比度和结构三个因素组成的数据.用均值作为亮度的估计,标准差作为对比度的估计,协方差作为结构相似程度的度量.各评价指标定义如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left((x'_i - x''_i)^2 + (y'_i - y''_i)^2 \right)} \quad (14)$$

其中, (x''_i, y''_i) 表示 (x'_i, y'_i) 的变换坐标的元素值, n 代表输入数据中的元素总数.

$$H(X_1, X_2) = - \sum_{x,y} p_{X_1, X_2}(x, y) \log p_{X_1, X_2}(x, y) \quad (15)$$

$$\text{MI}(X_1, X_2) = H(X_1) + H(X_2) - H(X_1, X_2) \quad (16)$$

其中, $H(X_1, X_2)$ 表示输入序列 B-scan 的联合信息熵.

$$\text{SSIM}(X_1, X_2) = \frac{(2\mu_{X_1}\mu_{X_2} + c_1)(2\sigma_{X_1, X_2} + c_2)}{(\mu_{X_1}^2 + \mu_{X_2}^2 + c_1)(\sigma_{X_1}^2 + \sigma_{X_2}^2 + c_2)} \quad (17)$$

其中, μ_{X_1} 是 X_1 的平均值, μ_{X_2} 是 X_2 的平均值, $\sigma_{X_1}^2$ 是 X_1 的方差, $\sigma_{X_2}^2$ 是 X_2 的方差, σ_{X_1, X_2} 是 X_1 和 X_2 的协方差. $c_1 = (k_1 L)^2$, $c_2 = (k_2 L)^2$ 是用来稳定的常数,其中 L 是元素值的动态范围,而 $k_1 = 0.01$, $k_2 = 0.03$. 结构相似性的范围是 0 到 1, 当两道数据一模一样时, SSIM 的值等于 1.

4.3 GPR 时变数据生成与量化分析

为了验证本文模型的有效性,分别使用双三次样条插值、HANTS 插值^[24]、GAN 网络插值^[25]、VAE 插值法^[26]对真实 GPR 管线时变数据集进行数据插值,将生成结果归一化至 0~255 的像素空间,并提取各方法生成结果相同区域 1 和 2 的局部阵列进行放大比较,结果如图 9 所示.

原始数据区域 1 中有一双曲波结构,与高频杂波存在部分重叠.由图 9 第 2 行可知,双三次插值中高频杂波仍然排列紧密,遮挡了双曲波顶部部分结构信息. HANTS 插值中底部杂波没有去除干净,遮挡了部分双曲波. VAE 插值中双曲波结构被明显削弱,结构信息没有得到完好保留. GAN 插值和本文方法中,双曲波结构得到清晰表征,特征信息被很好地保留.但本文方法对高频杂波具有更好的抑制作用,大部分高频杂波被去除.

原始数据区域 2 中存在一明显双曲波结构,且存在不规则偏移.由图 9 第三行可知,双三次插值中,双曲波结构中不规则偏移问题更加严重,已无法明显分辨双曲波. HANTS 插值和 VAE 插值中,数据间不规则偏移问题得到缓解,但双曲波结构被明显削弱. GAN 插值和本文方法较好地保留了双曲波结构特征,不同深度层状边界明显,不规则偏移现象减弱.但如图 10 所示, GAN 插值新增了明显的不规则偏移,说明 GAN 模型

并不稳定.

以上实验结果证明,使用本文方法可获得序列时变阵列的隐空间数据,且能够清晰表征双曲波特征,抑制数据间不规则偏移现象,提高空间数据密度.这验证了本文方法的有效性和鲁棒性.

对真实数据集和模拟数据集使用不同插值方法生成稠密时变阵列,并从中抽取切片与原始稀疏阵列同一位置的真实切片进行量化分析,分别计算归一化后像素空间内各结果 MI, RMSE 和 SSIM 的平均值,结果如表 1、表 2 所示. MI 值越高说明生成阵列所含信息连续性越强, RMSE 值越低说明生成阵列与原始阵列之间的误差越小, SSIM 值越大说明生成阵列与原始阵列之间的结构关系越相似. 由表 1、表 2 可知使用本文方法生成的时变阵列在互信息、均方差、结构相似性等方面均优于其他 4 种方法. 在真实数据集实验评价指标数值方面,与双三次插值相比,本文方法所得的 RMSE 降低了 60%, SSIM 提高了 48%. 与 HANTS 插值法相比,本文方法所得 RMSE 降低了 54%, SSIM 提高了 28%. 说明了约束嵌入数据生成模型能够有效减弱不规则偏移. 与 GAN 插值相比,本文方法所得 SSIM 提升了 4%, RMSE 降低了 29%. 与 VAE 插值相比,本文方法所得 SSIM 提升了 14%, RMSE 降低了 38%. 这说明了控制器动态调整损失权重对生成质量和学习能力的重要性. 三项指标说明本文方法生成的重构数据质量较高,在信息相关性、结构连续性方面优于其他方法.

4.4 三维重建实验

4.4.1 稠密时变阵列构建

采用上文基于 ControlVAE 的数据生成方法对真实数据集进行稠密时变阵列构建,于稀疏时变阵列空间

区域进行数据插补. 通过对隐空间内两点之间的特征向量插值,控制生成数据向不同采样源之间倾斜. 如图 11 所示,为了更直观体现本文方法对提高数据密度的有效性,重建过程将稀疏数据集中的每两幅序列 B-scan 数据所含共 1 024 道数据扩展为 5 120 道数据,即每两幅 B-scan 数据中插补八幅由伪道数据构成的 B-scan 剖面,得到类似 C-scan 的三维稠密时变阵列.

经过重建后的时变阵列空间数据密度得到提升. 从原始稀疏阵列及重建后的稠密时变阵列中选取片段通过光流成像处理算法^[27]进行三维可视化分析,其三维重建结果及剖面展示如图 12、图 13 所示.

对比图 12(b) 和图 13(b) 可知,原始稀疏时变阵列构建的三维模型特征连续性较差,双曲波结构特征会随着测线行进缺失. 而通过本文方法重建得到的稠密时变阵列经三维可视化所得三维模型背景清晰,保留了双曲波结构特征和明显的层位结构信息,提高了三维模型中双曲波结构的特征连续性.

4.4.2 约束嵌入有效性实验

为验证嵌入 ControlVAE 模型的约束信息是否有助于消除数据间不规则偏移,将不经过约束嵌入处理,直接使用 ControlVAE 生成的稠密阵列和经本文方法生成的稠密时变阵列进行三维可视化对比,对比结果如图 14 所示. 由图 14(a) 可以看出,未嵌入约束的双曲波部分存在大量结构重叠,在重建过程中误差逐渐累计导致三维模型无法准确反映地下目标物体的真实分布及结构走向. 而图 14(b) 显示,经约束嵌入重建的稠密时变阵列三维结构模型,层位背景清晰,双曲波结构连续性强.

将双曲波波峰进行标定作为对齐点进行直观可视

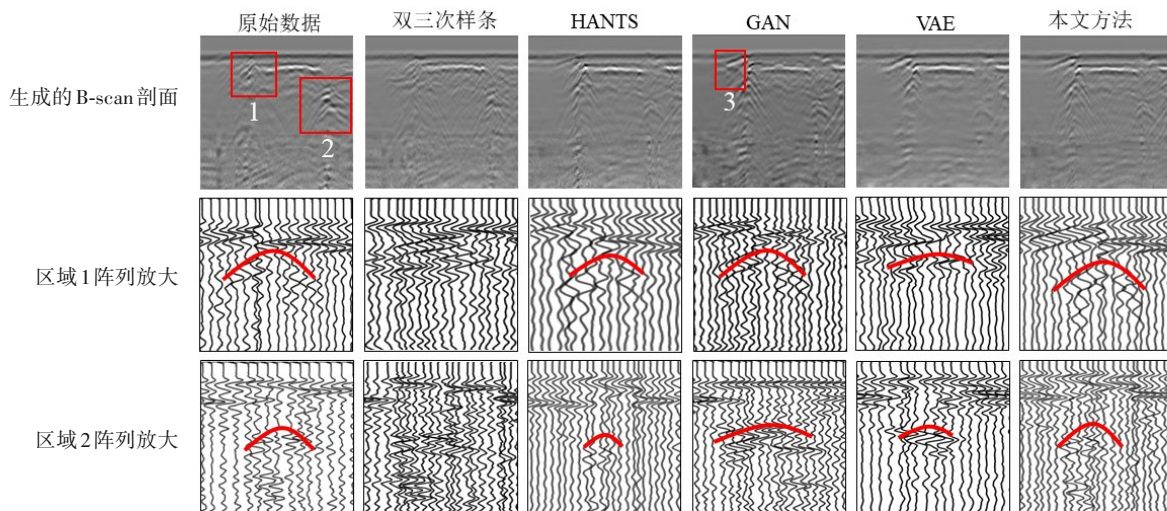


图9 不同插值方法生成结果对比





图10 区域3经GAN插值前后放大对比

表1 不同算法在重建真实数据集上的客观评价指标

插值方法	MI	RMSE	SSIM
双三次插值	0.38	0.14	0.49
HANTS插值	0.52	0.11	0.57
GAN插值	0.59	0.07	0.70
VAE插值	0.63	0.09	0.64
本文方法	0.86	0.05	0.73


表2 不同算法在重建模拟数据集上的客观评价指标

插值方法	MI	RMSE	SSIM
双三次插值	0.81	0.14	0.73
HANTS插值	0.87	0.13	0.78
GAN插值	0.88	0.15	0.81
VAE插值	0.92	0.11	0.82
本文方法	0.93	0.08	0.85



(a) 稀疏阵列空间构成 (b) 稠密阵列空间构成


图11 GPR稠密时变阵列重构结果



(a) 三维结构模型 (b) 双曲波区域放大展示


图12 原始稀疏时变阵列三维重建结果及剖面展示

化,结果如图15所示.由图15可知,约束嵌入前,数据间不规则偏移导致波峰位置不真实,甚至出现缺失现象.而本文采用的约束嵌入算法能够准确地检测到双曲波特征区域并配准,约束信息的嵌入有效消除了数



(a) 三维结构模型 (b) 双曲波区域放大展示


图13 稠密时变阵列三维重建结果及剖面展示



(a) 未嵌入约束 (b) 嵌入约束

图14 约束嵌入消融实验三维重建结果

据间的不规则偏移,降低了重构产生的累计误差,使重建后的三维模型具有较好的结构连续性,能更好地表征目标物体的分布与走向.



(a) 约束嵌入后 (b) 约束嵌入前

图15 双曲波峰标定可视化结果

以上实验结果表明,在稠密时变阵列的构建中,通过数据配准获取的约束嵌入可以有效减少数据间不规则偏移对数据重构的影响,而基于ControlVAE的时变数据生成网络可以提高空间数据密度,构建的稠密时变阵列误差小、精度高,有效表征了地下结构的真实分布情况.

5 结论

本文提出了一种基于可控变分自编码器的稠密时


变阵列构建方法,旨在解决稠密时变阵列构建过程中存在的空间数据密度低、数据不规则偏移问题.该方法采用区域划分与多域联合思想对道数据进行配准并生成特征描述符,约束嵌入数据重构算法,有效消除数据不规则偏移导致的累计误差.动态调整 ControlVAE 的损失函数,实现重建误差与 KL 散度权重分配的平衡,提高生成数据质量.于隐空间中采样并插值重构,融合多层次特征信息生成特征连续的重构数据.实验表明,本文方法所构建稠密时变阵列具有更高的空间数据密度与特征连续性,应用于真实数据时具有较高鲁棒性.

参考文献

- [1] WAI-LOK LAI W, DÉROBERT X, ANNAN P. A review of ground penetrating radar application in civil engineering: A 30-year journey from locating and testing to imaging and diagnosis[J]. *NDT & E International*, 2018, 96: 58-78.
- [2] 郝彤, 赵杰. 面向双曲线形态的探地雷达图像识别技术综述[J]. *电子学报*, 2019, 47(6): 1366-1372.
HAO T, ZHAO J. A brief review of the hyperbola signature recognition techniques for ground penetrating radar[J]. *Acta Electronica Sinica*, 2019, 47(6): 1366-1372. (in Chinese)
- [3] WANG L X, YIN Y S, WANG H, et al. A method of reconstructing 3D model from 2D geological cross-section based on self-adaptive spatial sampling: A case study of cretaceous McMurray reservoirs in a block of Canada[J]. *Petroleum Exploration and Development*, 2021, 48(2): 407-420.
- [4] DINH K, GUCUNSKI N, TRAN K, et al. Full-resolution 3D imaging for concrete structures with dual-polarization GPR[J]. *Automation in Construction*, 2021, 125: 103652.
- [5] GHOSHAL S, BANU S, CHAKRABARTI A, et al. 3D reconstruction of spine image from 2D MRI slices along one axis[J]. *IET Image Processing*, 2020, 14(12): 2746-2755.
- [6] YAMAGUCHI T, MIZUTANI T, NAGAYAMA T. Mapping subsurface utility pipes by 3-D convolutional neural network and Kirchhoff migration using GPR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(8): 6525-6536.
- [7] MA W P, WEN Z L, WU Y, et al. Remote sensing image registration with modified SIFT and enhanced feature matching[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(1): 3-7.
- [8] BERTOLAZZI E, FREGO M, BIRAL F. Point data reconstruction and smoothing using cubic splines and clusterization[J]. *Mathematics and Computers in Simulation*, 2020, 176: 36-56.
- [9] ZHOU J E, JIA L, MENENTI M. Reconstruction of global MODIS NDVI time series: Performance of Harmonic ANalysis of Time Series (HANTS)[J]. *Remote Sensing of Environment*, 2015, 163: 217-228.
- [10] LARI H H, NAGHIZADEH M, SACCHI M D, et al. Adaptive singular spectrum analysis for seismic denoising and interpolation[J]. *Geophysics*, 2019, 84(2): V133-V142.
- [11] LI X H, SHEN H F, ZHANG L P, et al. Sparse-based reconstruction of missing information in remote sensing images from spectral/temporal complementary information [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 106: 1-15.
- [12] VERLEYSSEN C, DE VLEESCHOUWER C. Piecewise-planar 3D approximation from wide-baseline stereo[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 3327-3336.
- [13] YANG S D, YU X Y, ZHOU Y. LSTM and GRU neural network performance comparison study: Taking yelp review dataset as an example[C]//2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAL). Piscataway: IEEE, 2020: 98-101.
- [14] ZHANG H, GOODFELLOW I, METAXAS D, et al. Self-attention generative adversarial networks[EB/OL]. (2019-06-14) [2022-10-08]. <https://arxiv.org/abs/1805.08318>.
- [15] KINGMA D P, WELING M. Auto-encoding variational Bayes[EB/OL]. (2013-12-20) [2022-10-08]. <https://arxiv.org/abs/1312.6114>.
- [16] CRISTOVAO P, NAKADA H, TANIMURA Y, et al. Generating in-between images through learned latent space representation using variational autoencoders[J]. *IEEE Access*, 2020, 8: 149456-149467.
- [17] DENTON E, BIRODKAR V. Unsupervised learning of disentangled representations from video[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 4417-4426.
- [18] SHAO H J, YAO S C, SUN D C, et al. ControlVAE: Controllable variational autoencoder[EB/OL]. (2020-04-13) [2022-10-08]. <https://arxiv.org/abs/2004.05988>.

- [19] COMITE D, AHMAD F, AMIN M G, et al. Forward-looking ground-penetrating radar: Subsurface target imaging and detection: A review[J]. IEEE Geoscience and Remote Sensing Magazine, 2021, 9(4): 173-190.
- [20] HOU S W, SUN W F, GUO B L, et al. RFSDAF: A new spatiotemporal fusion method robust to registration errors [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-18.
- [21] WANG L G, WANG X Y, WANG Q M, et al. Investigating the influence of registration errors on the patch-based spatio-temporal fusion method[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 6291-6307.
- [22] SHAO H J, XIAO Z S, YAO S C, et al. ControlVAE: Tuning, analytical properties, and performance analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(12): 9285-9297.
- [23] YANG X Y, ZHANG X L, ZHANG Z G, et al. DT-WSSSE: Data augmentation with a Siamese encoder for time series[C]//Asia-Pacific Web (APWeb) and Web-Age Information Management (WAIM) Joint International Conference on Web and Big Data. Cham: Springer, 2021: 435-449.
- [24] LI S, XU L, JING Y H, et al. High-quality vegetation index product generation: A review of NDVI time series reconstruction techniques[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 105: 102640.
- [25] MIRZA M, OSINDERO S. Conditional generative adversarial nets[EB/OL]. (2014-11-06)[2022-10-08]. <https://arxiv.org/abs/1411.1784>.
- [26] HARFORD S, KARIM F, DARABI H. Generating adversarial samples on multivariate time series using variational autoencoders[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(9): 1523-1538.
- [27] ZHANG G, HUANG T C, GUERRERO T, et al. Use of three-dimensional (3D) optical flow method in mapping 3D anatomic structure and tumor contours across four-dimensional computed tomography data[J]. Journal of Applied Clinical Medical Physics, 2008, 9(1): 59-69.

作者简介



孙文力 男, 1998年4月生, 山东烟台人。现为山东工商学院信息与工程技术学院硕士研究生。主要研究方向为探地雷达数据处理与应用、深度学习。
E-mail: swlswenli@163.com



原 达 男, 1968年10月生, 辽宁建昌人。现为山东高校智能信息处理重点实验室(山东工商学院)主任, 教授。主要研究方向为探地雷达、可视化处理。
E-mail: ydccec@126.com



姜新波 男, 1987年2月生, 山东烟台人。现为山东大学齐鲁交通学院助理研究员、硕士生导师。主要研究方向为计算机视觉、人工智能。
E-mail: xinbojiang@sdu.edu.cn