

基于条件生成对抗网络的不确定性空间信息重建

屠红艳¹ 陈 钰^{2*}
TU Hongyan CHEN Yu

摘 要

目前用于不确定性空间信息重建的方法例如多点地质统计法,需要多次对训练图像(TI)进行扫描,再通过复杂的概率计算获得模拟结果,导致其效率较低。针对这一问题,文章提出了一种基于条件生成对抗网络(CGAN)的不确定性空间信息重建方法。条件数据作为已知的信息对不确定性空间信息重建具有非常重要的引导意义,CGAN方法将随机噪声与条件数据一起输入生成器中,条件数据用于指导空间信息的生成过程,而判别器用于判断生成器的重建数据与训练样本是否为同一数据。相较于传统方法,CGAN方法在训练完成后,学习到的特征能够以参数的形式存储在硬盘中,当需要进行同种空间信息重建时就可以重复利用,而不必每次重新扫描训练样本,因此具有明显的速度优势。对重建结果与训练样本进行孔隙度、变差函数、多点连通曲线和孔隙分布的对比分析工作,实验证明了CGAN方法在条件数据的指导下能较好地再输出结果中再现TI的结构特征,同时效率与传统方法相比具有优势。

关键词

空间信息重建;深度学习;条件生成对抗网络

doi: 10.3969/j.issn.1672-9528.2025.08.008

0 引言

不确定性空间信息重建中有多种常用方法,如地质统计法、基于图像处理的方法还有近年兴起的机器学习与深度学习,其中地质统计法应用最为广泛。由于地质统计学与空间数据和结构信息密切相关,也称之为“空间信息统计学”^[1-2]。空间建模工具如今在石油地质、地层学、岩石学、气象学、遥感地质等诸多领域有着广泛的应用^[3]。

目前,应用较多的不确定性空间信息重建方法多点信息统计法,无法将重建特征以参数形式存储在磁盘上,所以每次重建均需要重新扫描TI。而深度学习方法在训练完成后,学习到的特征能够以参数的形式存储在硬盘中,因此可以重复利用,无需每次重新扫描TI。生成对抗网络中生成器将噪声映射到数据空间,期望生成数据具有与真实样本同样的分布。

本文结合条件数据,将CGAN应用于不确定性空间信息重建研究,阐述了条件数据的提取过程,通过对比传统GAN与基于条件数据CGAN的工作原理,并与其他不确定性空间

1. 上海电力大学现代教育技术中心 / 信息办 上海 201306
2. 上海理工大学科技发展研究院 上海 200093

[15] 彭杰威. 基于深度学习的植株点云数据修补算法研究[D]. 广州: 广东工业大学, 2022.

[16] WIDYANINGRUM E, BAI Q, FAJARI M K, et al. Airborne laser scanning point cloud classification using the DGCNN deep learning method[J]. Remote sensing, 2021, 13(5): 859.

[17] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway:IEEE, 2021:13708-13717.

[18] MILDENHALL B, SRINIVASAN P P, TANCIK M, et al. NeRF: representing scenes as neural radiance fields for view synthesis[J]. Communications of the ACM, 2021, 65(1): 99-106.

[19] FAN H Q, SU H, GUIBAS L. A point set generation network for 3D object reconstruction from a single image[EB/

OL].(2016-12-07)[2025-02-12].<https://doi.org/10.48550/arXiv.1612.00603>.

[20] HUANG Z T, YU Y K, XU J W, et al. PF-Net: point fractal network for 3D point cloud completion[C/OL]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR).Piscataway:IEEE,2020[2024-11-12]. <https://ieeexplore.ieee.org/document/9156663>.DOI:10.1109/CVPR42600.2020.00768.

【作者简介】

杨林森(1998—),男,四川巴中人,硕士研究生,研究方向:果园三维重建及点云处理, email: 185287562@qq.com。

(收稿日期: 2025-03-13 修回日期: 2025-07-30)

信息重建方法进行对比,在重建效果上有一定改进,且在速度上更具有优势,可以大幅缩短训练时间。实验验证了本文方法的有效性。

1 条件数据准备

三步采样法^[4]已经被证明是一种有效而普遍的逐层重建方法。而本文将简化采样步骤,通过两步采样得到条件数据,在描述两步采样法的详细过程之前,首先介绍两个与逐层重建直接相关的重要量,即相邻两层之间的变异性 and 连续性。显然,在一个三维空间信息中,两个相邻的层之间具有相同的部分,同时又彼此不同。将连续性定义为图像在相邻两层对应位置的相似性和一致性,而可变性定义为图像的多样性和差异性。与直接三维重建方法相比,逐层重建方法在速度和存储能力上都具有优势。然而,这一方法的本质是根据一定的抽样标准,适当地控制相邻两层之间的连续性和可变性。换句话说,确定采样点的数量和位置对于表征这两个量是非常关键的。

本文的采样方法分为两步:(1)进行5×5采样;(2)进行3×3采样。

首先,用5×5的模板来扫描图像,将中心点标记为采样点,记录其位置和像素值,对应的5×5区域被标记为被访问。采样结束后,获得满足条件的第一部分采样点,对于二值图像而言,图像中的像素均为0或1。与5×5采样类似,在第二步中,使用3×3模板扫描图像。但3×3模板只能对第一步中未访问到的点进行采样,然后将模板的中心点标记为采样点,记录像素值和位置;标记相应的3×3区域为被访问。通过以上两个步骤,剩余区域是不满足5×5和3×3采样条件的区域。至此,完成了两步采样程序,并将所有采样点相结合即可得到采样图像。相应的原理图如图1所示。




图1 两步采样程序原理图

最后的采样点即两步采样结果的组合,灰度点则为需要预测的像素点。

2 条件生成对抗网络的工作原理

GAN的最大特点是无需预先建模,仅采用博弈竞争方式对分布进行采样,逼近真实数据。GAN生成数据的方式虽然简单有效,但其过于“自由”,生成器的输出过于随机,不

能人为控制,为解决这个问题, Mirza 等人^[5]提出了带约束条件的生成对抗网络CGAN。

CGAN为GAN一种拓展,GAN为无监督学习,而CGAN为有监督学习,CGAN生成器的输入是对输出的特定描述,它可以是任意的描述信息,比如类别信息、图像信息等,而不再像GAN生成器的输入,为随机噪声。本文生成器的输入是在TI中抽取的部分信息,用来对生成结果进行控制,对训练网络有一定的引导作用,而GAN网络的生成器输入数据为随机噪声,决定了生成结果的难以控制性,训练网络的不稳定性。这也是CGAN相较于GAN的一大优势。本文生成器的输入数据将在下一节数据准备中进行介绍。本节将在上一章节的基础上介绍CGAN的工作原理。

2.1 CGAN的工作流程

与GAN的将随机噪声 z 映射到输出 y , $G: z \rightarrow y$ 不同,CGAN试图学习将随机噪声 z 和条件数据的 x' 到输出 y , $G: \{x'; z\} \rightarrow y$ 的映射。简而言之,通过将外部条件数据 x' 输入到生成器 G 中,条件数据指导数据生成过程。因此,在这种情况下,对 G 和 D 进行训练以优化目标函数为:

$$\min_G \max_D L(G, D) E_{x' \sim P_d(x'), y \sim P_d(y)} [\log D(x', y)] + E_{x' \sim P_d(x') z \sim P_z(z)} [\log(1 - D(x', G(x', z)))] \quad (1)$$

式中: x' 为两步采样法得到的条件数据; y 为目标图像; $G(x, z)$ 为生成器的输出, G 和 D 的工作流程图如图2所示。




图2 CGAN结构中生成器 G 和判别器 D 的工作流程

2.2 CGAN网络结构与损失函数

与GAN相同,本文方法中使用的模型网络架构包括两个子网,生成器 G 和判别器 D ,并且在此之前,已经进行了诸多工作来设计生成器和判别器结构^[5-6]。其中一个有效而突出的网络结构可以轻松地完成复杂的图像对图像的任务。由于工作性质也是图像数据的输入到图像数据的输出(从TI中采样输入模型中),因此在本文中,采用的网络结构如图3所示。




图3 生成器结构

图3中条件数据为第1节介绍的两步采样的结果，本节主要讨论 $64 \times 64 \times 64$ 的图像重建。值得一提的是， D 用于区分其输入是否真实，并给出输入被判断为真实数据的概率。此外， D 由5个卷积层组成的，最终输出使用 sigmoid 函数转换为一个浮点数（概率）。

在生成网络的设计中，采用形状类似“U”字的网络，包括两部分，即编码和译码（如图3所示），编码器可以被视为执行过程逐渐成倍减少，图像大小从64到1的编码图像特征的过程，译码器执行反向操作，逐渐成倍扩大图像大小，从1到64生成相似图像的过程。一般来说，“U”字网络的编译码过程是完全对称的。在这项工作中，使用2作为图像放大或收缩的倍数。因此，对于一个 $64 \times 64 \times 64$ 的数据来说，编码器和解码器网络都有6层，每层由卷积层、批归一化层和 ReLU 层组成。

该模型的损失函数与传统 GAN 模型的主要区别在生成器 G 中，所以对判别器的损失函数就不再赘述，重点关注生成器 G 的损失函数 L ，即用来衡量生成器 G 生成的图像与 TI 的相似度。本文所使用的综合损失函数 L 是两个独立损失函数的加权和，一个是生成损失 L_G ，另一个是条件损失 L_c 。

L_G 损失用来评估生成的样本与训练集上观察到的模式的相似度，可以表示为：

$$L_G = E_{x,z} [-\log D(x,z)] \quad (2)$$

此外， L_c 损失，即条件损失，被用来约束模型到给定的条件数据。实际上是生成器 G 的输出与条件数据的像素差的绝对值， L_c 损失的定义为：

$$L_c = E_{x',y,z} [\|y - G(x',z)\|_1] \quad (3)$$

此前研究表明，无论是使用生成损失 L_G 还是条件损失

L_c ，都将导致生成效果差。因此，采用 L_G 和 L_c 的加权和，称为综合损失 L ，用公式表示为：

$$L = L_G + \lambda L_c \quad (4)$$

式中： λ 为可指定的权重参数。

3 算法流程

步骤1：设计深度学习网络结构（层数、激活功能等）。

步骤2：输入 TI 和条件数据，并使用梯度下降来更新参数并选择学习率。

步骤3：将随机噪声和条件数据一同输入生成器，生成器生成模拟数据。

步骤4：从生成器的生成分布中进行随机采样，并且计算出每个样本的生成分布，通过最大似然函数求出生成器网络参数。

步骤5：将步骤4中的生成数据与 TI 一同送入判别器，根据判别器输出结果更新网络参数。

步骤6：重复以上步骤，直到模型收敛至纳什平衡点。

步骤2中的训练数据为 $64 \times 64 \times 64$ 的砂岩数据，首先从步骤3中生成器的生成分布中进行随机采样，该生成分布 $P_G(x; \theta)$ 是被 θ 参数化的生成分布，然后计算出 $P_G(x'; \theta)$ ，最后通过最大似然函数：

$$L = \prod_{i=1}^m P_G(x^i, \theta) \quad (5)$$

式中： m 为采样数量。设真实数据分布为 $P_{\text{data}}(x)$ ，求出参数 θ ，用公式表示为：

$$\theta^* = \arg \min_{\theta} \text{KL}(p_d(x) \| P_G(x; \theta)) \quad (6)$$

已知当：

$$D^*(x) = \frac{P_d(x)}{P_d(x) + P_G(x)} = \frac{1}{2} \quad (7)$$

即 $P_d(x) = P_G(x)$ 时，有最大似然函数。再将 $D(x)$ 代入似然函数即可得到空间信息数据的真实分布 $P_d(x)$ 与生成分布 $P_G(x)$ 间的 Jensen Shannon 散度，只需研究 Jensen Shannon 散度最小化即可解决两分布间的逼近问题。实际上 CGAN 的目标函数是一个二分类的交叉熵函数，通过分析生成对抗网络

的目标函数，从 G 的角度分析，若 G 想要“欺骗” D ，则必须最小化目标函数 $L(D, G)$ 。但当 D 学习较好时，会相对准确地判断出来自 G 的样本为假，而从 D 的角度出发，是要最大化两分布间的差异。

4 实验与结果分析

现实中岩石的孔隙分布难以通过数学公式等定量描述的工具来表达，因为其空间结构分布表现出显著的不确定性特征，所以适合采用不确定性空间信息重建方法来表达其孔隙和骨架结构。因此本实验的材料为半径 1.5 mm 的圆柱形砂岩，通过对样本的同步辐射射线扫描来获取该砂岩样本的三维空间数据，其分辨率为 10 ms/ 体素。

4.1 训练图像

本研究的 TI 是从上述砂岩样本中截取的孔隙度为 0.169 4 的数据，其体积为 $64 \times 64 \times 64$ ，样本的三维外表面、 $X/Y/Z$ 轴 32 号位的剖面及孔隙结构如图 4 所示。




图 4 训练图像

图 4 为训练图像，包含孔隙和骨架两种状态。本实验的输入数据集体素为 $64 \times 64 \times 64$ 的三维矩阵，矩阵中的元素取值为 0 和 1，0 代表骨架，1 代表孔隙。

4.2 重建结果

本文分别采用 CGAN 和其他几种经典的重建方法：SNESIM^[7]、DS^[8] 方法重建砂岩图像并进行多维度对比分析。重建图像如图 5~ 图 7 所示。




图 5 CGAN 重建图像




图 6 SNESIM 重建图像




图 7 DS 重建图像

可见四种重建方法的结果均与 TI（图 4）具有相似的结构和长连通的孔隙空间，下面将量化比较各重建结果。

4.3 孔隙度比较


本实验样本的孔隙度为 0.169 4，分别用传统地质重建方法和 CGAN 进行 10 次重建。CGAN 重建结果的孔隙度更接近 TI，而且方差最小，说明重建质量好而且稳定性较高，如表 1 所示。

表 1 SNESIM、DS 和 CGAN 十次重建结果的孔隙度


次数	SNESIM	DS	CGAN
#1	0.180 3	0.210 5	0.170 7
#2	0.180 7	0.209 3	0.171 5
#3	0.172 8	0.197 3	0.164 8
#4	0.170 5	0.186 4	0.168 8
#5	0.186 6	0.197 8	0.174 3
#6	0.187 1	0.172 9	0.174 0
#7	0.173 9	0.203 2	0.175 8
#8	0.176 8	0.185 4	0.172 2
#9	0.117 1	0.176 8	0.165 6
#10	0.181 8	0.210 9	0.170 1
均值	0.172 8	0.195 1	0.170 8
方差	0.000 41	0.000 20	0.000 01

4.4 变差函数与多点连通性比较


本节分别比较了 TI 和 CGAN、SNESIM 以及 DS 的重建结果在 X 、 Y 、 Z 方向的变差函数，如图 8 所示，CGAN 重建数据与 TI 在 A 、 B 方向上的变差函数无明显优势，但是在 Z 方向上更为接近，表明 CGAN 重建图像的空间特征与 TI 更相近，CGAN 的重建质量较好。



(a) X 方向的变差函数




(b) Y方向的变差函数




(c) Z方向的变差函数

图8 TI与SNESIM、DS、CGAN重建图像的变差函数


变差曲线只能表示空间信息中两点的空间连续性。为了进一步评价重建效果,本节还计算了节点的MPC用于评价空间信息的内部结构^[9]。如图9所示,CGAN、SNESIM和DS的MPC曲线在3个方向上都与TI相似,但CGAN的MPC曲线最接近TI。



(a) X方向多点连通性曲线



(b) Y方向多点连通性曲线



(c) Z方向多点连通性曲线

图9 训练图像与SNESIM、DS、CGAN重建图像的多点连通性曲线

4.5 渗透率比较

渗透率是指流体通过不确定性空间的能力。如表2所示,本文所采用的方法与TI在X、Y、Z三个方向上的渗透率更接近,反映了CGAN重建图像的质量较好。

表2 训练图像TI和重建图像在3个方向上的渗透率

方向	TI	SNESIM	CGAN	DS
X	1.631	1.484	1.696	1.528
Y	1.169	1.318	1.148	0.812
Z	1.371	1.021	1.369	1.037

4.6 孔隙分布比较

表3表示TI和10次重建图像的平均孔隙数目。表4表示TI和重建图像中的孔隙直径。如表3和表4所示,CGAN与TI的孔隙数和孔隙直径更为接近。

表3 TI和每种方法的10张重建图像的平均孔隙数

	TI	SNESIM	DS	CGAN
孔隙数	156	143	187	160

表4 TI和每种重建方法重建图像中孔隙直径

孔径(Voxel)	TI	SNESIM	DS	CGAN
平均	9.65	9.16	9.27	9.48
最大	23.74	21.32	21.17	22.83
最小	2.01	1.80	2.11	2.17

4.7 CPU性能与内存比较

本实验在CPU为Inter Core i5,内存为8 GB, GPU为Nvidia GeForce GTX970(4 GB)的环境下完成。本实验评估了CGAN、SNESIM和DS三种方法的平均性能,记录了在10次重建过程中的CPU和GPU平均利用率以及重建时间(分为第1次和剩余9次的平均重建时间),如表5所示。

由于 CGAN 在第一次训练完成后模型参数会被保存，而传统的不确定性空间信息重建方法在每次重建时都需要重新扫描 TI，因此无法避免重复计算。基于这一差异，表 5 将 CGAN 与传统方法的重建时间分别按第 1 次和其余 9 次进行对比。结果显示，CGAN 在后续 9 次重建时间上优势显著。此外，CGAN 能够利用 GPU 进行计算，而传统方法仅依赖 CPU，使得 CGAN 在重建时间和计算负荷方面更具竞争力。

表 5 四种方法在 10 次重建中的平均消耗内存、CPU 利用率、GPU 利用率和运行时间

比较项	SNESIM	DS	CGAN
平均内存	90%	90%	30%
平均 CPU 利用率	90%	90%	33%
平均 GPU 利用率	—	—	70%
第一次运行时间 /s	8 480	22 400	7 600
剩余九次平均重建时间 /s	8 260	21 600	760

CGAN 方法相较于 SNESIM 和 DS 等传统空间数据重建方法还具有明显优势：在进行新的空间数据重建时，SNESIM 和 DS 等传统方法仅在内存中存储训练模式，每当有新任务，都需要重新扫描训练数据以生成新的模式库，而 CGAN 在第一轮训练后会将模型参数永久保存到硬盘中，供后续重建直接调用。当需要重建与训练模型同类型的空间信息时，CGAN 可直接利用已存储的结构特征参数进行重建，以缩短整体重建时间。

5 结论

传统的不确定性空间信息重建方法在每次重建时都需要扫描 TI 建立训练模型，因此会花费较多训练时间，并且会占用大量的 CPU、内存资源。本文将条件生成对抗网络应用于不确定性空间信息重建，生成器的输入是在 TI 中抽取的部分信息，用来对生成结果进行控制，对训练网络有一定的引导作用，使得训练网络的稳定性更高，这也是 CGAN 相较于 GAN 的一大优势。本文实验针对三维砂岩数据使用 CGAN 方法进行建模，通过与传统的地质重建方法比较重建结果的多点连通曲线、变差函数曲线和孔隙度等，评估了该方法的有效性。实验结果表明：（1）CGAN 方法的模拟结果很好地保留了 TI 的结构特征，提高了模拟的效率。（2）与传统方法相比，CGAN 方法在模拟质量、训练速度和内存占用方面也具有优势。

参考文献：

[1] 屠红艳, 张挺, 夏鹏飞. 基于改进型变分自编码器的不确定性空间信息重建方法 [J]. 计算机应用, 2021, 41(10): 2959-2963.

[2] ZHANG M L, ZHANG Y Z, YU G M. Applied geostatistics analysis for reservoir characterization based on the SGeMS (Stanford Geostatistical Modeling Software) [J]. Open journal of yangtze oil and gas, 2017,2(1): 45-66.

[3] BODRUD-DOZA M, ISLAM A R M T, AHMED F, et al. Characterization of groundwater quality using water evaluation indices, multivariate statistics and geostatistics in central bangladesh[J]. Water science, 2016, 30(1): 19-40.

[4] GAO M L, HE X H, TENG Q Z, et al. Reconstruction of three dimensional porous media from a single two-dimensional image using three step sampling[J].Physical review E, 2015, 91: 013308.

[5] MIRZA M, OSINDERO S. Conditional generative adversarial nets[EB/OL].(2014-11-06)[2025-03-23]. <https://doi.org/10.48550/arXiv.1411.1784>.

[6] ISOLA P, ZHU J Y, ZHOU T H, et al. Image-to-image translation with conditional adversarial networks[C/OL][2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).Piscataway:IEEE,2017[2025-01-23]. <https://ieeexplore.ieee.org/document/8100115>.DOI:10.1109/CVPR.2017.632.

[7] PAITHANKAR A, CHATTERJEE S. Grade and tonnage uncertainty analysis of an African copper deposit using multiple-point geostatistics and sequential gaussian simulation[J]. Natural resources research, 2018,27(4): 419-436.

[8] JAMES J K, FAHD K, VENKATRAMAN S. An enhanced inference algorithm for data sampling efficiency and accuracy using periodic beacons and optimization [J]. Big data and cognitive computing, 2019,3(1):7-19.

[9] STREBELLE S. Conditional simulation of complex geological structures using multiple-point statistics[J]. Mathematical geology, 2002, 34: 1-21.

【作者简介】

屠红艳（1996—），女，江苏扬州人，硕士研究生，助理工程师，研究方向：深度学习、图像重建。

陈钰（1994—），通信作者（email: 18208021@mail.shiep.edu.cn），男，上海人，硕士研究生，研究方向：深度学习、图像处理。

（收稿日期：2025-03-07 修回日期：2025-07-30）