

地质统计和深度学习协同驱动的三维储层动态建模方法

白军辉¹ 于晓红¹ 向传刚¹ 丛丽萍¹ 陈大颀² 陈麒玉^{2*}

BAI Junhui YU Xiaohong XIANG Chuangang CONG Liping CHEN Dajie CHEN Qiyu

摘要

三维储层建模旨在对油气储层进行三维模拟和预测,以指导油气勘探和开发。然而,传统的三维储层建模方法在描绘储层结构能力上不足,难以满足实际生产的需求。多点地质统计方法能够很好地描述储层结构,但是也存在诸如参数化严重、局部空间连续性不足等问题。基于深度学习的方法能够很好地表征储层各向异性结构的全局连续性,但却依赖于高质量、大规模的数据进行驱动。为了解决以上储层建模方法中存在的问题,文章提出了一种多点地质统计方法和深度学习协同驱动三维动态建模方法。该方法采取多点地质统计序贯模拟生成储层地质模式库,作为深度学习方法的训练数据。训练生成对抗网络生成高质量的三维储层模型。实验结果和实际观测数据的比较表明,该方法的误差小于5%,有效提高了储层建模的准确性和精度。

关键词

三维储层建模; 多点地质统计; 生成对抗网络; 协同驱动

doi: 10.3969/j.issn.1672-9528.2026.01.001

0 引言

随着全球能源需求的增长和传统石油储备的逐渐枯竭,油气资源的探明与否成为制约国家经济发展的重要一环。储层地质建模是石油工业中一项关键技术,是有效地表征储层属性和特征三维空间分布规律的重要手段^[1]。通过储层地质建模能够在储层格架的基础上对储层的物性参数进行评估,并预测优质储层的空间展布情况。储层建模方法的发展对于有效探明石油和天然气的储量、优化开采方案以及提高开采效率至关重要。

传统的基于变差函数的两点地质统计确定性建模方法,仅考虑了两点之间的空间变异性,无法准确地反映地质结构的不确定性,在表征储层非均质性能力方面不足^[2-3]。为了解决传统三维储层建模方法所遇到的问题,多点地质统计方法(MPS)应运而生^[4],其基本理论的发展以及各种算法的提出为各向异性储层结构、属性描述提供了技术保障^[5]。多点地质统计学随机模拟方法旨在直接从训练图像中提取空间模式,并在模拟网格中实现复杂储层空间模式的表达和刻画^[6]。多点地质统计随机模拟方法不仅能够准确表达实际储层结构、几何形态及其分布模式,其建立的沉积微相模型更

具有地质意义。但是在使用多点地质统计随机模拟方法构建大规模储层结构时,往往存在局部连续性不足的问题,难以细致刻画储层空间局部特性^[7-8]。

近年来,以深度学习为代表的人工智能方法广泛应用于包括地质建模在内的图形生成领域^[9-12]。作为图像生成领域最常用的神经网络模型之一,生成对抗网络(GAN)模型能够分析训练样本数据中的多幅图像,感知其中的几何特征,并生成符合样本数据分布的图像^[13]。GAN等深度生成模型也在地质相关应用中获得了广泛的应用,如:GAN与数字岩心重构与岩石薄片生成等应用^[14-16]。相较于MPS方法,深度学习方法生成的地质图像更加真实、在全局连通性上的表现更好,因此其也在油藏建模方面显示出巨大的潜力。深度学习的方法在应用于地质建模的过程中通常采用整体生成的策略^[17],而地质建模的数据往往存在训练样本数据较少、分布不均衡的问题,此时这种策略会降低生成模式的空间异质性,不利于对模拟结果不确定性分析和优选评价。此外,现有的三维储层建模方法往往使用单一化的数据来源^[18],如测井、地震等数据。单一来源的数据存在数据量不足,而不同来源的数据又难以进行融合,从而协同控制油藏模型的构建,因此无法准确地描绘油气储层的地质特征的问题。这些问题限制了传统储层建模方法的应用范围。

在本文中,提出了一种地质统计和深度学习协同驱动的三维储层动态建模方法。该方法补足了MPS方法全局连通性较差,深度学习方法依赖海量高质量数据驱动的缺点,并结

1. 大庆油田有限责任公司勘探开发研究院 黑龙江大庆 163712
2. 中国地质大学(武汉)计算机学院 湖北武汉 430074
[基金项目] 2021年黑龙江省第一批“揭榜挂帅”科技攻关项目(DQYT-2022-JS-750)

合二者的长处协同解决了储层地质建模中数据量质量不高、多源数据难以融合的问题。在本方法中,使用统一多源数据域、对结构属性进行耦合表达的三维网格边界构建技术来整合多个来源的地质数据,通过 MPS 方法对网格采样后的条件数据生成多个等概率实现,构建储层结构模式库,并利用储层结构模式库训练生成对抗神经网络模型,最后将训练出的网络模型应用于储层地质建模中。对该方法进行了实验分析,结果表明, MPS 与深度学习技术的结合可以应对传统建模方法的挑战,提高油藏建模的准确性和精度,从而指导石油工业中的有效储层管理。

1 相关工作

1.1 多点地质统计学

多点地质统计 (multiple-point statistic, MPS) 模拟旨在直接从训练图像 (参考模型) 中提取区域变量的高维空间统计特征^[19],从而克服了传统地质统计学方法不能再现目标几何形态的不足,已经被广泛应用于储层表征、气象预测、遥感图像质量提升等多个地球科学应用领域^[20-22]。ENESIM 是由 Guardiano 等^[4]提出的最初的多点地质统计模拟算法。ENESIM 算法中,创新性地提出了一种称为训练图像的概念模型来整合各种地质知识。训练图像是先验模型的定量抽象表示,将地质结构和现象的空间分布模式注入 MPS 模拟中,从而使 MPS 方法能够还原复杂地质的各向异性模式。ENESIM 算法为 MPS 方法创造了一个通用原型框架,不过也留下了诸如训练图像难获取、模拟耗时过长或再现大规模结构受限等问题^[23-26]。受搜索树存储结构的启发,Strebel^[27]提出了第一个高效的 MPS 算法 SNESIM 并成功应用于实际油藏建模工作中。SNESIM 在搜索树的帮助下将多点模式和相应的频率存储在搜索树结构中,一定程度上缓解了 ENESIM 模拟效率低下的问题,成为第一个具有实际应用价值的 MPS 方法。Arpat^[28]基于模式识别和分类的思想提出了 SIMPAT 算法,通过对空间局部相似性进行量化,对地下储层进行恢复和再现。Zhang 等^[29]在所提出的 FILTERSIM 算法中通过使用过滤器对空间模式进行分类,避免了模式匹配带来的高算法开销,并且同时适用于类别变量和连续变量的模拟。Mariethoz 等^[30]提出 DS 算法,通过直接采样的方式,大幅提升了 MPS 算法的效率。除了算法本身的改进外,一些方法探索基于提高单次模拟的速度来提升 MPS 模拟的效率。Cui 等^[31]提出一种混合并行策略来有效提升 MPS 模拟效率。此外,也有方法针对三维训练图像难以获取的问题提出了解决方案。Comunian 等^[25]提出了 s2Dcd 算法,该方法基于二维剖面来重建三维模型,但是该方法生成的模型难以保证在各方向上的连通性。Chen 等^[32]提出了 3DRCS 方法,该方法

不仅把二维剖面作为训练图像,同时还利用剖面划分模拟区域,强化了局部特征的再现。

由于多点地质统计模拟方法本身是一个计算密集型任务,且其复杂的参数设置导致其在模拟大规模高分辨率的三维储层参数模型时仍然存在计算效率低、参数调优难等问题,难以做到智能化的储层精细模型高效构建。

1.2 深度学习方法及储层建模应用

深度学习方法能够提取、学习深层次的特征信息并将学习到的特征信息应用到不同任务中。随着近年来深度学习方法在图像生成、图像识别和建模预测等领域的成功应用,逐渐有学者不断尝试将深度学习融入地球科学领域的研究中,如遥感、大气污染预测、气象预测等^[33-34]。在地质建模领域,生成对抗网络框架 (GANs) 与卷积神经网络 (CNN) 结合的深度生成模型是主流的随机建模方法^[35]。基于生成对抗网络的地质建模方法,通过卷积神经网络学习地质空间分布特征和几何特征,通过生成器和判别器不断对抗来生成符合该模式特征的地质模型^[36],其优势在于很大程度上克服了 MPS 方法中模板结构带来的模式尺度再现有限以及抽象复杂空间能力不足等缺点。Laloy 等^[12]尝试将 GAN 应用于地质建模,切割训练图像来获取大量的数据集,取得了不错的生成效果。为了符合实际地质建模场景的需求,有条件约束的地质建模方法成为现在储层建模的研究热点内容^[37-38]。其中的条件约束可能是一些硬约束,例如:井、剖面或一些软约束,具体为地震数据、储层的物理化学特性等。Yang 等^[18]基于剖面数据,在 DCGAN 中添加联合损失项来约束训练过程,能够生成忠实于剖面数据的地质模型。在软数据约束方面, Song 等^[39]结合了测井和一些物化特性,将多元地质知识融入了 GAN 的模拟过程中创造了 GANSim。

深度学习方法在复现储层结构方面相比 MPS 方法有效率和效果的优势。但是其对于海量数据十分依赖,并且可解释较差,难以融入一些先验的地质知识。因此深度学习方法在三维储层研究领域还有着很大的探索空间和应用前景。

2 方法描述

重大石油勘探工程的实施对三维储层模型的精度、效率、可解释性都提出了更高的要求。多点地质统计方法能够很好地融合各类先验数据约束和地质知识,是能很好地保证地质模型符合地质规律的可靠性方法。但其也存在一些例如模式固定和对参数化的严重依赖的瓶颈。相比之下,深度学习方法参数敏感性较低且能够有效捕获数据特征,能够很精细地表征储层几何形态和空间结构。但深度学习的方法需要大量数据来进行知识的蒸馏。因此,在本文中提出了一种多点地质统计和深度学习方法的联合驱动方案,以充分发挥其各自

的优势，协同驱动三维储层建模向着更高效率、更精细、更可靠的方向前行。

在接下来的部分，将论述本文提出的三维储层动态建模方法，包括工作流程和实现细节等方面的详细介绍。

2.1 工作流程

在本研究提出的多点地质统计和深度学习联合驱动的三维地质建模方法中，提供了多种地质建模解决方案。通过对多源数据和训练图像的多次正反馈，联合多点地质统计学方法和深度学习方法，解决了多源数据难以融合和稀缺数据无法驱动训练的建模难题，并在此基础上对实际地质结构进行了精细表征。训练图像是由地质专家绘制的概念模型，它是对地质知识的高度凝练，可以反映地质结构的高阶统计量。然而因为储层勘探环境的高成本和训练图像的高度抽象性，训练图像也呈现极端稀缺性。而深度学习地质建模方法却极度依赖海量数据驱动。为了让深度学习的方法能够有足够的数

据供其学习，本研究中通过 MPS 方法，从少量的训练图像以及多源数据中提炼了大量的地质知识，构建了储层模式库。

如图 1 所示，建模 workflow 将从网格工区的构建开始。建




图 1 地质统计和深度学习协同驱动的建模流程

井曲线等）、三维的训练图像和二维的训练图像、地震数据。二维的训练图像可以是三维训练图像的一个剖面。测井数据作为硬约束，地震数据可作为条件软约束，可以共同协同参与到模型的条件模拟中。聚焦于原始的测量数据，测井数据有实际地理坐标以及多种物理化学特性；地震数据是一个时间域的数据，同样也包含许多物理化学特性（包括：实际坐标、xline、iline、twl 等），并且数据量繁多杂糅、需要人工对其进行解释分析。通过对原始数据进行网格重采样，对其进行时间深度域统一，用一个模型实现多种属性特征耦合表达。二维和三维的训练图像同样也被嵌入到网格模型中，来指导原始数据的属性模拟。

多点地质统计基于对训练图像的概率统计和序贯模拟，能生成忠实于条件数据的地质模型。在本方法的建模 workflow 中，将测井数据作为硬数据，地震数据作为软数据，重采样之后的井数据，经过多点地质统计随机模拟和数据增强之后，可以生成大量的二维和三维的训练图像，从而构建起储层地质模式库。在进行了训练集和测试集的剖分之后，二维剖面

和三维模型可以分别作为条件数据和训练标签输入到生成对抗神经网络（GAN）模型中。生成对抗网络的生成器接收条件数据，尝试生成以假乱真的模型；判别器接收训练标签和生成器生成的假模型，尝试判别出真的和假的模型。最终整个网络达成纳什均衡，建立起条件数据和地质模型之间的数据映射。在训练完成后，只需要输入条件数据，即可高效生成真实的地质模型。

2.2 实现细节

在本节中，讨论了本研究的工作流程涉及的具体方法的实现细节，包括：三维网格工区边界构建技术、基于多点地质统计模拟（DS）的数据集生成方法，基于深度学习（DCGAN）的三维储层建模方法。

生成对抗网络（GAN）是一种深度学习模型，它通过两个相互竞争的神经网络——生成器（generator, G）和鉴别器（discriminator, D），来生成新的数据样本。生成器 G 的任务是从随机噪声中学习并生成与真实数据分布相似的样本，而鉴别器

D 的目标则是区分输入的样本是来自真实数据集还是由生成器生成的假数据。在训练过程中,生成器试图生成越来越逼真的样本以欺骗鉴别器,而鉴别器则不断提高其识别能力以准确区分真实与假数据。这种对抗性训练促使生成器逐步优化其生成策略,从而能够产生高质量的、在视觉上难以与真实样本区分的数据。

图 2 中展示了 GAN 的基本架构,其中生成器 G 接收一个随机噪声向量作为输入,并通过一系列转置卷积层将其转换为一个假样本;鉴别器 D 接收来自真实数据集的样本以及生成器生成的假样本,并通过一系列卷积层来评估这些样本的真实性。鉴别器的输出是一个概率值,表示输入样本为真实数据的可能性。通过这种对抗性训练,生成器和鉴别器相互促进,最终生成器能够生成与真实数据相似的高质量样本。




图 2 GAN 网络架构

本方法中的整体训练过程如图 3 所示,在数据生成环节,采取了 DS 方法作为储层地质模式库的构建方法。




图 3 网络结构及训练过程

DS 方法采用了直接采样的方式生成地质模式,算法消耗低,生成速度快,因此在实际应用中常被优先考虑。DS 方法支持二维和三维模拟,离散和连续属性的模拟,在应用范围方面较广。DS 方法还支持条件模拟中的硬数据模拟和软硬协同模拟,因此可以把地震数据嵌入到模拟 workflow 中。得益于能够统一时间深度域的三维网格,其将网格边界、井数据和地震数据都在同一个模型中得以耦合表达,可以选择

硬数据模拟或者软硬协同模拟生成二维和三维的实现,构建储层地质模式库。二维实现可以作为下一阶段神经网络训练中的条件数据或者标签数据,三维实现可以作为标签数据,也可以将三维实现的切片作为条件数据。构建完成模式库后,对模式库进行评估和优选,保证地质知识和语义能被凝练于构建出的模式库中。将优选后的模式库将作为生成对抗网络的训练数据,参与到神经网络迭代训练优化中。

在建立神经网络映射的环节,本文使用的深度卷积生成对抗网络由生成器和判别器组成。生成对抗网络的网络结构如图 3 所示,生成器根据输入的剖面数据生成三维储层结构模型,判别器计算生成器生成的储层结构在所有输入样本中的概率。生成器的网络结构采用了 U-Net 结合体卷积策略的网络结构,每个卷积层的卷积核大小为 $3 \times 3 \times 3$ 。生成器通过体卷积变换对空间感受野进行缩放,提取储层异质空间由细尺度到粗尺度的结构特征,从而生成更好的局部空间连通性。判别器使用了一个三层的三维卷积神经网络,为了保持感受野的一致性,判别器中卷积层的卷积核大小也被设置为 $3 \times 3 \times 3$ 。在模型的训练优化过程中,由于涉及条件约束,损失函数包含了交叉熵损失项和条件损失项。交叉熵损失函数可以公式化为:

$$L_1(G, D) = E_{x, y \sim P_{\text{data}}(x, y)} [\log D(x, y)] + E_{x \sim P_{\text{data}}(x), z \sim P_{\text{data}}(z)} [\log(1 - D(x, G(x, z)))] \quad (1)$$

条件约束损失函数可以用公式表示为:

$$L_2 = E_{x, y \sim P_{\text{data}}(x, y), z \sim P_z(z)} [\|y - G(x, z)\|_1] \quad (2)$$

式中: x 为条件图像; y 为标签图像; z 为随机噪声。联合损失函数由两个权重参数控制,其公式为:


$$L = \lambda_1 L_1 + \lambda_2 L_2 \quad (3)$$

式中: λ_1 和 λ_2 是调整两项损失的权重参数,用来调节网络的训练过程。本文在训练过程中参数设置为: $\lambda_1=1$, $\lambda_2=1.3$ 。

3 实验分析

如图 4 (a) 所示,选取了一张训练数据 $90 \times 90 \times 90$ 尺度的褶皱结构的二元岩相标准模型作为 DS 模拟的训练图像,在经过 DS 的无条件模拟后,生成了 $128 \times 128 \times 128$ 尺寸的地质模式结构。如图 4 (b) 所示,该模型中含有的褶皱模式相较于原始训练图像更为密集,证明了 DS 能够有效地捕获原始训练图像中的异质模式,并在模拟生成的模型中表达出来。随后采取密集切分策略,用滑动窗口将 DS 生成的 $128 \times 128 \times 128$ 的模型切分成了大量的 $64 \times 64 \times 64$ 的小尺寸模型,采取了大于 1 的步长,来防止滑动窗口切割产生的数据集的模式过于相似和集中,最后生成了共 4 792 张小尺寸数据集,构建了储层模式库。图 4 (c) 展

示了储层模式库中的 8 个 $64 \times 64 \times 64$ 模型。可以看出,即使是小尺寸模型中的褶皱相模式也比原始 $90 \times 90 \times 90$ 尺度中的更密集,这证明 DS 方法确实能够有效地提取原始训练图像中的模式,借助 DS 方法生成的模式更密集,优于直接对原始训练图像进行切割生成的稀疏模式。并且可以看到 DS 方法生成的实现模型,能在很大程度还原训练图像中的异质结构的基础上,生成拥有足够丰富模式的实现,足够丰富的模式有助于帮助深度学习方法很好地增强其泛化性能。然而,模型库中的模型空间结构在局部连通性上还有不足之处,因此需要借助深度学习的方法来增强生成地质模式的局部连通性。



(a) 训练图像 (b) DS 实现 (c) 多点模式库

图 4 储层模式库构建

借助于构建的储层模式库,能够有足量高质量的储层模型数据对基于 DCGAN 的深度学习方法进行驱动。在符合条件约束下进行模拟是储层建模工作的关键性需求,为了符合条件建模的需要,从储层模式库中随机截取剖面作为条件数据,并将除了条件剖面之外的数据进行填充升维,来保证输入与输出的维度相同。为了对神经网络模型的泛化能力进行有效验证,4 792 张小尺寸实现数据集和其对应的条件数据集被 9:1 切分为 4 357 对训练集和 454 对测试集。将 4 357 张实现训练集作为标签数据,将 4 357 张对应的条件数据集作为条件数据和噪声一起输入到 DCGAN 的网络模型中。生成器根据剖面数据尝试生成以假乱真的地质模式,判别器尝试区分真实地质模式和伪造的地质模式。通过两者的博弈最终训练好了可以生成真实储层模型的生成器,并建立了生成器从输入条件剖面到输出真实模型的映射。用测试集中的条件剖面作为输入,复用该模型映射,对生成器生成的地质结构进行了评估分析。图 5 是利用 DCGAN 生成

的 8 个实现,从这些实现的视觉外观可以看出:首先,由于 DCGAN 是由模式库的模型作为标签数据生成的模型,因此其在单模型中褶皱相模式的丰富度上是跟模式库中模型类似的,因而基于模式库数据训练的 DCGAN 的生成实现在模式丰富度上也同样优于基于密集切分数据训练的 DCGAN 的生成实现;其次,相较于 DS 方法生成的储层褶皱相模式,DCGAN 方法生成的模式在局部空间连通性上表现更好,这是由于 DCGAN 能够有效提取训练数据中的地质知识和关键空间结构特征并具有一定的抗干扰能力,能够排除掉模型中一些非连通性结构的干扰影响,从而生成更符合连通性更好的储层模式。




图 5 DCGAN 的实现

除针对生成模型视觉外观上的比较之外,还采样了 20 个生成的模型,并对其进行了一些统计学分析,图 6 展示了由 20 个采样实现和原始训练图像绘制的变差函数曲线。变差函数通过衡量空间任意两点之间的差异情况来表述地质结构的空变异性。如图所示,实现模型的变差函数曲线分布参考模型的变差函数曲线周围,并且两者位置极其靠近,进一步为本方法生成实现的可靠性进行了验证。




图 6 实现(灰色虚线)与训练图像(黑色实线)的变差函数曲线

图 7 展示了由 20 个采样实现和原始训练图像绘制的连通性曲线。连通性曲线可以反映三维模型在 x 和 y 轴上的连通性。如图所示,参考模型和实现模型间的 x 与 y 轴的连通性曲线都极为靠近,再次证明了本方法生成的实现具有比较高的可靠性。




图7 实现(灰色虚线)与训练图像(黑色实线)的连通性曲线

4 应用案例

为了对本文提出的方法可靠性和适用性进行分析,使用了位于松辽盆地某区油田的真实数据进行了建模工作。松辽盆地位于中国东北部,是一个典型的陆相沉积盆地。该盆地的基底由前古生界、古生界变质岩和火成岩等构成。沉积盖层从侏罗系至新生界均有发育,总厚度可达11 000 m以上,但以白垩系为主。其中,白垩系厚度占总厚度的2/3以上,是盆地内的主要生烃层系。松辽盆地由西南隆起区、西部斜坡区、中央凹陷区、东南隆起区、东北隆起区和北部倾没区6个一级构造单元组成。松辽盆地的白垩系包括登娄库组、泉头组、青山口组、姚家组和嫩江组等,青山口组是该盆地内最重要的烃源岩发育区。

首先利用该区内的井数据、地震层位数据、断层数据等基础数据构建研究区的构造网格模型。本文所建构造网格的精度为50 m×50 m×1 m,最终在X、Y、Z方向上网格的剖分数量分别为293、311、110,所建模型结果如图8所示。利用所得模型,将区内实际测井数据及剖面数据中包含的岩性、孔隙度、渗透率属性离散到地质模型中作为先验条件数据。




图8 研究区构造网格模型

区内主要有页岩、油页岩、粉砂岩、介壳灰岩四种岩性的岩石。为了对本文神经网络进行训练,利用相邻区内已有储层岩性模型来构建训练集,并对训练集中数据进行增广。训练过程中,从训练集中随机采样得到钻井形式及剖面形式的条件数据,来更贴近真实的数据分布。图9所示为使用训

练后的网络构建的储层岩性模型,基于该模型随机设置10口虚拟直井,提取粉砂岩、介壳灰岩夹层的平均数,与区内或邻近直井解释夹层的平均条数进行对比,误差分别为2.27%和-3.39%,误差较小,证实所建岩性模型符合已有的岩性分布模式。




图9 研究区岩性建模结果

除了岩性数据外,本文还对孔隙度、渗透率这样的连续储层参数进行了建模,用来验证所提方法面对不同分布的属性数据时的特征重建能力及网络的泛化能力。储层的孔隙度和渗透率两个属性对油气的开发有着重要的影响,并且两个参数之间也存在着内在的联系。在对储层孔隙度进行建模时,本文使用了离散化后的钻孔数据和孔隙度地震解释数据作为条件数据输入,训练网络学习相关的模式,最终构建的孔隙度模型如图10(a)所示。考虑到储层的孔隙度影响着其渗透率,在对储层渗透率进行建模时,本文使用离散化后的钻孔数据以及先前得到的孔隙度模型作为约束,最终构建的储层渗透率模型如图10(b)所示。




图10 研究区储层参数建模结果

可以看出,两个模型的属性值分布范围虽存在差异,但其分布模式表现出明显的相似性。经过统计,该方法建立的储层孔隙度、渗透率模型平均值与区内或邻近直井解释的平均孔隙度和渗透率的误差均在5%以内,结果证明了本文方法条件约束策略的有效性,本文方法能够构建出符合先验认识的地质模型。

5 结论

在传统储层地质建模中,多源数据难以耦合,地质各向异性表征不足,成为制约其广阔应用的极大阻碍。多点地质统计方法和深度学习方法在克服异质结构难以精细刻画方面都取得了很大的成果,但是MPS方法是计算密集型方法,参数化严重,并且使用多点地质统计随机模拟方法描述大规模

储层结构时,往往存在全局连续性不足的问题。深度学习的储层建模方法往往依赖大规模的数据进行训练,而实际建模流程中往往缺乏海量高质量的数据。

为了解决储层建模中的以上难点,本文提出了一种地质统计和深度学习协同驱动的三维储层动态建模方法,使用多点地质统计随机模拟方法根据网格化后的测井和地震数据能够实现储层结构的有效学习,并生成多个等可能概率的储层模型,构建储层结构模式库,避免了深度学习难以获取三维训练数据的问题。使用生成对抗网络模型从稀疏剖面重建整个储层模型结构,提高了对复杂各向异性储层结构的重建能力。本文通过实验分析以及实际数据应用对方法的可靠性进行了可靠性验证。实验结果表明,本文的方法能够支持融合多源数据,并结合多点地质统计学和深度学习方法的优点,有效提升了表征储层异质结构的能力。

参考文献:

- [1]PYRCZ M J, DEUTSCH C V. Geostatistical reservoir modeling[M].United Kingdom:Oxford University Press, 2014.
- [2]KLISE K A, WEISSMANN G S, MCKENNA S A, et al. Exploring solute transport and streamline connectivity using lidar-based outcrop images and geostatistical representations of heterogeneity[J/OL]. Water resources research,2009[2025-12-02].<https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2008WR007500>.
- [3]KNUDBY C, CARRERA J. On the relationship between indicators of geostatistical, flow and transport connectivity[J]. Advances in water resources, 2005, 28(4): 405-421.
- [4]GUARDIANO F B, MOHAN SRIVASTAVA R. Multivariate geostatistics: beyond bivariate moments[J]. Geostatistics tróia'92, 1993,5: 133-144.
- [5]HU L Y, CHUGUNOVA T. Multiple-point geostatistics for modeling subsurface heterogeneity: a comprehensive review[J/OL]. Water resources research,2008[2025-12-02]. <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2008WR006993>.
- [6]MARIETHOZ G, CAERS J. Multiple-point geostatistics: stochastic modeling with training images[M]. Hoboken:John Wiley & Sons, 2014.
- [7]李振华. 复杂断块油藏储层地质建模研究 [D]. 北京: 中国石油大学, 2010.
- [8]熊英, 周志远, 刘志方, 等. 三维地质建模技术的研究与应用综述 [J]. 城市勘测, 2023(4):184-190.
- [9]CUI Z S, CHEN Q Y, LIU G. Characterization of subsurface hydrogeological structures with convolutional conditional neural processes on limited training data[EB/OL]. (2022-12-02)[2025-12-02].<https://www.xmol.com/paper/1598914629795893248>.DOI: 10.1029/2022wr033161.
- [10]BAI T, TAHMASEBI P. Hybrid geological modeling: combining machine learning and multiple-point statistics[J]. Computers & geosciences, 2020, 142: 104519.
- [11]GUO J T, LI Y Q, JESSELL M W, et al. 3D geological structure inversion from Noddy-generated magnetic data using deep learning methods[J]. Computers & geosciences, 2021, 149: 104701.
- [12]LALOY E, HÉRAULT R, JACQUES D, et al. Training-image based geostatistical inversion using a spatial generative adversarial neural network[J]. Water resources research, 2018, 54(1): 381-406.
- [13]GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [14]ZHANG T, XIA P F, LU F F. 3D reconstruction of digital cores based on a model using generative adversarial networks and variational auto-encoders[J]. Journal of petroleum science and engineering, 2021, 207: 109151.
- [15]ZHENG Q, ZHANG D X. RockGPT: reconstructing three-dimensional digital rocks from single two-dimensional slice with deep learning[J]. Computational geosciences, 2022, 26(3): 677-696.
- [16]CHENG G J, ZHANG F L, QIANG X J. Super-resolution reconstruction of rock thin-section image based on SinGAN[C]// 2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). Piscataway:IEEE,2020: 786-790.
- [17]CHEN Q Y, CUI Z S, LIU G, et al. Deep convolutional generative adversarial networks for modeling complex hydrological structures in Monte-Carlo simulation[J]. Journal of hydrology, 2022, 610: 127970.
- [18]YANG Z X, CHEN Q Y, CUI Z S, et al. Automatic reconstruction method of 3D geological models based on deep convolutional generative adversarial networks[J]. Computational geosciences, 2022, 26(5): 1135-1150.
- [19]ZHANG T F, BOMBARDE S, STREBELLE S, et al. 3D porosity modeling of a carbonate reservoir using continuous multiple-point statistics simulation[J]. SPE journal, 2006, 11(3): 375-379.
- [20]HU L Y, LIU Y, SCHEEPENS C, et al. Multiple-point simulation with an existing reservoir model as training image[J]. Mathematical geosciences, 2014, 46(2): 227-240.

- [21]AZAMIFARD A, AHMADI M, RASHIDI F, et al. Insights of new-generation reservoir property modeling (MPS methods) in assessing the reservoir performance for different recovery methods[J]. Arabian journal of geosciences, 2020, 13(7): 1-14.
- [22]JHA S, MARIETHOZ G, EVANS J P, et al. Demonstration of a geostatistical approach to physically consistent downscaling of climate modeling simulations[J]. Water resources research, 2013, 49(1): 245-259.
- [23] 石书缘, 尹艳树, 和景阳, 等. 基于随机游走过程的多点地质统计学建模方法[J]. 地质科技情报, 2011, 30(5): 127-131.
- [24]ZHOU K F, ZHANG N N. Extraction of alteration mineral information from moderate remote sensing images using MPS method[J]. Journal of the indian society of remote sensing, 2018, 46(1): 89-96.
- [25]COMUNIAN A, RENARD P, STRAUBHAAR J. 3D multiple-point statistics simulation using 2D training images[J]. Computers & geosciences, 2012, 40: 49-65.
- [26]RENARD P, MARIETHOZ G. Special issue on 20 years of multiple-point statistics: part 1[J]. Mathematical geosciences, 2014, 46: 129-131.
- [27]STREBELLE S. Conditional simulation of complex geological structures using multiple-point statistics[J]. Mathematical geology, 2002, 34: 1-21.
- [28]ARPAT G B. Sequential simulation with patterns[D]. Palo Alto: Stanford University, 2005.
- [29]ZHANG T F, SWITZER P, JOURNEL A. Filter-based classification of training image patterns for spatial simulation[J]. Mathematical geology, 2006, 38(1): 63-80.
- [30]MARIETHOZ G, RENARD P, STRAUBHAAR J. The Direct Sampling method to perform multiple-point geostatistical simulations[J/OL]. Water resources research, 2010[2025-12-02]. <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2008WR007621>.
- [31]CUI Z S, CHEN Q Y, LIU G, et al. Hybrid parallel framework for multiple-point geostatistics on Tianhe-2: a robust solution for large-scale simulation[J]. Computers & geosciences, 2021, 157: 104923.
- [32]CHEN Q Y, MARIETHOZ G, LIU G, et al. Locality-based 3D multiple-point statistics reconstruction using 2-D geological cross sections[J]. Hydrology and earth system sciences, 2018, 22(12): 6547-6566.
- [33]HAMIDA A B, BENOIT A, LAMBERT P, et al. 3D deep learning approach for remote sensing image classification[J]. IEEE transactions on geoscience and remote sensing, 2018, 56(8): 4420-4434.
- [34]WANG S, LI Y R, ZHANG J, et al. PM2.5-GNN: a domain knowledge enhanced graph neural network for PM2.5 forecasting[EB/OL]. (2021-10-11)[2025-12-02]. <https://doi.org/10.48550/arXiv.2002.12898>.
- [35]周永章, 左仁广, 刘刚, 等. 数学地球科学跨越发展的十年: 大数据、人工智能算法正在改变地质学[J]. 矿物岩石地球化学通报, 2021, 40(3): 556-573.
- [36]SONG S H, MUKERJI T, HOU J G. Bridging the gap between geophysics and geology with generative adversarial networks[J/OL]. IEEE transactions on geoscience and remote sensing, 2021[2025-12-02]. <https://ieeexplore.ieee.org/document/9399180>. DOI: 10.1109/TGRS.2021.3066975.
- [37]ZHANG T F, TILKE P, DUPONT E, et al. Generating geologically realistic 3D reservoir facies models using deep learning of sedimentary architecture with generative adversarial networks[J]. Petroleum science, 2019, 16(3): 541-549.
- [38] 石书缘, 尹艳树, 冯文杰. 多点地质统计学建模的发展趋势[J]. 物探与化探, 2012, 36(4): 655-660.
- [39]SONG S H, MUKERJI T, HOU J G. GANSim: conditional facies simulation using an improved progressive growing of generative adversarial networks(GANs)[J]. Mathematical geosciences, 2021, 53(7): 1413-1444.

【作者简介】

白军辉(1978—), 男, 陕西扶风人, 硕士, 正高级工程师, 研究方向: 油气田开发及信息化, email: jhbai@petrochina.com.cn。

于晓红(1982—), 女, 黑龙江大庆人, 硕士, 高级工程师, 研究方向: 智能化开发及信息化, email: yu-xh@petrochina.com.cn。

向传刚(1982—), 男, 重庆丰都人, 硕士, 高级工程师, 研究方向: 低渗透油藏建模数模及非常规油藏地质力学研究, email: xiangchuangang@petrochina.com.cn。

丛丽萍(1981—), 女, 黑龙江大庆人, 本科, 高级工程师, 研究方向: 勘探开发智能软件开发, email: congplp@petrochina.com.cn。

陈大颀(2000—), 男, 山东德州人, 博士研究生, 研究方向: 智能三维地质建模算法, email: chendj@cug.edu.cn。

陈麒玉(1990—), 通信作者(email: qiyu.chen@cug.edu.cn), 男, 甘肃天水人, 博士, 教授, 研究方向: 三维地质建模及地学大数据应用。

(收稿日期: 2025-07-03 修回日期: 2025-12-30)