

# 基于生成对抗网络的储层地质建模方法研究进展

宋随宏<sup>1,2,3</sup>, 史燕青<sup>1,2,4</sup>, 侯加根<sup>1,2,4\*</sup>

1 中国石油大学(北京)地球科学学院, 北京 102249

2 中国石油大学(北京)人工智能学院, 北京 102249

3 鹏城实验室, 深圳 518055

4 中国石油大学(北京)油气资源与探测国家重点实验室, 北京 102249

\* 通信作者, houjg63@cup.edu.cn

收稿日期: 2021-10-12

国家自然科学基金面上项目(42072146) 和国家自然科学基金青年基金项目(42102118) 联合资助

**摘要** 地下储层地质建模对油气和水资源的开发以及CO<sub>2</sub>地质封存(CCS)具有重要意义。传统基于地质统计学的建模方法(如基于变差函数或多点统计学的方法)产生的储层地质模型可在一定程度上与地质模式保持一致,但当模式特征变得复杂时,则具有明显的缺陷。深度学习中的生成对抗网络(GANs)能够抽象和再现复杂的空间模式特征,而在许多领域得到了成功的应用。近年来,学者将生成对抗网络与地质建模相结合,利用由卷积神经网络(CNN)构成的生成器(模拟器)去学习复杂的地质模式特征,进而产生非常逼真的地质模型。基于生成对抗网络的地质建模方法在许多方面得到了深入研究,该方法甚至已被应用于实际油田复杂储层的三维地质建模,取得了很好的效果。本文综述了基于生成对抗网络地质建模方法的研究进展,主要包括无条件约束和有条件约束两大类。无条件约束即只需产生吻合期望模式特征的地质模型而无须与条件数据一致。根据生成对抗网络训练方式的不同,其可分为传统生成对抗网络地质建模方法和渐进增长的生成对抗网络地质建模方法。前者对模拟器和判别器中的所有卷积层同时进行训练,而后者则是从浅到深逐层进行训练。渐进增长的方法允许模拟器从大到小逐尺度学习地质模式特征,因而在地质模型效果和训练时间方面优于传统方法。为了构建同时吻合模式特征和给定条件数据的地质模型,有条件约束的生成对抗网络地质建模方法被提出并得到广泛研究。其中,基于模拟器输入向量搜寻的条件化方法主要应用梯度下降法或马尔可夫链蒙特卡罗法(MCMC)去搜寻适当的潜在向量,使其通过预训练模拟器生成与给定条件数据一致的地质模型。但是,当条件数据发生变化时,则需要重新搜寻另一组合适的潜在向量,需要大量的时间和计算资源。为此,模拟器直接条件化的地质建模方法(GANSim)被提出。该方法中,模拟器被训练以同时学习模式特征和各类条件数据与地质模型之间关系的知识,进而利用这两类知识将给定的任意条件数据直接转化为与模式特征和条件数据都吻合的地质模型。GANSim方法已被拓展到三维,形成GANSim-3D框架,并成功应用于塔河油田溶洞储层的三维地质建模。最后,笔者就GANSim框架、生成对抗网络地质建模方法所耗资源、该方法的工业落地和地质知识数字化研究提出了几点展望。

**关键词** 生成对抗网络; 地质建模; 卷积神经网络; 地质模型; 储层

引用格式: 宋随宏, 史燕青, 侯加根. 基于生成对抗网络的储层地质建模方法研究进展. 石油科学通报, 2022, 01: 34-49

SONG Suihong, SHI Yanqing, HOU Jiagen. Review of a Generative Adversarial Networks (GANs)-based geomodelling method. Petroleum Science Bulletin, 2022, 01: 34-49. doi: 10.3969/j.issn.2096-1693.2022.01.004

# Review of a Generative Adversarial Networks (GANs)-based geomodelling method

SONG Suihong<sup>1,2,3</sup>, SHI Yanqing<sup>1,2,4</sup>, HOU Jiagen<sup>1,2,4</sup>

*1 College of Geosciences, China University of Petroleum-Beijing, Beijing 102249, China*

*2 College of Artificial Intelligence, China University of Petroleum-Beijing, Beijing 102249, China*

*3 Peng Cheng Laboratory, Shenzhen 18055, China*

*4 State Key Laboratory of Petroleum Resources and Prospecting, China University of Petroleum-Beijing, Beijing 102249, China.*

**Abstract** Geomodelling of subsurface reservoirs is of great significance to the development of hydrocarbon and water resources as well as carbon capture and storage (CCS). Traditional geostatistics-based geomodelling approaches (e.g., variogram- or multiple point statistics-based) produce geomodels that are to some extent consistent with geological patterns but have apparent flaws when the patterns become complicated. Generative Adversarial Networks (GANs) in deep learning can abstract and reproduce complicated spatial patterns and have been used successfully in many areas. In recent years, GANs have been combined with geomodelling, where the generator composed of Convolutional Neural Networks (CNN) can first learn complicated geological patterns and then produce realistic reservoir geomodels. The GANs-based geomodelling approach has been researched and improved in many aspects. Researchers have even applied this method in the 3D geomodelling of complicated field reservoirs, much of which has achieved excellent performance. This paper reviews the research progress of the GANs-based geomodelling approach. The unconditional geomodelling approach can be classified into two categories, namely conventional and progressive GANs-based methods, based on the training manner of GANs. With a conventional manner, all CNN layers of the generator and discriminator are concurrently trained, while with a progressive manner, they are trained layer by layer from shallow to deep. The progressive manner allows the generator to learn geological patterns from coarse to fine scales and thus is superior to the conventional alternative in terms of the output quality and training time. To produce geomodels that are consistent with not only expected geological patterns but also the given conditioning data, GANs-based conditional geomodelling approaches are proposed. One of the conditional approaches is the post-GANs latent vector searching method, where proper input latent vectors of a pretrained generator are searched using the gradient descent or the Markov Chain Monte Carlo (MCMC) methods. In this context, geomodels consistent with given conditioning data can be produced from these proper latent vectors by the pretrained generator. However, once the given conditioning data change, another set of proper latent vectors needs to be searched, which requires a lot of time and computational resources. As a countermeasure, the direct conditional simulation method based on GANs (GANSim) is proposed. In GANSim, the generator is trained to learn both geological patterns and relationships between various conditioning data and the geomodel; with these two types of learned knowledge, the generator can directly map any given conditioning data into geomodels that are consistent with both geological patterns and conditioning data. GANSim is expanded into 3D to form a GANSim-3D framework, which has been successfully applied in 3D geomodelling of karst cave reservoirs in the Tahe Oilfield. Finally, several prospects are proposed as potential future working directions, involving GANSim frameworks, training resources, industrialization potentials, and digitalization of geologic knowledge.

**Keywords** generative adversarial networks; GANs; geomodelling; convolutional neural network; geo-model; reservoir

**doi:** 10.3969/j.issn.2096-1693.2022.01.004

## 0 引言

储层地质建模本质上是一个融合井筒、地震和地质模式等多类地质信息对地下储层的空间分布进行精细预测的过程,是油气储量评价、钻井设计和油气田开采方案调整的关键。储层离散相(包括但不限于沉积相)建模是储层属性建模的基础,本文所提及的储层建模特指离散相地质建模。

长期以来,诸多地质统计学方法被应用于各类储层的地质建模<sup>[1]</sup>,包括基于变差函数的方法<sup>[2-3]</sup>、基于

目标的方法<sup>[4-6]</sup>和仿沉积过程的方法<sup>[7-8]</sup>。其中,基于变差函数的方法虽然可以较好地吻合井筒、地震等条件数据,但无法刻画地质体的复杂几何形态;而基于目标的和仿沉积过程的方法虽然可以很好地复现地质体的地质模式(如几何形态和沉积相接触关系等),但在融合井点等条件数据上存在较大的不足<sup>[9]</sup>。

近年来,基于多点地质统计学的建模思路被提出并广泛应用,如SNESIM方法<sup>[10]</sup>、SIMPAT方法<sup>[11]</sup>、FILTERSIM方法<sup>[12]</sup>、HYPPS方法<sup>[13]</sup>和直接采样方法(Direct Sampling)<sup>[14]</sup>。基于多点地质统计学的建模方法

通过扫描训练图像获取地质空间内的多点统计数据, 以此作为地质模式信息, 生成的地质模型可在忠实于井点和概率体条件数据的基础上一定程度地复现地质体的模式特征。但是, 由于其对于地质模式的表达仅限于训练图像小范围内的多点统计信息, 缺乏对更大范围地质模式特征的完整抽象和总结, 当井点数据稠密或地质体结构较为复杂时, 基于多点地质统计学的方法建模效果并不理想, 如出现河道相储层断断续续的现象。

如何让构建的地质模型既能完整有效地复现地质模式特征又能很好地吻合各类条件数据, 是地质建模的核心问题, 其中对空间地质模式特征的复现是最大的难点。人工智能(深度学习)中的生成对抗网络框架(GANs)<sup>[15]</sup>与卷积神经网络(CNN)<sup>[16]</sup>相结合, 可以很好地抽象并复现物体完整的空间模式特征, 即生成非常逼真的虚拟物体(如人脸图片), 在图像生成<sup>[17-20]</sup>、云层空间形态预测<sup>[21]</sup>、岩石微观模型重建<sup>[22]</sup>等领域有着成功的应用。近几年, 多位学者将此方法应用于储层地质建模, 在生成对抗网络框架下去训练得到由卷积神经网络构成的地质模型模拟器, 让其学习地质体完整的空间模式特征, 并生成吻合该模式特征的地质模型<sup>[23-32]</sup>; 这类方法被称为基于生成对抗网络的地质建模方法。刘彦锋等<sup>[33]</sup>已就该方法的特点、应用和未来发展方向做了概述。根据有无条件约束, 基于生成对抗网络的地质建模方法可具体分为无条件约束和有条件约束两种情况, 本文深入讨论每种情况的核心思想、应用效果以及未来研究应用的展望。

## 1 无条件约束的生成对抗网络地质建模方法

将原始生成对抗网络直接应用于地质建模, 便可形成无条件约束的地质建模方法。生成对抗网络的训练过程可分为传统训练过程和渐进增长的训练过程, 与之相对应, 无条件约束建模方法也可分为传统生成对抗网络地质建模方法和渐进增长的生成对抗网络地质建模方法。下文依次简要介绍生成对抗网络框架、传统生成对抗网络地质建模方法和渐进增长的生成对抗网络地质建模方法。

### 1.1 生成对抗网络框架

生成对抗网络(GANs)是深度学习中的一种训练神经网络的框架, 由Goodfellow<sup>[15]</sup>提出。其根本目的是: 训练神经网络从观测样本中学习样本的一般模式知识(如人脸的模式), 并据此生成与该模式吻合的虚拟

样本(如逼真的人脸图片)。目前已有多个生成对抗网络变种框架<sup>[17-19, 34-36]</sup>。

生成对抗网络主要包含生成器神经网络、判别器神经网络和损失函数。生成器将低维随机数组生成成为虚拟样本, 判别器则将真实或虚拟样本转化为一个代表输入样本真假程度的数值, 称为逼真度, 损失函数则为真假样本对应的逼真度间的某种距离。生成器和判别器的神经网络结构可以是全连接神经网络、卷积神经网络(CNN)或循环神经网络(RNN)<sup>[37]</sup>。针对图片或地质模型等具有空间结构的样本数据形式, 一般采用卷积神经网络作为生成器和判别器<sup>[25-26, 34, 38]</sup>。基于真假样本逼真度间不同的距离计算方式, 多类损失函数已被提出<sup>[39-41]</sup>, 其中基于梯度惩罚的Wasserstein损失函数(Wasserstein loss with gradient penalty)<sup>[41]</sup>取得了很好地应用效果。

对于生成对抗网络的训练可分为传统训练过程和渐进增长的训练过程<sup>[17]</sup>。传统过程中, 把生成器和判别器神经网络分别当作不可拆分的整体, 依次循环训练判别器和生成器, 来分别增大和减小损失函数。该过程中, 生成器不断学习真实样本中的模式知识, 进而生成与真实样本极为相像的虚拟样本。而样本的模式特征具有尺度性, 大尺度模式特征控制或影响着小尺度模式特征。但是传统训练过程没有考虑模式的尺度性, 而让生成器完全自主地学习所有尺度的模式知识; 生成器有可能先学习小尺度模式特征后学习大尺度模式特征, 限制了生成器的学习效率和最终生成效果。

Karras<sup>[17]</sup>提出了渐进增长的生成对抗网络训练方法(progressive growing of GANs)。该方法中, 生成器中的神经网络被逐层加以训练, 来依次从大到小地学习不同尺度的模式特征; 比如第一层神经网络学习大尺度模式特征, 第二层神经网络学习中尺度模式特征。该方法考虑了不同尺度模式特征之间的控制和依附关系, 极大地提升了生成对抗网络的训练效率和最终生成效果, 在训练时间、稳定性和生成效果等方面远超传统训练方法<sup>[17]</sup>。

### 1.2 传统生成对抗网络地质建模方法

传统生成对抗网络地质建模方法主要强调应用传统过程去训练生成对抗网络。Song<sup>[30]</sup>之前的生成对抗网络建模方法<sup>[23-29]</sup>均采用传统训练过程。下文依次介绍传统生成对抗网络地质建模方法的核心思想及典型应用。在地质建模中, 生成对抗网络的生成器和判别器均采用卷积神经网络结构。

1.2.1 核心理念

图 1 以暗河溶洞二维(水平切面)地质模型作为样本的情况为例,直观展示了传统生成对抗网络地质建模的核心理念。给定诸多吻合暗河溶洞地质模式的原型模型作为训练数据(真实样本),这些训练地质模型在对应的高维空间中具有特定的分布范围。此处的“高维”特指表征地质模型所有可能性的维度空间,比如,一个  $100 \times 100 \times 100$  的河道与非河道两相地质模型的维度则为  $2^{100 \times 100 \times 100}$ 。生成器神经网络的根本目的就是这些训练地质模型中学习到暗河溶洞的地质模式知识,并应用该知识生成具有相同模式特征的地质模型。

首先,在未经训练时,生成器  $G_0$  尚未学习到任何地质模式知识,其由随机向量生成的虚拟地质模型  $S_0$  非常杂乱,不显现任何地质模式特征。随后,判别器首次得到训练 ( $D_1$ ),将虚拟的地质模型  $S_0$  与真实的训练地质模型集分割开来。然后,生成器得到训练 ( $G_1$ ),通过学习训练地质模型集中的部分模式知识,来生成具有一定模式特征的地质模型  $S_1$ ,以让此时的判别器  $D_1$  无法区分虚拟地质模型  $S_1$  和训练地质模型集。随后,判别器再次得到训练 ( $D_2$ ) 来将新的虚拟地质模型  $S_1$  与训练地质模型集分割开。而后,生成器再次得到训练 ( $G_2$ ),通过学习更多的地质模式知识,

来生成更为真实的地质模型  $S_2$ 。通过对判别器和生成器的循环训练,生成器逐渐学习到越来越多的地质模式知识,并最终生成与训练地质模型极为相像的虚拟地质模型,以至于判别器再也无法将虚拟的地质模型与真实的训练地质模型区分开来。

最终的生成器 ( $G_N$ ) 便学习到了训练模型集中暗河溶洞发育的全部地质模式知识,可将任意低维向量生成为吻合暗河溶洞地质模式的、逼真的地质模型。该生成器则可作为地质模型的模拟器在无条件约束的地质建模实际中加以应用。为了便于地质领域研究人员的理解,本文将生成器统称为地质模型模拟器。生成对抗网络本质上是通过判别器和模拟器“博弈式”的交替优化,来将训练地质模型集中的地质模式知识迁移到模拟器神经网络中来,以定量参数的形式保存下来。

1.2.2 应用效果分析

Laloy<sup>[25]</sup>最早将生成对抗网络应用于地质建模,将一个大型训练图像经过若干次切割而形成诸多小型训练地质模型,应用传统生成对抗网络训练方法得到模拟器卷积神经网络;训练完成的模拟器可将任意随机向量生成为与训练地质模型非常相像的地质模型,如图 2 所示。Zhang<sup>[26]</sup>应用基于目标的方法构建了大量的训练地质模型,去训练模拟器;而后将模拟

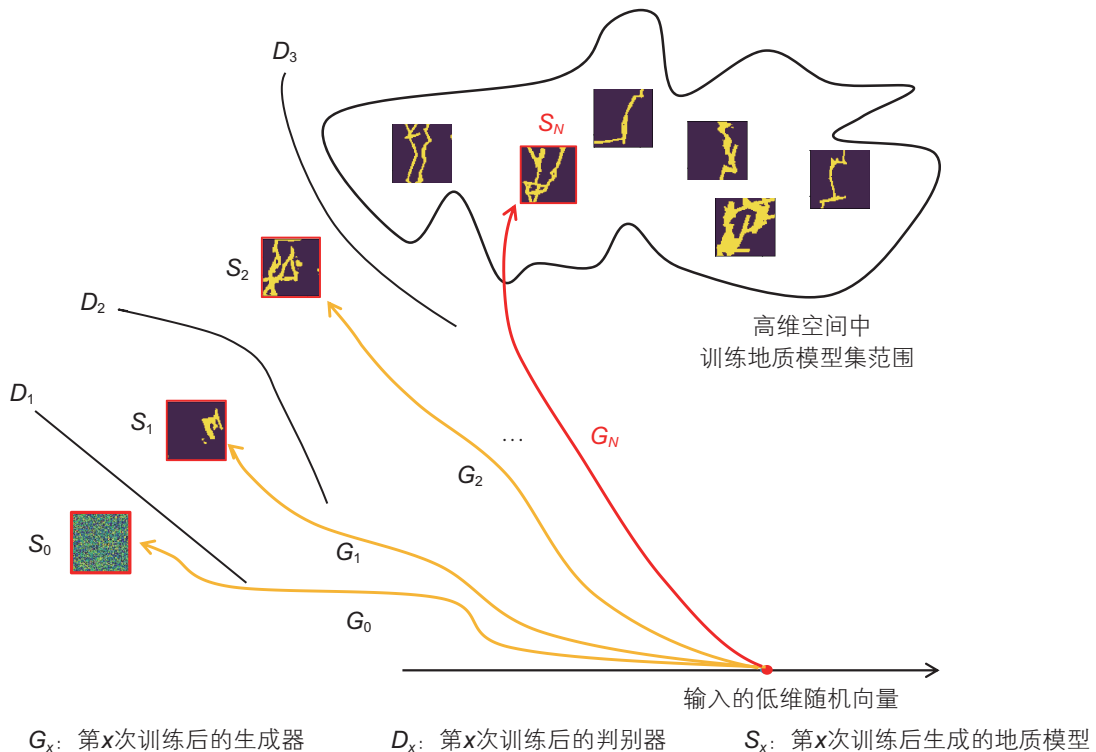


图 1 生成对抗网络地质模型生成器(模拟器)训练过程示意图

Fig. 1 Schematic diagram of training process of the geomodel generator based on Generative Adversarial Networks




图2 河道相二维训练地质模型与模拟器生成的地质模型实现示例<sup>[25]</sup>

Fig. 2 Examples of 2D training facies models of channel reservoirs and the corresponding generator-produced facies models<sup>[25]</sup>




图3 河道相三维训练地质模型与模拟器生成的地质模型实现示例<sup>[26]</sup>

Fig. 3 Examples of 3D training facies models of channel reservoirs and the corresponding generator-produced facies models<sup>[26]</sup>

器应用于无条件约束的三维地质建模，如图 3 所示。Nesvold<sup>[27]</sup>通过对地表卫星照片的处理来获取河道相水平切片二维训练地质模型集，去训练模拟器，进而进行无条件约束的随机模拟。在这些研究中，模拟器产生的地质模型均与训练地质模型非常相像，即生成的地质模型与训练地质模型具有相同的地质模式特征，表明模拟器学习到了完整的地质模式知识。

### 1.3 渐进增长的生成对抗网络地质建模方法

Song<sup>[30]</sup>首次将生成对抗网络渐进增长的训练过程与地质建模相结合，形成了渐进增长的生成对抗网络地质建模方法，并将其与传统方法进行了应用对比分析。下文简述了该方法的思想步骤及应用分析。

#### 1.3.1 核心理念

该方法包括训练地质模型多精度粗化和渐进增长的模拟器训练两个步骤；前者是为了获得能够代表不同尺度地质模式特征的训练地质模型集，后者则是让

模拟器从这些训练地质模型集中依次学习到不同尺度的地质模式知识。比如，针对图 4 所示的模拟器和判别器结构(原始训练地质模型和模拟器最终生成的地质模型均为  $64 \times 64$  的暗河溶洞水平切片二维模型)，首先将原始训练地质模型粗化到  $32 \times 32$ 、 $16 \times 16$ 、 $8 \times 8$  和  $4 \times 4$  不同精度，精度越低的训练地质模型代表的模式尺度越大；然后从左到右依次激活模拟器和判别器中的卷积神经网络层，即卷积 1、卷积 2、...，同时应用从低到高不同精度的训练地质模型去训练当时的模拟器和判别器，来让模拟器依次学习从大到小不同尺度的地质模式知识；训练完成后，把模拟器中的所有卷积层当作一个整体在实际建模中加以应用，生成  $64 \times 64$  的暗河溶洞二维地质模型。

#### 1.3.2 应用效果分析

Song<sup>[30]</sup>将渐进增长生成对抗网络地质建模方法应用于河道及暗河溶洞储层水平切片二维地质建模，并与传统生成对抗网络地质建模方法进行了对比。图 5

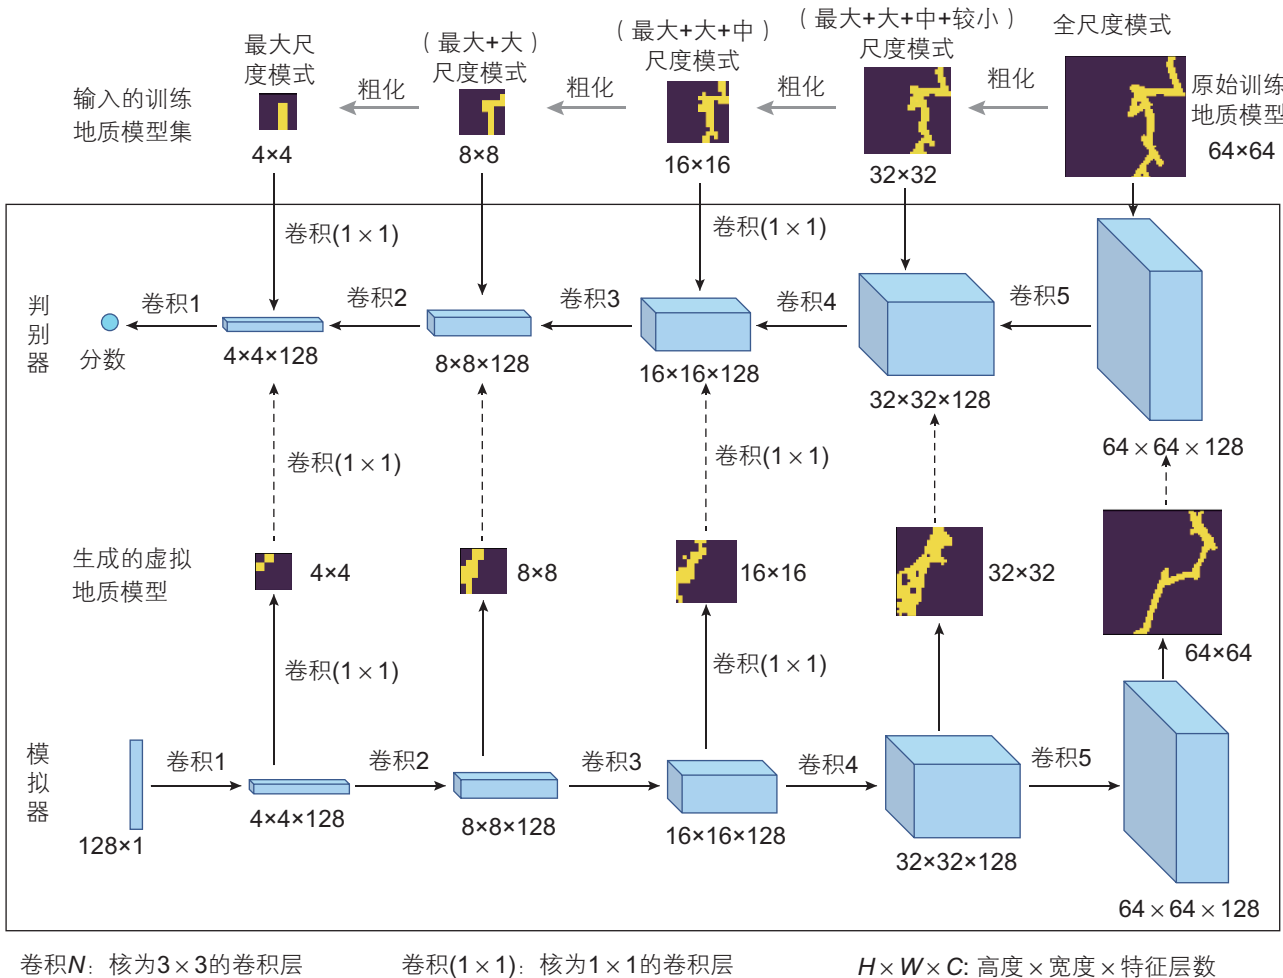


图 4 渐进增长生成对抗网络地质建模方法示意图

Fig. 4 Schematic diagram of the geomodelling approach based on progressive growing of GANs

展示了渐进增长的训练过程中模拟器依次生成的河道储层地质模型；可以看出，随着模拟器中越来越多的卷积层被激活和训练，模拟器学到越来越精细的地质模式特征，而生成越来越逼真的地质模型(从第1列到第5列)，最终生成的地质模型(第5列)与训练地质模型(最后两列)极为相似。

图6把渐进增长生成对抗网络地质建模方法产生的地质模型、传统生成对抗网络地质建模方法产生的地质模型与训练地质模型进行了对比，可以看到两种

方法产生的地质模型都与训练地质模型极为相像，且都具有很强的多样性，表明两种方法中的模拟器都学习到了训练地质模型中完整的地质模式知识。但渐进增长的建模方法中训练模拟器所需的时间(6.03 h)仅是传统方法所需时间(15.4 h)的39.2%，证明渐进增长方法在训练时间上的明显优势。在模拟效果上，Song<sup>[30]</sup>应用基于Wasserstein距离的多尺度标量图法定量评价了两种建模方法产生的地质模型与训练地质模型的分布关系。如图7所示，每个样点代表40个地质模型，

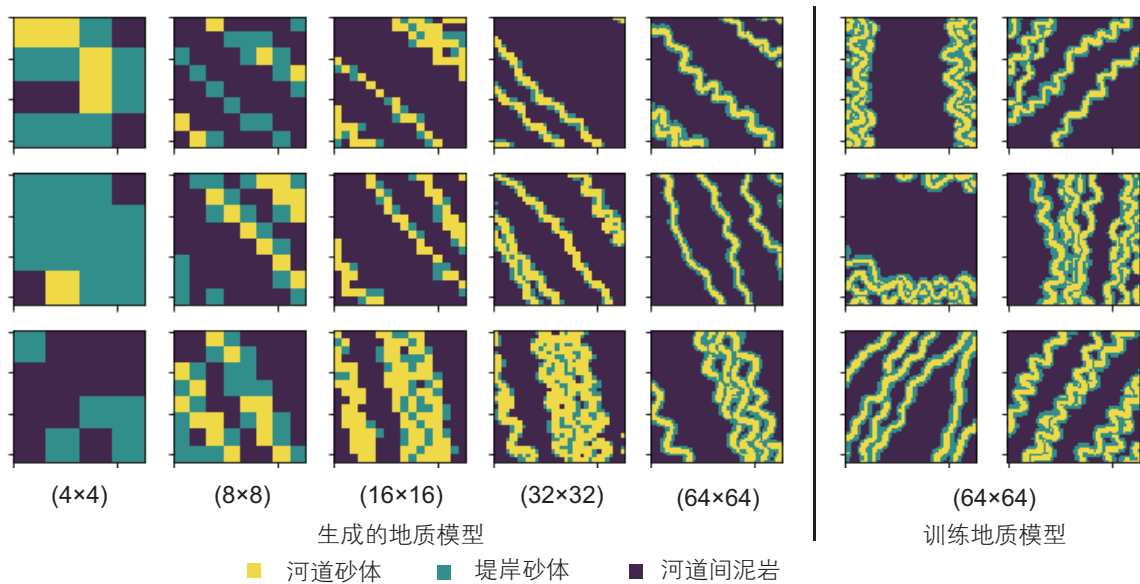


图5 渐进增长训练过程中模拟器生成的河道储层地质模型与训练地质模型对比<sup>[30]</sup>

Fig. 5 Comparison between the generated channel reservoirs during progressively training of the generator and the corresponding training facies models<sup>[30]</sup>

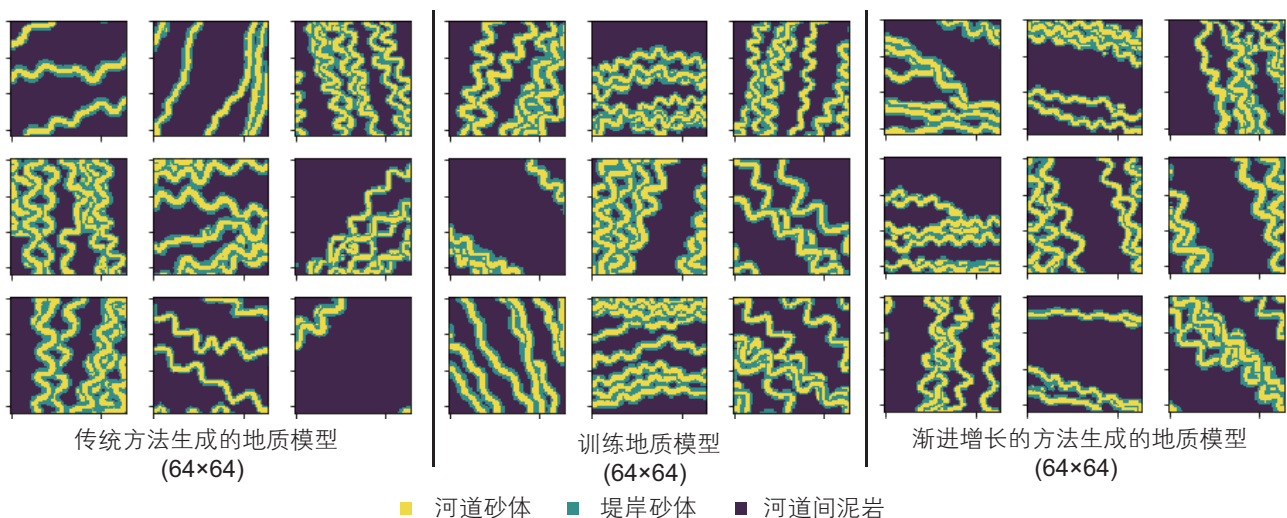


图6 渐进增长与传统生成对抗网络地质建模方法生成地质模型的对比<sup>[30]</sup>

Fig. 6 Comparison of the simulated reservoir geomodels between the progressive GANs training and the conventional GANs training approaches<sup>[30]</sup>

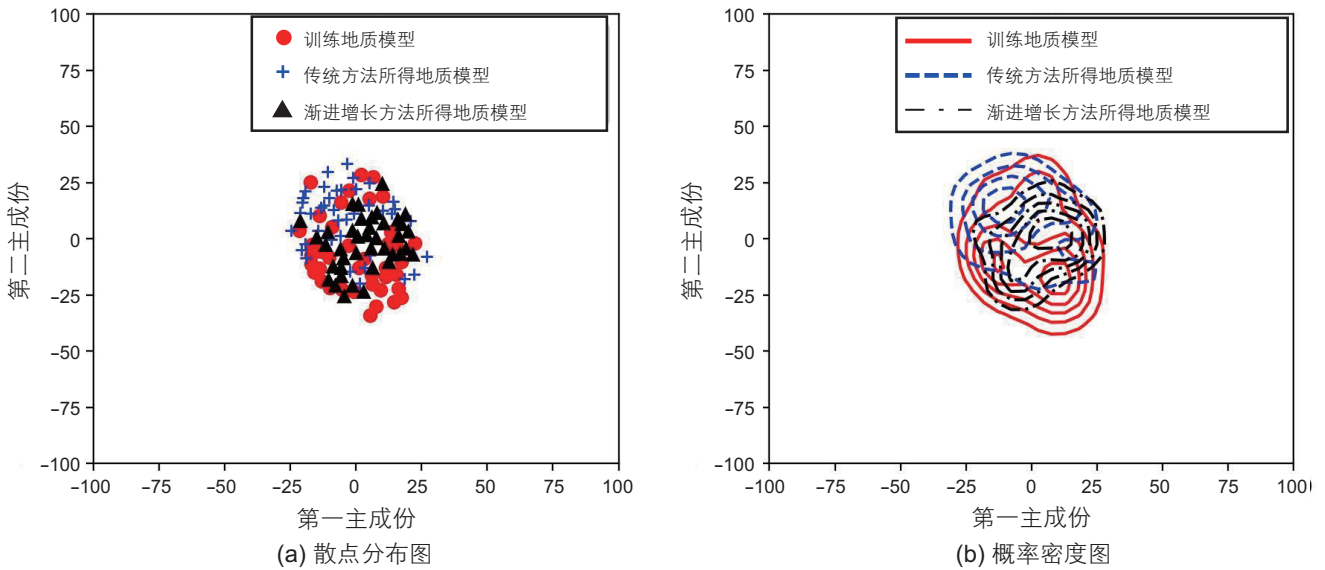


图 7 传统和渐进增长生成对抗网络地质建模方法所得的地质模型与训练地质模型之间关系的分布图<sup>[30]</sup>  
 Fig. 7 The relationship map among facies models generated from the conventional and progressive geomodeling methods and the training facies models<sup>[30]</sup>

可以看到，相比于传统建模方法，渐进增长方法产生的地质模型分布更接近训练地质模型分布，表明渐进增长方法产生的地质模型的地质模式与训练地质模型更吻合。

## 2 有条件约束的生成对抗网络地质建模方法

有条件约束的地质建模方法是在无条件约束方法的基础上发展而来的，本文把目前学术界关于有条件约束地质建模方法的研究成果归结为两大类：基于模拟器输入向量搜寻的条件化方法和模拟器直接条件化的地质建模方法。学术界对于前者的研究和应用较多<sup>[24-29]</sup>，后者则是为了解决前者存在的一般性缺陷，由 Song<sup>[31-32]</sup> 最新提出。

### 2.1 基于模拟器输入向量搜寻的条件化方法

#### 2.1.1 核心理念

在无条件约束的建模方法中，训练得到的模拟器可将任意低维向量生成为吻合特定地质模式的地质模型。这些地质模型分布在对应高维空间中的一个特定区域内，该区域内的每一个地质模型都与输入的低维向量一一对应，如图 8 所示。针对任意给定的条件数据(如井点数据)，在地质模型区域内必然存在一个小型区域(记为区域 1)，该区域内的所有地质模型均与该条件数据吻合。同时，在低维输入向量空间中也必然存在一个对应的区域(记为区域 2)，该区域内的向

量值可通过模拟器生成为区域 1 中的地质模型。条件约束地质建模的目的则是找出区域 1 中的地质模型。由于地质模型的维度远大于输入向量的维度，所以通常会去搜寻区域 2 中的向量值，然后通过模拟器将这些向量生成为区域 1 中的地质模型。

目前，在学术界存在两大类方法来寻找区域 2 中的向量值，一类是向量优化的方法，还有一类是神经网络映射的方法。在第一类方法中，首先构建一个目标函数，如式(1)，该目标函数反映了模拟器生成的地质模型与给定条件数据之间的差距；然后通过优化该目标函数中输入的低维向量  $z$  来最小化目标函数。常用的两种优化方法包括马尔科夫链蒙特卡洛方法(MCMC)<sup>[25,27,29]</sup>和梯度下降的方法<sup>[24,26]</sup>。每次优化只能寻找到一个位于区域 2 中的输入向量，通过模拟器可计算得到一个与条件数据吻合的地质模型(位于区域 1 内)。不确定性地质建模需要得到多个地质模型实现，因而需要进行多次优化，每次选择不同的初始值来获得多个合适的输入向量，这些向量通过模拟器则可生成多个与条件数据一致的地质模型。

$$O = \text{Dist} [ M [ G ( z ) ], \text{cond} ] \quad (1)$$

式中， $O$  为目标函数， $\text{Dist}$  为某种距离， $G$  为训练好的模拟器卷积神经网络， $z$  为输入的低维向量， $\text{cond}$  为给定的条件数据， $M$  为地质模型到条件数据的映射方程，比如针对井筒产量条件数据， $M$  即为储层渗流的正演方程，而针对井点条件数据， $M$  则为对地质模



型  $G(z)$  进行井点抽样的算子。

考虑到多次优化速度较慢且操作繁琐, Chan<sup>[28]</sup> 提出了神经网络映射的方法。具体来说, 针对给定的条件数据, 训练一个额外的小型神经网络, 将一个已知区域(如 0 至 1 的区域)映射到区域 2 上, 如图 8。此

时, 该已知区域内的任意数值都可通过这个额外的神经网络转化成区域 2 内的输入向量, 进而通过模拟器生成与条件数据一致的地质模型(位于区域 1 内)。这样, 便可同时获得大量模型实现。

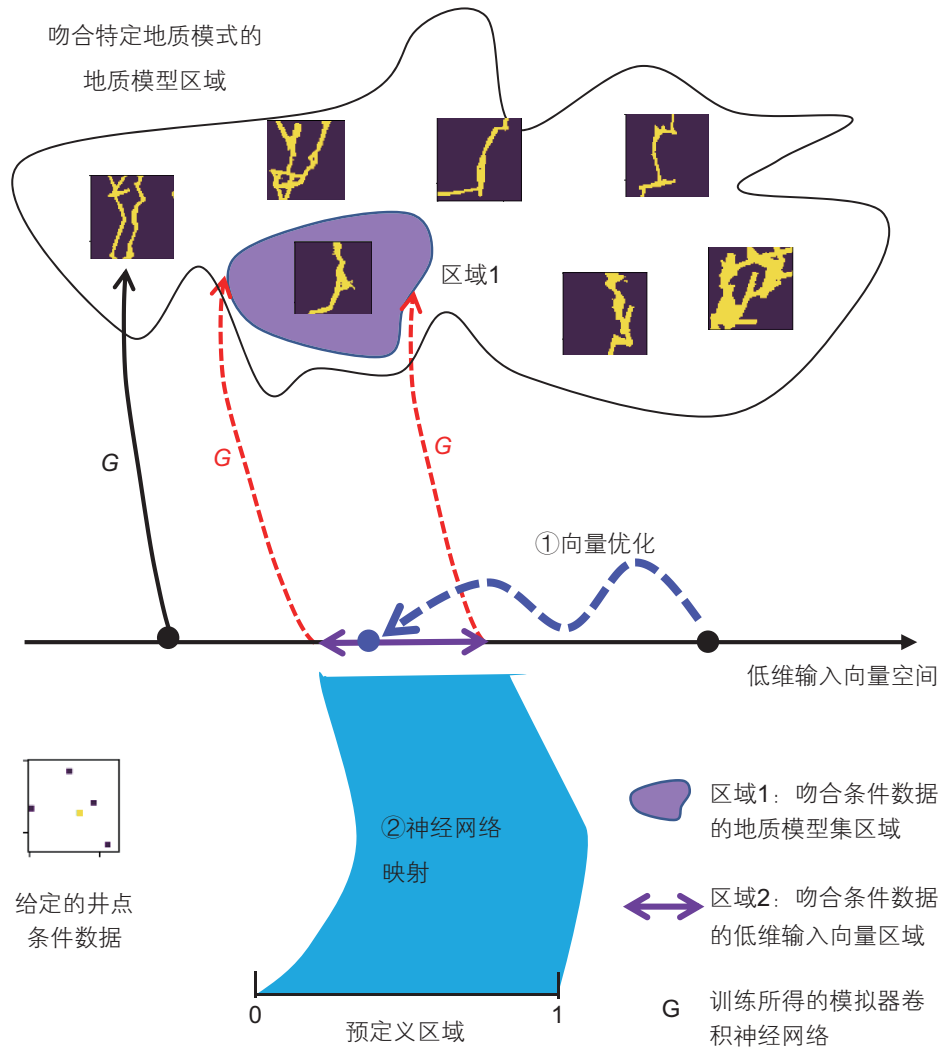


图 8 基于模拟器输入向量搜寻的条件化方法示意图

Fig. 8 Schematic diagram of conditioning approach based on searching of the input latent vector of the trained generator

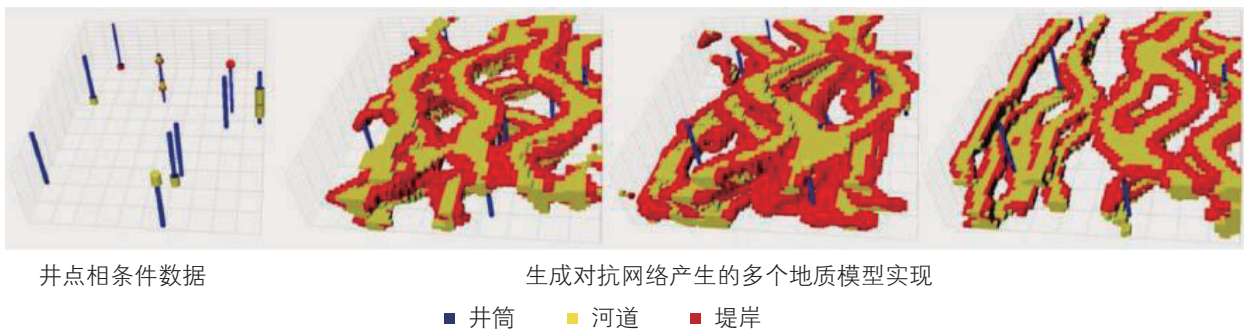


图 9 基于梯度下降方法产生的与给定井点条件数据一致的多个三维河道储层地质模型实现<sup>[26]</sup>

Fig. 9 Multiple 3D channel reservoir geomodels conditioned to given well data produced by gradient descent approach<sup>[26]</sup>

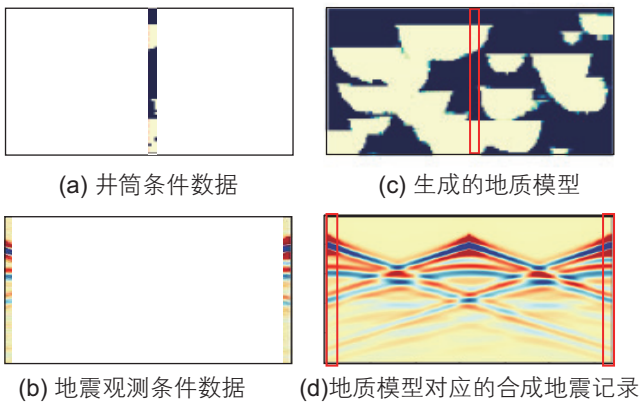


图 10 (a)和(b)为井筒解释和地震观测条件数据, (c)为井筒和地震数据约束的地质模型, (d)为由地质模型正演而来的合成地震记录<sup>[29]</sup>

Fig. 10 (a) and (b) are the observed well interpretation and partial seismic conditioning data, (c) is a produced geomodel conditioned to the given well and seismic data, (d) is the seismic data synthesized from the geomodel in (c) using forward modelling<sup>[29]</sup>

### 2.1.2 应用效果分析

图 9 为 Zhang<sup>[26]</sup>应用梯度下降方法产生的井筒数据约束的三维河道储层地质模型实现, 模型实现与井点数据完全吻合<sup>[26]</sup>。图 10 为 Mosser<sup>[29]</sup>应用马尔科夫链蒙特卡洛方法得到的井筒和地震数据共同约束的河道储层纵切片二维地质模型; 其中, 地质模型与井筒数据完全吻合, 由地质模型正演而来的合成地震记录也与地震观测条件数据完全一致。Zhang<sup>[26]</sup>还通过实例证实了生成对抗网络方法相比于多点地质统计学建模方法在地质模式复现上的优越性。

## 2.2 模拟器直接条件化的地质建模方法

基于模拟器输入向量搜寻的条件化方法最大的问题就是: 每次针对一个新的井区或新的条件数据时, 需要重新去寻找合适的向量值, 而寻找的过程比较繁琐耗时、且需要较大的算力。因而, Song<sup>[31-32]</sup>在渐进增长生成对抗网络地质建模的基础上提出了模拟器直接条件化的地质建模方法(GANSim)。

### 2.2.1 核心思想

模拟器直接条件化的地质建模方法(GANSim)的提出主要受“地质专家手绘沉积相图”这一过程的启发: 给定特定条件数据(如井点数据), 地质专家可以直接画出既吻合地质模式又与给定条件数据一致的沉积相图, 而无需专门的条件化操作; 这是因为地质专家的大脑中除了保存地质模式知识以外, 还有条件数据与地质模型之间关系的知识(即条件数据对地质模

型约束规则的知识)。与地质专家相类比, 在无条件约束情况下训练所得的模拟器只学习到了地质模式知识, 还欠缺条件数据与地质模型之间关系的知识。那么, 能否让模拟器在学习地质模式知识的同时还学习到这种关系知识呢? 这样, 当把任意实际地质条件数据输入到模拟器中时, 模拟器便可以像地质专家一样, 直接生成吻合输入条件数据和特定地质模式的地质模型, 而无需对模拟器的输入向量进行繁琐的搜寻操作。这便是模拟器直接条件化地质建模的核心思想。

具体来说, 如图 11 所示, 首先设计条件数据输入模拟器的接口结构, 把条件数据和低维随机向量一起输入到模拟器中; 然后定义专门的条件损失函数, 生成对抗网络原损失函数促使模拟器学习地质模式知识(进行无条件约束的地质建模), 而条件损失函数则促使模拟器学习条件数据与生成地质模型之间关系的知识。最终训练得到的模拟器便可将任意条件数据直接生成成为同时吻合地质模式知识和输入条件的地质模型。

Song<sup>[31-32]</sup>和宋随宏<sup>[42]</sup>分别就条件类型为全局特征变量(如相比例、河道弯曲度、河道宽度)、离散井点数据和地球物理解释的概率体数据的情况, 形成了这几类条件数据单独约束以及联合约束的模拟器直接条件化地质建模方法。

### 2.2.2 应用效果分析

Song<sup>[31-32]</sup>将模拟器直接条件化的地质建模方法应用于河道宽度和弯曲度、泥岩相比例、井点以及概率图多类条件约束的河流相水平切片二维地质建模, 取得了非常好的效果。比如在图 12(a)中, 将泥岩比例、井点数据、河道堤岸复合体概率图和低维随机向量共同输入到训练好的模拟器中, 生成的地质模型与所有条件数据和对应地质模式都非常吻合, 当输入的随机向量发生任意变化时, 模拟器则可生成不同的地质模型实现(图 12(a)中地质模型的每一列对应一个不同的输入向量)。在图 12(b)中, 保持输入的井点数据和概率图不发生变化(与图 12(a)中一致), 只改变输入的泥岩比例数值, 生成的地质模型也相应地发生改变, 即从左到右地质模型中的河道数量逐渐减少。

宋随宏<sup>[42]</sup>将该方法应用于塔河油田奥陶系暗河溶洞储集体的不确定性三维地质建模。基于 2 万多个训练数据( $64 \times 64 \times 64$ ), 应用 4 块 GPU(NVIDIA Tesla V100-PCIe-32GB)耗时 25 个小时训练得到针对塔河暗河溶洞储层的三维地质模型( $64 \times 64 \times 64$ )模拟器。如图 13 所示, 将塔河油田 TK6112 井区的井筒解释、地震所得溶洞概率体和一个低维随机向量一起输入到训练好的模拟器中, 任意改变随机向量的数值大小则




图 11 模拟器直接条件化的地质建模方法示意图<sup>[31]</sup>

Fig. 11 Schematic diagram of the direct conditioning approach based on GANs (GANSim)<sup>[31]</sup>

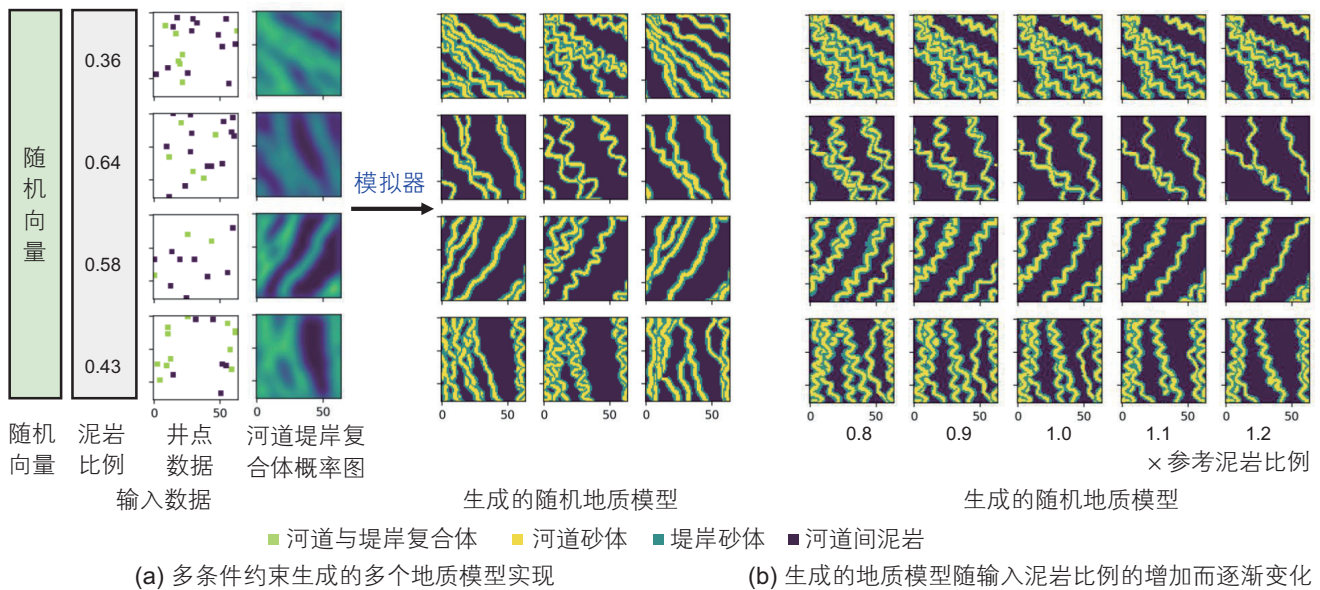


图 12 泥岩比例、井点数据和概率图共同约束的河流相水平切片二维地质模型<sup>[32]</sup>

Fig. 12 2D GANSim-produced 2D channel reservoirs conditioned to mud proportion, well data, and probability maps<sup>[32]</sup>

可产生不同的三维地质模型实现。这些实现与输入的井筒解释数据吻合率为 100%，与概率体数据也非常

吻合；生成的暗河溶洞在形态、走向等方面也与研究区的地质认识非常一致，如厅堂洞的发育、阶梯状的

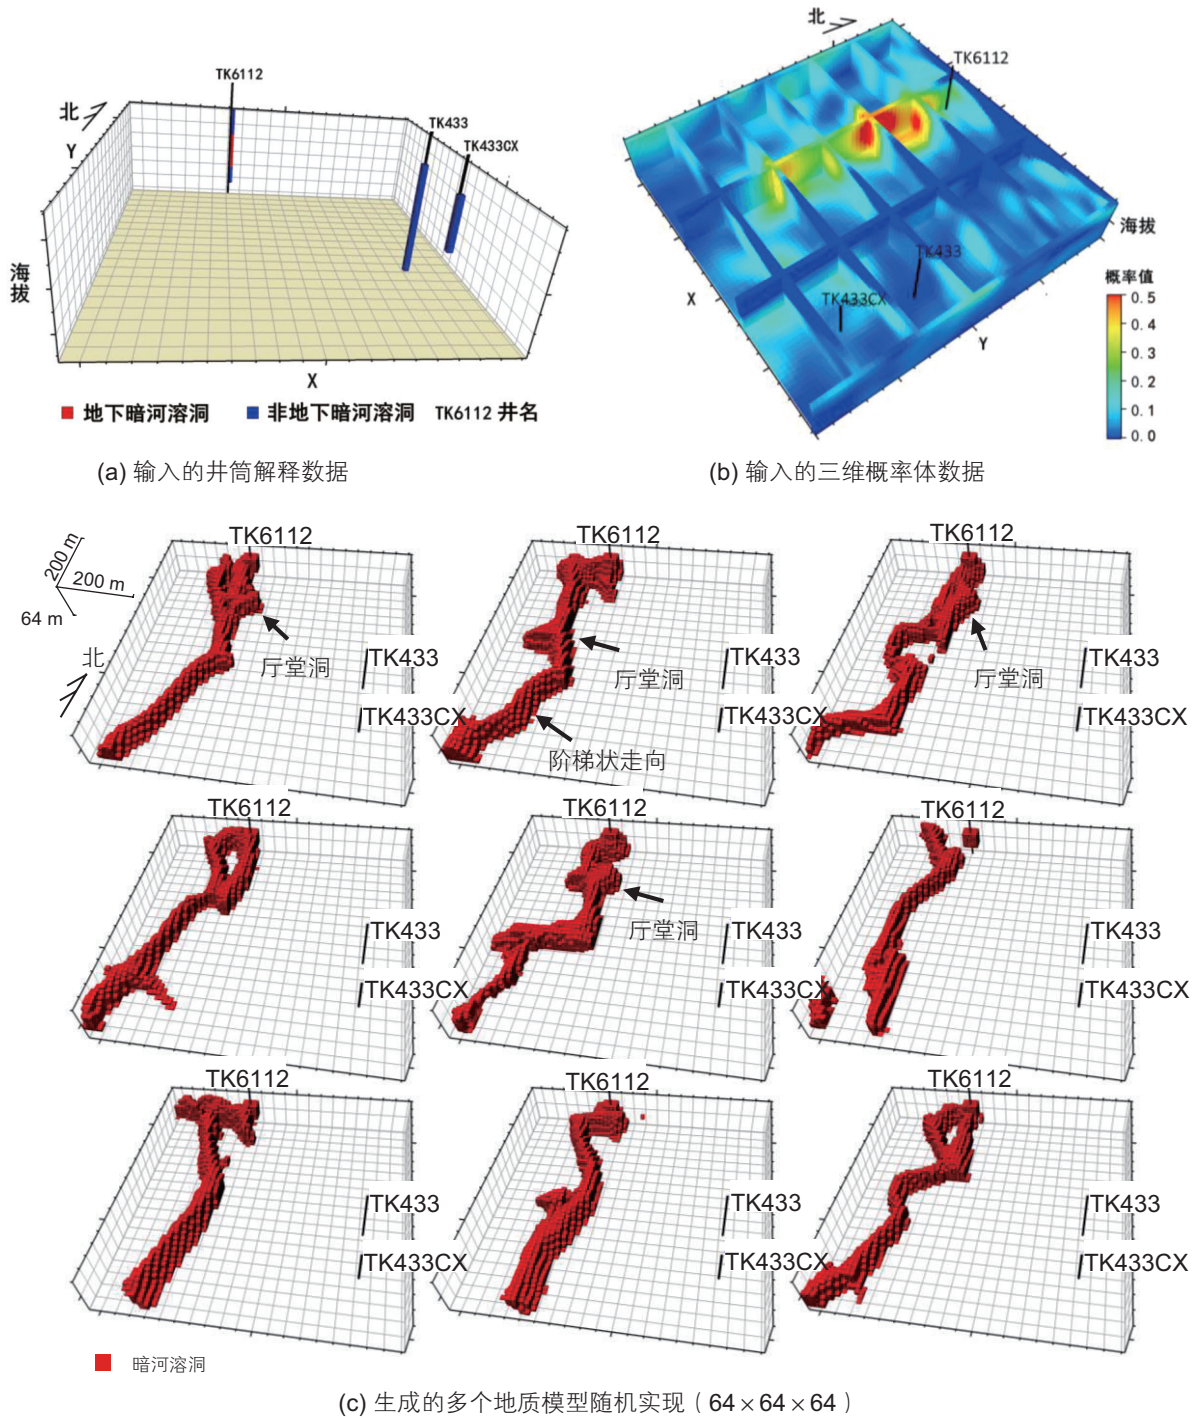


图 13 塔河油田 TK6112 井区井筒和地震概率体数据共同约束的暗河溶洞储集体三维地质建模 (储层大小为 800 m × 800 m × 64 m, 网格数为 64 × 64 × 64)<sup>[42]</sup>

Fig. 13 GANSim-produced 3D geomodels of the underground river karst cave reservoir in TK6112 well block of Tahe Oilfield conditioned to well data and seismic probability maps (the size of the reservoir is 800 m × 800 m × 64 m and the cell number of each geomodel is 64 × 64 × 64)<sup>[42]</sup>

形态以及 NNE、NNW 和近 EW 的溶洞段走向。

Song<sup>[43]</sup> 进一步改进该方法形成 GANSim-3D 框架, 来让模拟器直接产生任意尺寸的三维地质模型, 其核心在于保证模拟器中只包含卷积神经网络层 (剔除全

连接层)。如图 14 所示, 训练所得的模拟器则可针对任意大小的实际储层, 将井筒解释和地震概率体数据生成为多个对应的三维地质模型实现。同样, 这些实现既吻合实际地质模式特征也与输入的条件数据一致,

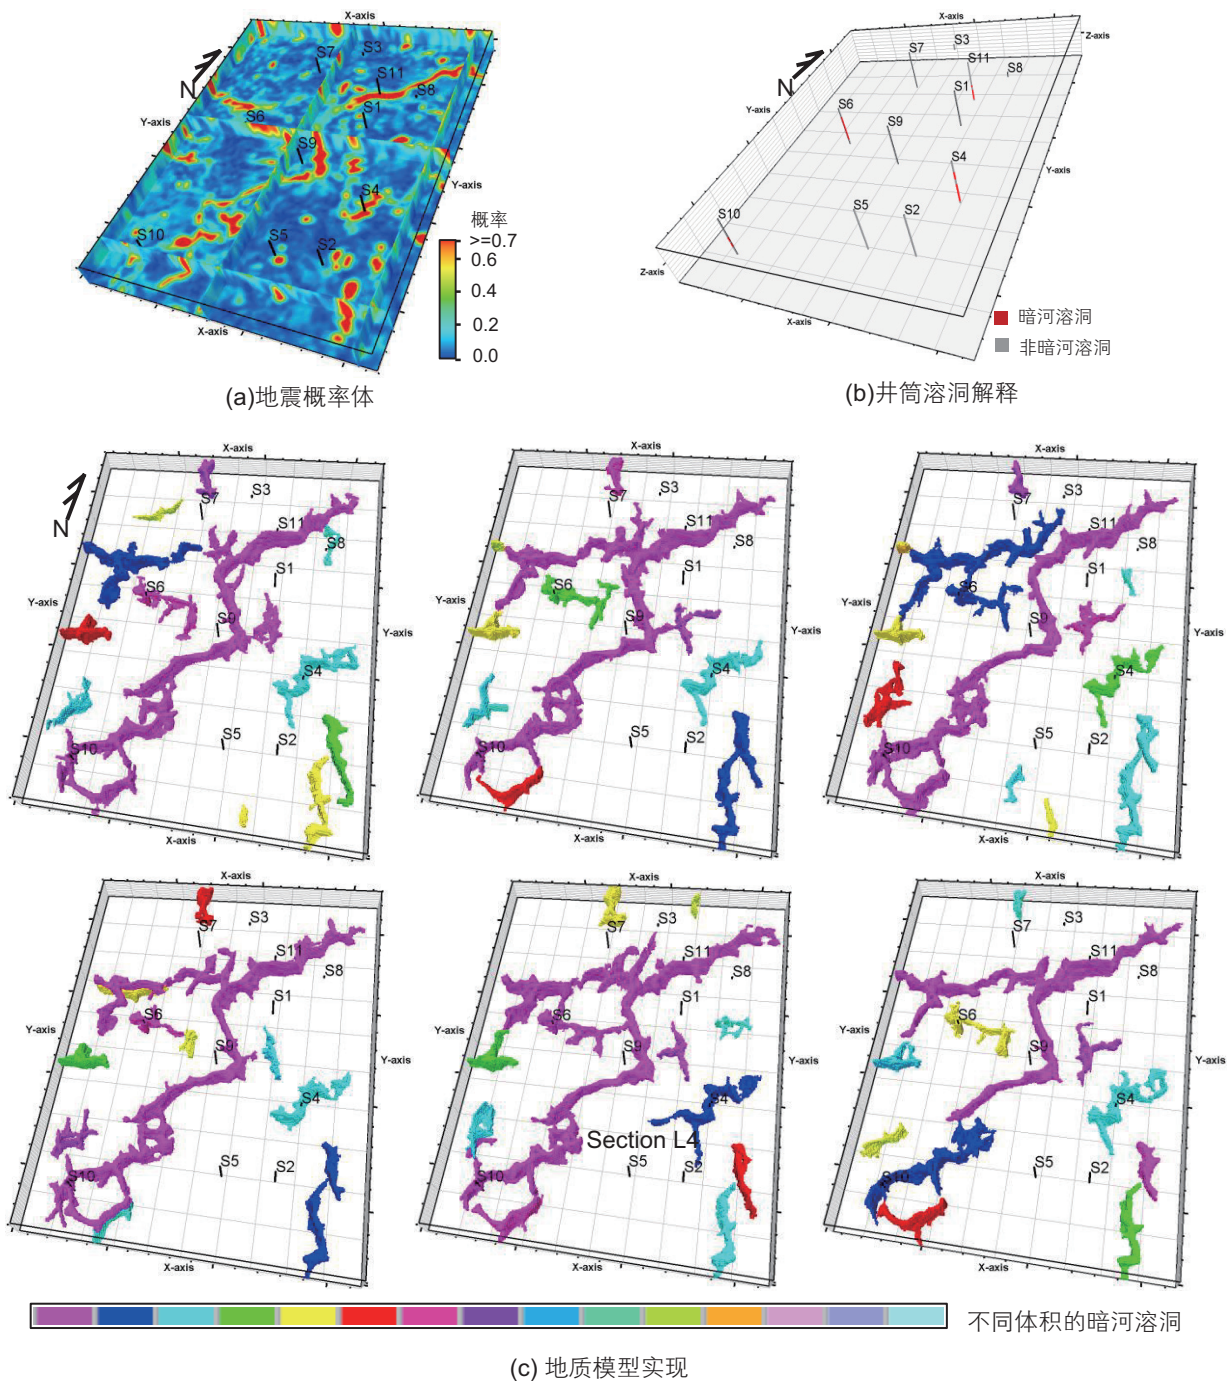


图 14 塔河油田某大型区块井筒和地震概率体数据共同约束的三维地质建模(储层大小为  $4200\text{ m} \times 3200\text{ m} \times 96\text{ m}$ , 网格数为  $336 \times 256 \times 96$ )<sup>[43]</sup>

Fig. 14 GANSim-produced 3D geomodels of the underground river karst cave reservoir in a large block of Tahe Oilfield conditioned to well data and seismic probability maps (the size of the reservoir is  $4200\text{ m} \times 3200\text{ m} \times 96\text{ m}$  and the cell number of each geomodel is  $336 \times 256 \times 96$ )<sup>[43]</sup>

地震概率体中的噪声被有效地压制, 模拟速度也非常快: 一个网格为  $336 \times 256 \times 96$  的三维地质模型只需  $0.988\text{ s}$  来产生。

相比于基于模拟器输入向量搜寻的条件化方法, 模拟器直接条件化的地质建模方法在操作的简便性和

耗时上具有明显的优势; 其缺点在于目前还无法实现地震及生产动态等间接条件数据的直接约束, 而基于模拟器输入向量搜寻的条件化方法却可以实现这些数据的约束。当然, 两种方法也可以结合使用, 在模拟器实现井点等数据直接条件化的基础上, 应用输入向

量搜寻的方法实现间接条件数据的约束。

### 3 结论及展望

#### 3.1 结论

(1)生成对抗网络地质建模方法可以很好地复现地质体的空间模式特征,其模拟效果优于多点地质统计学建模方法。

(2)无条件约束时,渐进增长生成对抗网络地质建模方法在地质模型模拟器训练时间和模拟效果上都优于传统生成对抗网络地质建模方法。

(3)模拟器直接条件化的建模方法在操作便捷性和建模速度上远优于基于模拟器输入向量搜寻的条件化方法,已形成了全局变量(如河道弯曲度、相比例)、井点和概率体约束的模拟器直接条件化地质建模方法;但目前,前者无法实现地震及生产数据等间接条件数据的约束,而后者可以实现。

#### 3.2 展望

(1)模拟器直接条件化的地质建模方法(GANSim和GANSim-3D)是一个开放的方法体系,可通过进一步深入研究,将地质力学、原始地震、生产动态以及原始沉积水动力等间接数据融合进来作为条件数据,实现对地质建模全方位多角度的综合约束,以最大限度地降低储层预测的不确定性。

(2)生成对抗网络地质建模方法虽然在训练模拟器时需要构建大量的训练地质模型并且需要在多块高端GPU上训练较长的时间(如图13的例子中应用4块Tesla V100 GPU耗时25小时),但是这些工作都只需完成一次即可,而训练所得的模拟器却可以在任何相

似地质模式区进行无数次应用。考虑到GPU的市场价格,石油公司、科研单位或个人有能力进行生成对抗网络地质建模方法的大规模研究和应用。

(3)从工业落地应用的角度来看,有如下两个问题需要重点关注:一个是如何获得大量能够代表真实地下储层的训练数据(训练地质模型)?基于过程的方法能捕捉地质体不同尺度的细节,但对于很多地质过程的认识尚不清楚,且运算速度过慢需要消耗大量运算资源;针对具体储层特征,研究专门的基于目标或基于仿过程的模拟方法或是解决训练数据问题的重要思路。另一个问题是自然界的储层类型非常多样,是否要构建针对每种储层类型的地质模型模拟器,而又该如何划分储层类型?笔者的一个不成熟的想法是:能否构建一个针对全球各种储层类型、放之四海而皆准的大型地质模型模拟器,那么在未来工程师只须将目标区块的条件数据和储层类型等基础数据上传云端,便可在几秒内传回大量可能的地质模型实现和不确定性分析结果。目前,人类已经在语言等领域构建了诸多千百亿参数的人工智能“大模型”(如GPT-3、鹏城-百度·文心等),获得了极为出色的效果,此处所提的“模拟器大模型”或是地学领域一个重要、可实现、具有巨大应用和商业潜力的努力方向。

(4)从地质知识的角度来看,模拟器实际上是把抽象的地质模式知识(和条件对地质模型的约束规则知识)以定量参数(即神经网络参数)的形式保存下来,形成可灵活操纵和应用的数字化知识。这些数字化知识除了直接应用于本文所述的地质建模以外,或许还可通过神经网络迁移学习等方式应用于其它实践,并为“地学知识数字化”相关课题的研究提供重要的借鉴和实践意义。

### 参考文献

- [1] 张文彪,段太忠,刘彦锋,等. 定量地质建模技术应用现状与发展趋势[J]. 地质科技情报, 2019, 38(3): 264-275. [ZHANG W B, DUAN T Z, LIU Y F, et al. Application status and development trend of quantitative geological modeling [J]. Geological Science and Technology Information, 2019, 38(3): 264-275.]
- [2] JOURNEL A G, ALABERT F G. New method for reservoir mapping[J]. Journal of Petroleum Technology, 1990, 42(2): 212-228.
- [3] BEUCHER H, GALLI A, LE L, et al. Including a regional trend in reservoir modelling using the truncated Gaussian method[G]// Geostatistics Tróia '92: 1. Springer, 1993, 01: 555-566.
- [4] HALDORSEN H H, LAKE L W. A new approach to shale management in field-scale models[J]. Society of Petroleum Engineers Journal, 1984, 24(04): 447-457.
- [5] CLEMETSEN R, HURST A R, KNARUD R, et al. A computer program for evaluation of fluvial reservoirs[G]//North Sea Oil and Gas Reservoirs—II. Springer, 1990: 373-385.
- [6] DAMSLETH E, TJOLSEN C B, OMRE H, et al. A two-stage stochastic model applied to a north sea reservoir[J]. Journal of Petroleum

- Technology, 1992, 44(04): 402–486.
- [7] SUN T, MEAKIN P, JOSSANG T, et al. A simulation model for meandering rivers[J]. *Water resources research*, 1996, 32(9): 2937–2954.
- [8] DEUTSCH C V, BEGG S H. The use of ranking to reduce the required number of realizations[J]. *Centre for Computational Geostatistics (CCG) Annual Report*, 2001, 3: 3–15.
- [9] PYRCZ M J, DEUTSCH C V. *Geostatistical reservoir modeling*[M]. Oxford: Oxford University Press, 2014.
- [10] STREBELLE S. Conditional simulation of complex geological structures using multiple-point statistics[J]. *Mathematical Geology*, 2002, 34(1): 1–21.
- [11] ARPAT G B, CAERS J. A Multiple-scale, pattern-based approach to sequential simulation[G]//*Geostatistics Banff 2004*, Springer, 2005: 255–264.
- [12] ZHANG T, SWITZER P, JOURNEL A. Filter-based classification of training image patterns for spatial simulation[J]. *Mathematical Geology*, 2006, 38(1): 63–80.
- [13] TAHMASEBI P. Structural adjustment for accurate conditioning in large-scale subsurface systems[J]. *Advances in Water Resources*, 2017, 101: 60–74.
- [14] MARIETHOZ G, RENARD P, STRAUBHAAR J. The direct sampling method to perform multiple-point geostatistical simulations[J]. *Water Resources Research*, 2010, 46(11): 1–14.
- [15] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[C]//*International Conference on Neural Information Processing Systems*. Montréal, 2014: 2672–2680.
- [16] LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. *Neural Computation*, 1989, 1(4): 541–551.
- [17] KARRAS T, AILA T, LAINE S, et al. Progressive growing of GANs for improved quality, stability, and variation[J]. *arXiv preprint arXiv: 1710.10196*, 2017.
- [18] KARRAS T, LAINE S, AILA T. A style-based generator architecture for generative adversarial Networks[C]//*IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 2018: 4401–4410.
- [19] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//*IEEE International Conference on Computer Vision*, Venice, 2017: 2223–2232.
- [20] LEDIG C, THEIS L, HUSZAR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//*IEEE conference on computer vision and pattern recognition*, Las Vegas, 2016: 4681–4690.
- [21] LEINONEN J, GUILLAUME A, YUAN T. Reconstruction of cloud vertical structure with a Generative Adversarial Network[J]. *Geophysical Research Letters*, 2019, 46(12): 7035–7044.
- [22] MOSSER L, DUBRULE O, BLUNT M J. Stochastic reconstruction of an oolitic limestone by Generative Adversarial Networks[J]. *Transport in Porous Media*, 2018, 125(1): 81–103.
- [23] CHAN S, ELSHEIKH A H. Parametrization and generation of geological models with Generative Adversarial Networks[J]. *arXiv preprint arXiv: 1708.01810*, 2017.
- [24] DUPONT E, ZHANG T, TILKE P, et al. Generating realistic geology conditioned on physical measurements with Generative Adversarial Networks[J]. *arXiv preprint arXiv: 1802.03065*, 2018.
- [25] LALOY E, HERAULT 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.
- [26] 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.
- [27] NESVOLD E, MUKERJI T. Simulation of fluvial patterns with GANs trained on a data set of satellite imagery[J]. *Water Resources Research*, 2021, 57(5): 1–20.
- [28] CHAN S, ELSHEIKH A H. Parametric generation of conditional geological realizations using generative neural networks[J]. *Computational Geosciences*, 2019, 23(5): 925–952.
- [29] MOSSER L, DUBRULE O, BLUNT M J. Stochastic seismic waveform inversion using Generative Adversarial Networks as a geological prior[J]. *Mathematical Geosciences*, 2020, 52(1): 53–79.
- [30] SONG S, MUKERJI T, HOU J. Geological facies modeling based on progressive growing of Generative Adversarial Networks (GANs)[J]. *Computational Geosciences*, 2021, 25: 1251–1273.
- [31] SONG S, MUKERJI T, HOU J. GANSim: Conditional facies simulation using an improved progressive growing of Generative Adversarial Networks (GANs)[J]. *Mathematical Geosciences*, 2021, 53: 1413–1444.
- [32] SONG S, MUKERJI T, HOU J. Bridging the gap between geophysics and geology with Generative Adversarial Networks (GANs)[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60.

- [33] 刘彦锋, 张文彪, 段太忠, 等. 深度学习油气藏地质建模研究进展[J]. 地质科技通报, 2021, 40(04): 235–241. [LIU Y F, ZHANG W B, DUAN T Z, et al. Progress of deep learning in oil and gas reservoir geological modeling [J]. Bulletin of Geological Science and Technology, 2021, 40(04): 235–241.]
- [34] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional Generative Adversarial Networks[J]. arXiv preprint arXiv: 1511.06434, 2015.
- [35] KARRAS T, LAINE S, AITTALA M, et al. Analyzing and improving the image quality of stylegan[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 8110–8119.
- [36] DUMOULIN V, BELGHAZI I, POOLE B, et al. Adversarially learned inference[J]. arXiv preprint arXiv: 1606.00704, 2016.
- [37] MOGREN O. C-RNN-GAN: Continuous recurrent neural networks with adversarial training[J]. arXiv preprint arXiv: 1611.09904, 2016.
- [38] WU J, ZHANG C, XUE T, et al. Learning a probabilistic latent space of object shapes via 3D Generative-Adversarial Modeling[C]//Conference on Neural Information Processing Systems, Barcelona, 2016: 82–90.
- [39] LUCIC M, KURACH K, MICHALSKI M, et al. Are GANs created equal? A large-scale study[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, Hawaii, 2017: 2467–2476.
- [40] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN[C]//International Conference on Machine Learning, Sydney, 2017: 214–223.
- [41] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C]//International Conference on Neural Information Processing Systems, Long Beach California, 2017: 5769–5779.
- [42] 宋随宏. 基于卷积神经网络的岩溶储集体随机建模方法研究[D]. 北京: 中国石油大学(北京), 2021. [SONG S S. Karst reservoir geomodelling method based on convolutional neural network[D]. Beijing: China University of Petroleum –Beijing, 2021.]
- [43] SONG S, MUKERJI T, HOU J, et al. GANSim–3D for conditional geomodelling: Theory and field application[J]. Earth arXiv: 10.31223/X5FK8B, 2021.

(责任编辑 刘冬冬 编辑 付娟娟)