

DOI: 10.51790/2712-9942-2020-1-3-4

ГЕНЕРАЦИЯ ТРЁХМЕРНЫХ ПОРИСТЫХ СТРУКТУР

Э. М. Камилов¹, А. А. Егоров²

Сургутский государственный университет, г. Сургут, Российская Федерация
Федеральный научный центр Научно-исследовательский институт системных исследований
Российской академии наук, г. Москва, Российская Федерация
¹ *erkimkamilov@gmail.com*, ² *eaafit@gmail.com*

Аннотация: разработана сверточная генеративно-сопоставительная нейронная сеть, генерирующая объемные изображения пористых сред (горной породы). Рассматриваются возможности модификации нейронной сети для генерации пористых сред с заданными характеристиками: коэффициент пористости, проницаемости, состав и размеры зерен, каналов и каверн.

Ключевые слова: цифровой керн, коллектор углеводородов, нейронная сеть, генеративно-сопоставительная сеть, пористые среды, пористость.

Для цитирования: Камилов Э. М., Егоров А. А. Генерация трёхмерных пористых структур. *Успехи кибернетики*. 2020;1(3):33–40. DOI: 10.51790/2712-9942-2020-1-3-4.

3D POROUS STRUCTURE IMAGE GENERATION

Erkin M. Kamilov¹, Alexander A. Egorov²

Surgut State University, Surgut, Russian Federation
Scientific Research Institute for System Analysis of the Russian Academy of Sciences,
Moscow, Russian Federation
¹ *erkimkamilov@gmail.com*, ² *eaafit@gmail.com*

Abstract: in this study, a convolutional generative adversarial neural network generating 3D images of porous media (rock) was developed. The neural network can be modified to generate porous media with specific properties such as porosity factor, permeability factor, composition and sizes of the grains, channels, and voids.

Keywords: digital core, hydrocarbon reservoir, neural network, generative adversarial network, porous media, porosity.

Cite this article: Kamilov E. M., Egorov A. A. 3D Porous Structure Image Generation. *Russian Journal of Cybernetics*. 2020;1(3):33–40. DOI: 10.51790/2712-9942-2020-1-3-4.

В настоящее время математическое моделирование широко используется для анализа разработки и эксплуатации нефтяных и газовых месторождений. К задачам, которые возникают в этой области, относятся разработка и обоснование плана разработки месторождения, определение оптимального способа воздействия на пласт с целью увеличения нефтеотдачи и прогнозирования. Стандартные методы оценки параметров пласта — это геофизические и гидродинамические методы исследования скважин, лабораторные исследования керна.

Лабораторные исследования керна являются одним из важнейших методов исследования и позволяют определять большое количество физических свойств образцов: пористость, абсолютную и относительную фазовые проницаемости. Указанные методы имеют ряд недостатков, среди которых: сложность получения и обработки качественного стержневого материала в достаточном количестве; высокая стоимость и практическая невозможность массового применения ряда методик лабораторных исследований; невозможность проведения множественных экспериментов на одном образце, невозможность воспроизводимости результатов исследования.

Современной технологией, позволяющей повысить точность описания свойств системы взаимодействия флюидов и горной породы, является подход, называемый «цифровым ядром» [1]. Характерным свойством этого подхода вне зависимости от физики исследуемого объекта является детальное разрешение геометрической структуры порового пространства. В основе подхода лежит прямое

математическое моделирование процессов, происходящих в пласте на микроуровне, которое определяет как результаты макроскопических лабораторных экспериментов, так и динамику фильтрационных процессов в масштабах месторождения. В то же время сам подход позволяет устранить ряд сформулированных выше недостатков лабораторных исследований [2].

Тем не менее даже в процессе оцифровки керна происходят необратимые изменения его структуры вследствие механического воздействия при его разрезе и саморазрушения [3]. На рис. 1 представлено сравнение плотности образца керна на различных срезах.




Рис. 1. Срез томографии керна, слева № 105, справа № 200 [3]

Целью данной работы является разработка программы для создания искусственной модели пористой среды с использованием нейронной сети, обученной на выборке из реальных компьютерных микротомографий проб керна. Основной задачей эксперта, формирующего обучающую выборку, является отбор качественных данных небольшого объема, достаточного для обучения нейронной сети.

Генеративно-сопоставительная сеть

Генеративно-сопоставительная сеть (англ. Generative Adversarial Networks, далее GAN) — алгоритм машинного обучения без учителя, построенный на комбинации из двух нейронных сетей, одна из которых (сеть G, генератор) генерирует образцы на основе вектора параметров и нормализованного вектора шума, а другая (сеть D, дискриминатор) старается отличить правильные («подлинные») образцы от неправильных [4]. Так как сети G и D имеют противоположные цели — создать образцы и отбраковать образцы, между ними возникает игра с нулевой суммой.

Каждая нейронная сеть стремится минимизировать собственную ошибку. Генератор узнает свою ошибку из классификации дискриминатора. В оригинальной статье, описывающей GAN, в качестве функции ошибки дискриминатора используется формула перекрестной энтропии. При рассмотрении нейронной сети в целом получается функция, которую генератор стремится минимизировать, а дискриминатор — максимизировать:

$$E_x[\log(D(x))] + E_z[\log(1 - D(G(z)))], \quad (1)$$

где

- z — нормализованный вектор шума;
- x — реальные данные;
- $G(z)$ — данные, сгенерированные генератором;
- $D(x)$ — классификация дискриминатором для реальных данных;
- $D(G(z))$ — классификация дискриминатором для сгенерированных данных;
- E_x — ожидаемое значение для всех реальных экземпляров данных.

Генератор не может напрямую влиять на член $E_x[\log(D(x))]$, поэтому для генератора минимизация ошибки эквивалентна минимизации члена $E_z[\log(1 - D(G(z)))]$ (рис. 2).

Недостатки оригинальной архитектуры GAN

В процессе работы возникли сложности, связанные с чувствительностью генеративно-сопоставительной нейронной сети к конфигурации гиперпараметров, что приводило к невозможности

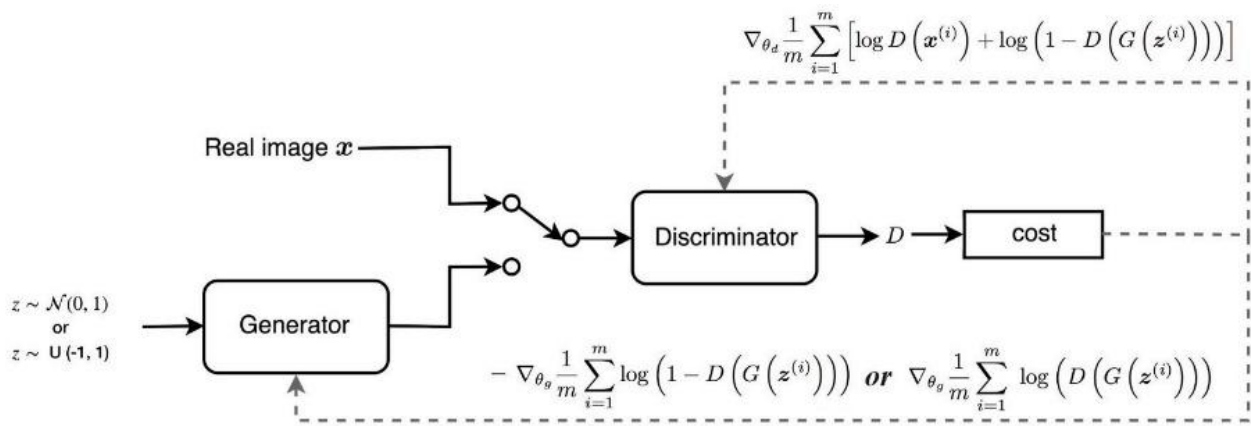


Рис. 2. Архитектура и обратное распространение ошибки в GAN [5]

обучения или длительному подбору настроек. Это связано с известными проблемами при использовании оригинальной архитектуры GAN.

1. Исчезновение градиентов обучения

Исчезновение градиентов обучения — проблема, связанная с использованием сигмоиды в качестве функции активации на выходе дискриминатора.

Сигмоида необходима для формирования выходного сигнала в диапазоне (0;1), чтобы обеспечить бинарную классификацию для перекрестной энтропии. При стремлении значения выхода сигмоиды к одной из асимптот (0 или 1) ее производная стремится к 0, вследствие чего нейронная сеть не получает градиенты для обучения. Это заставляет разработчика нейронной сети конфигурировать архитектуру так, чтобы значение сигмоиды на как можно большем протяжении обучения находилось равноудаленно от асимптот, где производная сигмоиды максимальна (рис. 3).




Рис. 3. График сигмоиды и ее производной (фото авторов)

2. Низкое качество для большой разрешающей способности

Для больших разрешений изображений необходимо увеличивать размерности слоев и глубину нейронной сети. Работа алгоритма обратного распространения ошибки не позволяет слоям, далеким от выхода сети обновляться так же интенсивно, как слоям, близким к выходу. Это приводит к медленному обучению нейронной сети и некачественным изображениям на выходе.

3. Коллапс генератора

Задача генератора — обмануть дискриминатор, научившись воспроизводить изображения из реальной выборки. Но изображения из реальной выборки имеют разную сложность для воспроизведения, и генератор всегда стремится выбрать те изображения для воспроизведения, которые легче подделать. Это приводит к постепенному сужению разнообразия генерируемых изображений в процессе обучения.

Модификации GAN

1. Deep convolutional GAN

Модификация Deep convolutional GAN (DCGAN) [6] использует архитектуру сверточной нейронной сети для обработки изображений в скрытых слоях. Использование сверточной нейронной сети значительно повышает качество и скорость обучения для сети, обрабатывающей изображения.

2. Wasserstein GAN

Модификация Wasserstein GAN (WGAN) [7] использует расстояние Вассерштейна в качестве функции дискриминатора. Это позволяет использовать линейную активацию на выходе дискриминатора, что решает проблему исчезающих градиентов ценой увеличения времени на одну итерацию, связанную со сложностью вычисления ошибки и дополнительными итерациями дискриминатора. В работе используется модификация с градиентным штрафом WGAN-GP [8].

3. Progressive growing of GANs

Модификация Progressive growing of GANs (PGGAN, постепенный рост GAN) [9] постепенно увеличивает слои нейронной сети и размерность выхода генератора и входа дискриминатора. Это ускоряет обучение нейронной сети и значительно улучшает качество сгенерированных изображений в высоком разрешении.

4. Minibatch standard deviation layer

Слой Minibatch standard deviation layer, описанный в статье PGGAN [9], рассчитывает стандартное отклонение в партии выборки дискриминатора. Эта модификация заставляет генератор выдавать изображения со стандартным отклонением, как в реальной выборке, и решает проблему коллапса генератора.

5. Conditional GAN

Модификация Conditional GAN (CGAN) [10] заключается в добавлении дополнительных нейронов в генераторе и дискриминаторе для контроля генерируемых изображений. В текущей работе дополнительный нейрон определяет пористость изображения. В генераторе выход дополнительного нейрона умножается на вектор шума, а в дискриминаторе – подается на дополнительный канал свертки.

Обучающая выборка

Для обучения использовалась компьютерная микротомография песчаника Берия объемом 400^3 вокселей [11] и массив искусственного идеального грунта с одинаковым размером зерен объемом 500^3 (рис. 4) для наглядной визуализации дефектов при генерации изображений. Из-за ограничений в размере оперативной памяти, необходимой для хранения графа нейронной сети и выборки изображений, из каждой выборки были получены трехмерные массивы пористых сред с меньшей размерностью — 128^3 вокселей.




Рис. 4. Срез массива песчаника Берия (слева) и идеального грунта (справа) с примерами среза выборки (красный контур) (фото авторов)

Обучение и результаты

1. Бесконтрольная генерация

Нейронная сеть без использования модификации CGAN обучалась около 48 часов на платформе Google Colaboratory с графическим ускорителем Nvidia Testa P100. На рис. 5 представлен постепенный рост дискретизации генерируемых изображений.




Рис. 5. Постепенный рост дискретизации генерируемых изображений в процессе обучения нейронной сети на примере песчаника Берия (фото авторов)

Для сравнения результатов возьмем сгенерированные изображения пористых сред с использованием архитектуры DCGAN из исследования Lukas Mosser и др. [12] (рис. 6).




Рис. 6. Сравнение результатов по выборке из идеального грунта (сверху) и песчаника Берия (снизу). Слева — оригинал, по центру — DCGAN, справа — текущая работа (фото авторов)

Использование модификаций PGGAN и WGAN-GP усложняет граф нейронной сети. Из-за ограничений в оперативной памяти видеоускорителя мы вынуждены снизить размерность генерируемых изображений. Тем не менее использование этих модификаций значительно повышает качество генерируемых изображений, особенно это видно в сравнении с идеальным грунтом, где при использовании DCGAN наблюдается большое количество шума и артефактов.

На рис. 7 представлено сравнение трехмерной модели реальной и сгенерированной пористой среды. Трехмерные модели получены с использованием алгоритма маршрутирующих кубов.

2. Контролируемая генерация

Обучение нейронной сети с дополнительным нейроном на входе для контроля генерируемых изображений составило около 4 суток. Увеличение сложности архитектуры увеличило время, требуемое на одну итерацию обучения, и потребляемую оперативную память, что вынудило снизить размерность генерируемых изображений до 64^3 .

Диапазон пористости в выборке из песчаника Берия — [5%; 36%]. На рис. 8 видно, что нейронная сеть обучена генерировать изображения с необходимой пористостью с небольшой погрешностью в диапазоне пористости обучающей выборки.




Рис. 7. Сравнение реальной (слева) и сгенерированной (справа) пористой среды в трехмерном виде (фото авторов)




Рис. 8. Интерполяция по значению пористости при постоянном векторе шума в виде срезов массивов пористых сред: c_0 — пористость, подаваемая на вход нейронной сети, c — фактическая пористость сгенерированного изображения (фото авторов)




Рис. 9. Интерполяция по параметру пористости (фото авторов)

На рис. 9 графически представлена интерполяция по параметру пористости. Из графика видно, что нейронная сеть способна значительно экстраполировать пористость на изображениях, выходя за диапазон пористости из обучающей выборки.

На рис. 10 представлен пример с минимальной и максимальной пористостью с постоянным вектором шума.

Если обратить внимание на детали рис. 8 и 10, то можно заметить, что генератор не просто изменяет размер элементов при изменении параметра пористости, но и меняет их взаимное расположение.

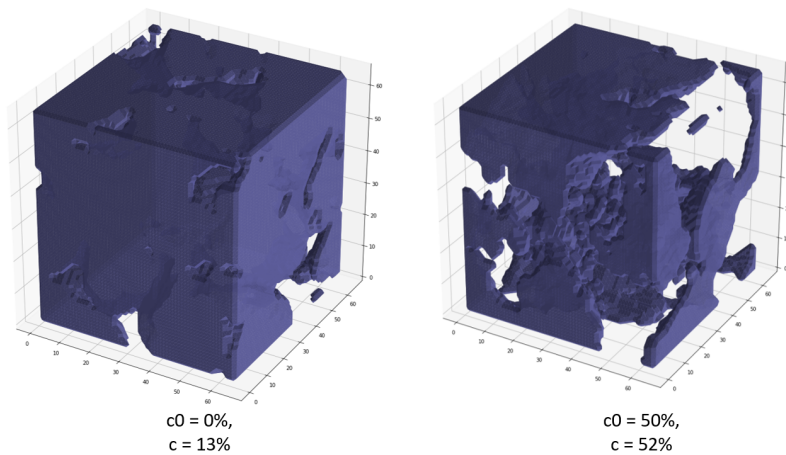


Рис. 10. Трехмерная модель пористой среды с минимальной (слева) и максимальной (справа) пористостью (фото авторов)

Заключение

Применение генеративно-состязательной нейронной сети позволило искусственно сгенерировать массивы пористых сред с необходимой пористостью. В дальнейшем планируется модификация архитектуры сети для добавления новых контрольных параметров, возможности генерации массивов изображений с несколькими каналами, плотностями грунта и возможности генерации структур размеров, превышающих размеры изначальной выборки.

ЛИТЕРАТУРА

1. Воробьев К. А., Воробьев А. Е., Тчаро Х. Цифровизация нефтяной промышленности: технология «цифровой» керн. *Вестник Евразийской науки*. 2018;10(3). Режим доступа: <https://esj.today/78nzvn318.html>.
2. Балашов В. А., Свенков Е. Б. Цифровой керн. Моделирование микротечений в поровом пространстве пород-коллекторов. *Neftegaz.ru*. 2019;7. Режим доступа: <https://magazine.neftegaz.ru/articles/tsifrovizatsiya/475125-tsifrovoy-kern-modelirovanie-mikrotecheniy-v-porovom-prostranstve-porod-kollektorov/>.
3. Стулов П. А., Егоров А. А., Гавриленко Т. В. Современные технологии создания модели порового пространства горных пород. *Вестник кибернетики*. 2019;1:47–54.
4. Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio. Generative Adversarial Networks. 2014. Режим доступа: <https://arxiv.org/abs/1406.2661>.
5. Hui J. GAN – What is Generative Adversarial Networks GAN? Режим доступа: https://medium.com/@jonathan_hui/gan-whats-generative-adversarial-networks-and-its-application-f39ed278ef09.
6. Alec Radford, Luke Metz, Soumith Chintala. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. 2015. Режим доступа: <https://arxiv.org/abs/1511.06434>.
7. Martin Arjovsky, Soumith Chintala, Léon Bottou. Wasserstein GAN. 2017. Режим доступа: <https://arxiv.org/abs/1701.07875>.
8. Ishaan Gulrajani, Faruk Ahmed, Martin Arjovsky, Vincent Dumoulin, Aaron Courville. Improved Training of Wasserstein GANs. 2017. Режим доступа: <https://arxiv.org/abs/1704.00028>.
9. Tero Karras, Timo Aila, Samuli Laine, Jaakko Lehtinen. Progressive Growing of GANs for Improved Quality, Stability, and Variation. 2017. Режим доступа: <https://arxiv.org/abs/1710.10196>.
10. Mehdi Mirza, Simon Osindero. Conditional Generative Adversarial Nets. 2014. Режим доступа: <https://arxiv.org/abs/1411.1784>.
11. *Berea Sandstone Extraction* / Imperial College London. Режим доступа: <https://www.imperial.ac.uk/earth-science/research/research-groups/perm/research/pore-scale-modelling/micro-ct-images-and-networks/berea-sandstone/>.

12. Lukas Mosser, Olivier Dubrulle, Martin J. Blunt. Reconstruction of Three-Dimensional Porous Media Using Generative Adversarial Neural Networks. 2017. \T2A\CYRR\T2A\cyre\T2A\cyrzh\T2A\cyri\T2A\cyrm\T2A\cyrd\T2A\cyro\T2A\cyrs\T2A\cyrt\T2A\cyru\T2A\cyrp\T2A\cyra:https://arxiv.org/pdf/1704.03225.pdf.

REFERENCES

1. Vorobyev K. A., Vorobev A. E., Tchare H. Oil Industry Digitization: Technology “Digital” Core. *The Eurasian Scientific Journal*. 2018;3(10). Available at: <https://esj.today/PDF/78NZVN318.pdf>. (In Russ.).
2. Balashov V. A., Svenkov E. B. The Digital Core. Simulation of Microflows in the Reservoir Rock Porous Media. *Neftegaz.ru*. 2019;7. Available at: <https://magazine.neftgaz.ru/articles/tsifrovizatsiya/475125-tsifrovoy-kern-modelirovanie-mikrotecheniy-v-porovom-prostranstve-porod-kollektorov/>. (In Russ.).
3. Stulov P. A., Egorov A. A., Gavrilenko T. V. Modern Technologies for Modelling Pore Space of Rocks. *Proceedings in Cybernetics*. 2019;1:47–54. (In Russ.).
4. Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio. Generative Adversarial Networks. 2014. Available at: <https://arxiv.org/abs/1406.2661>.
5. Hui J. GAN – What is Generative Adversarial Networks GAN? Available at: https://medium.com/@jonathan_hui/gan-whats-generative-adversarial-networks-and-its-application-f39ed278ef09.
6. Alec Radford, Luke Metz, Soumith Chintala. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. 2015. Available at: <https://arxiv.org/abs/1511.06434>.
7. Martin Arjovsky, Soumith Chintala, Léon Bottou. Wasserstein GAN. 2017. Available at: <https://arxiv.org/abs/1701.07875>.
8. Ishaan Gulrajani, Faruk Ahmed, Martin Arjovsky, Vincent Dumoulin, Aaron Courville. Improved Training of Wasserstein GANs. 2017. Available at: <https://arxiv.org/abs/1704.00028>.
9. Tero Karras, Timo Aila, Samuli Laine, Jaakko Lehtinen. Progressive Growing of GANs for Improved Quality, Stability, and Variation. 2017. Available at: <https://arxiv.org/abs/1710.10196>.
10. Mehdi Mirza, Simon Osindero. Conditional Generative Adversarial Nets. 2014. Available at: <https://arxiv.org/abs/1411.1784>.
11. *Berea Sandstone Extraction* / Imperial College London. Available at: <https://www.imperial.ac.uk/earth-science/research/research-groups/perm/research/pore-scale-modelling/micro-ct-images-and-networks/berea-sandstone/>.
12. Lukas Mosser, Olivier Dubrulle, Martin J. Blunt. Reconstruction of Three-Dimensional Porous Media Using Generative Adversarial Neural Networks. 2017. Available at: <https://arxiv.org/pdf/1704.03225.pdf>.