

## АВТОМАТИЧЕСКАЯ АДАПТАЦИЯ ГИДРОДИНАМИЧЕСКОЙ МОДЕЛИ С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ

Сливкин С.С., Шишаев Г.Ю., Харитонцева П.А.

Научный руководитель доцент Рукавишников В.С.

Национальный исследовательский Томский политехнический университет, г. Томск, Россия

В настоящее время адаптация гидродинамических моделей происходит путем ручной либо полуавтоматизированной настройки параметров гидродинамической модели на данные добычи (добыча жидкости, нефти, закачка воды, забойное давление). Весь процесс адаптации является довольно длительным и трудоемким и не гарантирует качественного прогноза работы моделируемого месторождения, т. к. многовариантное моделирование представляется практически невозможным по причине вычислительных и временных затрат.

В представленной работе апробируется работа генеративных нейронных сетей для адаптации двумерной геологической модели одновременно с ее созданием. Применяется архитектура - Generative adversarial network (GAN), этот метод хорошо зарекомендовал себя в других областях знаний (например, обработка изображений). Кроме того, за последние несколько лет вышел ряд публикаций, описывающих процессы использования GAN в качестве генераторов геологических объектов [1], [4] с одновременной настройкой на данные добычи [2], [3].

GAN – это генеративно-сопоставительная сеть, которая состоит из двух соревнующихся друг с другом нейронных сетей – генератора  $G(z)$  (создает объекты на основе вектора  $z$  из скрытого пространства) и дискриминатора  $D(y)$  (оценивает вероятность того, что  $y$  принадлежит реальным данным, а не сгенерированным). При условии того, что входные данные состоят из набора оригинальных образцов, цель генератора – создать образцы с распределением, близким к распределению входных данных. Иными словами, генератор пытается воссоздать процесс создания данных. С другой стороны, дискриминатор является классификатором, который принимает образцы как входные данные и пытается определить, является ли образец реалистичным (т. е., воспроизводит первоначальную выборку) или синтетическим (т. е., создан генератором). Выходные данные дискриминатора – это скаляр, который представляет вероятность воспроизведения первоначальной выборки. Иными словами, цель дискриминатора – отличить синтетические образцы от реалистичных, тогда как цель генератора – обмануть дискриминатор.

В качестве обучающей выборки (для обучения GAN) с помощью объектного моделирования был сгенерирован датасет русловых отложений. Объектное моделирование – это метод моделирования геологического сценария при помощи объектов, которые создаются и распределяются стохастически. Все геометрические входные данные, отвечающие за форму тел (ширина, толщина и т. д.), могут быть определены детерминистически, следовать определенному статистическому распределению, быть назначены с использованием карты трендов или, как в текущей работе, задаваться в виде переменной с рангом значений. Все созданные модели имеют размерность  $128 \times 128 \times 1$  ячеек (рис. 1), а также две исходные скважины – нагнетательную (слева) и добывающую (справа), отмеченные синей и красной прямыми, соответственно. Всего обучающая выборка была составлена из 5000 реализаций геологических моделей.




Рис. 1. Структурный каркас моделей и пример распределения фаций русловых отложений

Следующим шагом был процесс обучения GAN воспроизводить геологические модели без статистического противоречия обучающей выборке. Дополнительно, визуально оценивалось качество распределения фаций русла.

После обучения с помощью кода на языке программирования Python GAN был соединен с гидродинамическим симулятором для решения обратной задачи (адаптации гидродинамической модели на историю разработки) путем оптимизации параметров генеративной сети. В процессе адаптации минимизировалась целевая функция, тем самым приближая каждую последующую сгенерированную модель к исторической модели. В качестве алгоритма оптимизации использовался метод градиентного спуска.

В качестве метрик использовались следующие показатели:

- 1) Статистические параметры сгенерированных геологических объектов (пористость, проницаемость) не противоречат обучающей выборке;
- 2) Динамические данные (дебит нефти, объем закачки), рассчитанные на симуляторе отклоняются от исторических данных в коридоре 10 %.

Пример изменения сетки пористости модели в процессе адаптации показан на рисунке 2. Процесс адаптации дебита нефти и закачки воды приведен на рисунке 3 и рисунке 4.




Рис. 2. Структурный каркас моделей и пример распределения фаций русловых отложений




Рис. 3. Процесс адаптации дебита нефти (рыжая линия – референсная/историческая добыча, синяя линия – добыча при оптимизации)




Рис. 4. Процесс адаптации закачки воды (рыжая линия – референсная/историческая добыча, синяя линия – добыча при оптимизации)

В результате проведения экспериментов была подтверждена эффективность использования генеративных нейронных сетей для решения обратной задачи (автоматическая адаптации модели) на двумерной модели. Кроме того, многократный запуск процесса оптимизации, либо использование других оптимизационных алгоритмов способны предоставлять множество решений обратной задачи, что обеспечивает многовариантность и оценку неопределенностей. Дальнейшим развитием работы является переход от 2х мерных моделей к 3х мерным с последующим воспроизведением процесса автоматической адаптации.

#### Литература

1. Lee K. et al. Feature extraction using a deep learning algorithm for uncertainty quantification of channelized reservoirs //Journal of Petroleum Science and Engineering. – 2018. – Т. 171. – С. 1007-1022.
2. Mosser L., Dubrule O., Blunt M. J. Deepflow: history matching in the space of deep generative models //arXiv preprint arXiv:1905.05749. – 2019.
3. Ahn S. et al. Data-driven inverse modeling with a pre-trained neural network at heterogeneous channel reservoirs //Journal of Petroleum Science and Engineering. – 2018. – Т. 170. – С. 785-796.
4. Smith Arauco Canchumuni, Alexandre A. Emerick, Marco Aurelio Pacheco "Integration of Ensemble Data Assimilation and Deep Learning for HM Facies Models", Offshore Technology Conference 2017 Canchumuni S. A., Emerick A. A., Pacheco M. A. Integration of ensemble data assimilation and deep learning for history matching facies models //Offshore Technology Conference Brasil. – OTC, 2017. – С. D011S006R005.