

УДК: 532.5

Методика имитационного моделирования на основе обучающих данных для двухфазного течения в гетерогенной пористой среде

А. В. Умановский

Российский государственный университет нефти и газа
(Национальный исследовательский институт) имени И. М. Губкина,
Россия, 119991, г. Москва, Ленинский пр-т., д. 65

E-mail: lynx.ff@gmail.com

Получено 16.04.2021, после доработки — 23.06.2021.

Принято к публикации 30.06.2021.

Классические численные методы, применяемые для предсказания эволюции гидродинамических систем, предъявляют высокие требования к вычислительным ресурсам и накладывают ограничения на число вариантов геолого-гидродинамических моделей, расчет эволюции состояний которых возможно осуществлять в практических условиях. Одним из перспективных подходов к разработке эвристических оценок, которые могли бы ускорить рассмотрение вариантов гидродинамических моделей, является имитационное моделирование на основе обучающих данных. В рамках этого подхода методы машинного обучения используются для настройки весов искусственной нейронной сети (ИНС), предсказывающей состояние физической системы в заданный момент времени на основе начальных условий. В данной статье описаны оригинальная архитектура ИНС и специфическая процедура обучения, формирующие эвристическую модель двухфазного течения в гетерогенной пористой среде. Основанная на ИНС модель с приемлемой точностью предсказывает состояния расчетных блоков моделируемой системы в произвольный момент времени (с известными ограничениями) на основе только начальных условий: свойств гетерогенной проницаемости среды и размещения источников и стоков. Предложенная модель требует на порядки меньшего процессорного времени в сравнении с классическим численным методом, который послужил критерием оценки эффективности обученной модели. Архитектура ИНС включает ряд подсетей, обучаемых в различных комбинациях на нескольких наборах обучающих данных. Для обучения ИНС в рамках многоэтапной процедуры применены техники состязательного обучения и переноса весов из обученной модели.

Ключевые слова: имитационное моделирование, нейросетевые модели физических процессов, суррогатное моделирование, гидродинамика, пористая среда, сверточные нейронные сети, состязательное обучение

UDC: 532.5

Data-driven simulation of a two-phase flow in heterogenous porous media

A. V. Umanovskiy

National University of Oil and Gas «Gubkin University»,
65 Leninsky ave., Moscow, 119991, Russia

E-mail: lynx.ff@gmail.com

Received 16.04.2021, after completion — 23.06.2021.

Accepted for publication 30.06.2021.

The numerical methods used to simulate the evolution of hydrodynamic systems require the considerable use of computational resources thus limiting the number of possible simulations. The data-driven simulation technique is one promising approach to the development of heuristic models, which may speed up the study of such models. In this approach, machine learning methods are used to tune the weights of an artificial neural network that predicts the state of a physical system at a given point in time based on initial conditions. This article describes an original neural network architecture and a novel multi-stage training procedure which create a heuristic model of a two-phase flow in a heterogeneous porous medium. The neural network-based model predicts the states of the grid cells at an arbitrary timestep (within the known constraints), taking in only the initial conditions: the properties of the heterogeneous permeability of the medium and the location of sources and sinks. The proposed model requires orders of magnitude less processor time in comparison with the classical numerical method, which served as a criterion for evaluating the effectiveness of the trained model. The proposed architecture includes a number of subnets trained in various combinations on several datasets. The techniques of adversarial training and weight transfer are utilized.

Keywords: data-driven simulation, physics informed neural networks, proxy modelling, hydrodynamics, porous media, convolutional neural networks, GAN

Citation: *Computer Research and Modeling*, 2021, vol. 13, no. 4, pp. 779–792 (Russian).

© 2021 Arseniy V. Umavovskiy

This work is licensed under the Creative Commons Attribution-NoDerivs 3.0 Unported License.

To view a copy of this license, visit <http://creativecommons.org/licenses/by-nd/3.0/>
or send a letter to Creative Commons, PO Box 1866, Mountain View, CA 94042, USA.

1. Введение

Имитационное моделирование на основе численных методов часто является единственным способом предсказать эволюцию гидродинамической системы. Нелинейные свойства математических описаний некоторых систем, в частности гидродинамических, затрудняют аналитическое моделирование их развития во времени. Такие системы, в частности гидродинамические, характеризуются как турбулентные или хаотические. Нелинейность соответствующих им уравнений означает существенное и непредсказуемое влияние даже небольшого изменения начальных условий на форму решения.

Аппроксимация решений для другой математической системы, приближенной к оригинальной и построенной путем дискретизации начальных условий по пространству, для эволюции, дискретизированной по времени, и называется имитационным моделированием.

Задача поиска таких приближенных решений выполняется с помощью компьютера и является крайне требовательной к вычислительным ресурсам. В последние годы параллельные и распределенные вычисления становятся доступнее, ведутся успешные исследования по адаптации алгоритмов имитационного моделирования для оптимального использования актуальных вычислительных технологий. Существуют, однако, фундаментальные пределы возможностей оптимизации этих алгоритмов для параллельных процессоров.

Одним из инновационных подходов в области имитационного моделирования физических процессов, развившихся в последние годы, является *имитационное моделирование на основе обучающих данных (data-driven simulations)*. В рамках этого подхода процедура машинного обучения, использующая специфическую архитектуру *искусственной нейронной сети (ИНС)*, преследует цель предсказания результатов работы классического алгоритма имитационного моделирования, основанного на решении дискретизированных уравнений численными методами. Возникновение этого направления связано с успешными и широко известными исследованиями в области архитектур и методик обучения ИНС, позволяющих обрабатывать графические и видеоданные на прежде недоступном уровне.

Результаты работы классического алгоритма при этом используются для формирования *набора обучающих данных*, служащего инструментом настройки весов ИНС и критерием успешности обучения.

Успехи данного подхода лежат прежде всего в области ускорения параллельной обработки задач имитационного моделирования и уже находят практическое применение в коммерческих программных продуктах. Возможности имитационного моделирования на основе обучающих данных вызывают и некоторый фундаментальный научный интерес в связи с перспективами нового понимания степени предсказуемости турбулентных процессов [Brunton et al., 2020].

Задачи имитационного моделирования движения флюидов (фильтрации) в пористой среде характерны для нефтегазодобывающей индустрии. Специфика возникающих в этой отрасли задач делает весьма актуальной разработку эвристических оценок эволюции таких гидродинамических систем [Баранов и др., 2012; Косентино, 2007].

В данной статье рассматривается применение методики имитационного моделирования на основе обучающих данных к гидродинамике пористой среды. В продолжение исследования [Умановский, 2020], описавшего возможность применения сверточной ИНС для предсказания состояния гидродинамической системы на основе начальных условий, настоящая статья рассматривает более широкий спектр ситуаций, включающих зависимость эволюции системы также от переменной проницаемости расчетных блоков.

Эвристическая модель, основанная на оригинальной архитектуре ИНС и специально разработанной многоэтапной процедуре обучения, позволяет предсказывать характеристики всех расчетных блоков (ячеек сетки) дискретизированной модели в произвольный момент времени, основываясь только на начальных условиях: конфигурации источников и стоков и свойствах гетерогенной пористой среды.

2. Релевантные работы

Имитационное моделирование на основе обучающих данных является весьма молодым направлением исследований. Большинство актуальных работ в этой области созданы в 2015–2021 гг.; существуют лишь единичные публикации, затрагивающие применение такого рода методов к гидродинамике в пористой среде.

Мотивацией и основным успехом наиболее известных работ являлось ускорение трудоемких расчетов, связанных с решением системы дискретизированных уравнений в рамках классических алгоритмов имитационного моделирования, без которых, как правило, невозможно обеспечивать соблюдение условий несжимаемости для моделируемых флюидов. Так, авторы [Ladický et al., 2015] сообщили об увеличении скорости расчета на 1–3 порядка в сравнении с классическим *методом сглаженных частиц*. В основе этого широко известного метода, в свое время также разработанного для ускорения процесса имитационного моделирования гидродинамических систем, лежит лагранжевое представление моделируемого флюида в виде характеристик движущихся *псевдочастиц* путем интерполяции положения которых определяется форма фронта раздела. Как и многие из работ в области, авторы работы [Ladický et al., 2015] ориентируются прежде всего на задачи компьютерной графики и анимации, что делает приоритетом скорость расчета или постоянство скорости расчета вне зависимости от начальных условий, даже за счет потерь точности.

В работе [Yang et al., 2016] более актуальное для научных задач эйлеровское представление, основанное на разбиении расчетной области на конечные объемы, обрабатывается с использованием инновационной архитектуры ИНС со сверточными слоями для получения дискретизированного поля давлений с нулевой дивергенцией на основе состояния поля скоростей жидкости после осуществления менее ресурсоемкого «явного» шага классического алгоритма. Этот результат получил развитие в [Tompson et al., 2016]. Для ускорения имитационного моделирования на основе методов конечных объемов были предложены каскадные архитектуры сверточной ИНС [Thuerey et al., 2020], связки «кодировщик–декодировщик» [Wiewel et al., 2019], формирующие сжатое отображение входных данных, варианты методов состязательного обучения [Xie et al., 2018; Werhahn et al., 2019] и др.

В то время как наиболее популярной целью изысканий является разработка высокоскоростных методов имитационного моделирования флюидов, вплоть до доступности «режима реального времени» на типичной потребительской видеокарте, ряд работ указывает также на потенциал подхода в области более точных расчетов, востребованных промышленными отраслями [Guo et al., 2016; Thuerey et al., 2020]. Стоит отметить работы [Holl et al., 2020; Hu et al., 2019; Sanchez-Gonzalez et al., 2020], рассматривающие возможность обобщения и создания более универсального алгоритма имитационного моделирования на основе обучающих данных, способного обрабатывать в рамках одной модели различные физические системы. К этим материалам можно обратиться за списком актуальной литературы.

Хотя техники машинного обучения широко применяются в различных задачах нефтегазодобывающей отрасли, очень небольшое количество работ затрагивает тему имитационного моделирования на основе обучающих данных. Можно отметить интерполяционную модель для оценки динамики пластового давления [Chen et al., 2013] и эвристический «инструмент нейросимуляции» [Gorucu et al., 2005], предсказывающий скалярные характеристики процесса закачки углекислого газа в пласт в обход трудоемких численных расчетов. В недавней работе [Amini, Mohaghegh, 2019] к похожей задаче успешно применена методика, отчасти сходная с рассматриваемой в настоящей статье, предполагающая определение динамических характеристик расчетных блоков в заданный момент времени. Примечательно, что в [Amini, Mohaghegh, 2019] результаты инновационной модели сравниваются не только с классическим методом, но и с данными истории эксплуатации реального месторождения. Работа [Teixeira, Secchi, 2019] использует расположение добывающих и нагнетательных скважин (источников и стоков гидродинамической модели) в качестве входов ИНС, преследуя цель предсказания характеристик добычи.

3. Архитектура ИНС

В рамках данного исследования была поставлена цель создания суррогатной модели на базе ИНС, позволяющей предсказывать водонасыщенности всех ячеек двумерной сеточной расчетной области в заданный момент времени на основе входных данных: расположения точечных источников и стоков и характеристик проницаемости участков расчетной области. Обучение специфической ИНС производилось на основе набора обучающих данных, составленного из результатов имитационного моделирования гидродинамической системы классическими численными методами.

В качестве исходной модели бралась автоассоциативная архитектура ИНС, включающая подсети: кодировщик и генератор, состоящие соответственно из сверточных слоев и «обратных сверток». Выходными данными такой модели является матрица чисел той же размерности, что и другая матрица, принимаемая кодировщиком на вход — в данном случае 128×128 .




Рис. 1. Архитектура компонентов ИНС: кодировщика (сверху) и генератора (снизу)

Каждый сверточный слой применяет к данным предыдущего слоя ряд фильтров, перемножая эти данные с весами, настраиваемыми в процессе обучения ИНС, и записывает сумму нескольких ячеек в единственную ячейку очередного слоя. Каждый фильтр порождает отдельную матрицу меньшего размера, количество таких матриц для каждого слоя указано как третье число в подписях на Рис. 1. Все слои данной ИНС используют перекрывающиеся друг друга с шагом 2 фильтры 5×5 , кроме последних слоев генератора, не меняющих размер матрицы. Операции «обратной свертки» используют аналогичные фильтры для восстановления большей матрицы из предыдущего слоя меньшей размерности, фильтры кодировщика и генератора различны и настраиваются независимо друг от друга. Нейроны всех слоев, кроме трех последних слоев генераторов, применяют функцию активации $g = \max(0, x)$, где x соответствует входным данным от нейронов предыдущего слоя или единице смещения. Эта функция, известная как ReLU, предъявляет низкие требования к вычислительным ресурсам как во время вывода, так и в процессе обучения ИНС. Нейроны трех последних слоев генератора применяют гиперболический тангенс $g = \tanh(x) = (2 / (1 + e^{-2x})) - 1$.

Как установлено предшествующим исследованием [Умановский, 2020], прямолинейный подход к обучению автоассоциативной ИНС в данной задаче бесперспективен. Была разрабо-

тана многоэтапная процедура обучения, задействующая в общей сложности 3 кодировщика для значений проницаемости, водонасыщенности и размещения источников и стоков (соответственно E_K , E_S и E_Q) и 2 генератора G_K и G_S . Кодировщик ставит входной матрице 128×128 в соответствие сжатое отображение — 1024-мерный вектор k или q .

Генераторы G_K и G_S , обученные в рамках отдельных процедур (см. § 5), объединяются в гибридный генератор G_{KS} , задачей обучения которого в свою очередь является минимизация функции потерь

$$\mathcal{L}_G = \sqrt{\sum_N \left[\mathbf{S}_{true} - G_{KS}(\omega_G, E_Q(\omega_{EQ}, \mathbf{Q}), E_K(\omega_{EK}, \mathbf{K})) \right]^2}, \quad (1)$$

где \mathbf{S}_{true} обозначает целевую матрицу водонасыщенности расчетных блоков, \mathbf{Q} — входную матрицу, в которой значение 1 соответствует размещению нагнетательной скважины в данном блоке, (-1) — размещению добывающей скважины, и остальным блокам соответствуют нули, \mathbf{K} обозначает матрицу характеристик проницаемости. Таким образом, L_2 -норма между целевыми значениями водонасыщенности и выдачей гибридного генератора является основной функцией потерь, снижение значений которой для обучающего набора данных ставится целью процесса обучения ИНС, т. е. оптимизации множеств весов, обозначенных здесь буквой ω .

После окончания разделенного на несколько этапов процесса обучения компонентов ИНС два кодировщика и гибридный генератор объединяются в 12-слойную архитектуру, выводящую предсказание значений матрицы водонасыщенностей \mathbf{S}_{NN} для входных условий \mathbf{K} , \mathbf{Q} и t . Принципиальная схема этой суррогатной модели дана на Рис. 2.

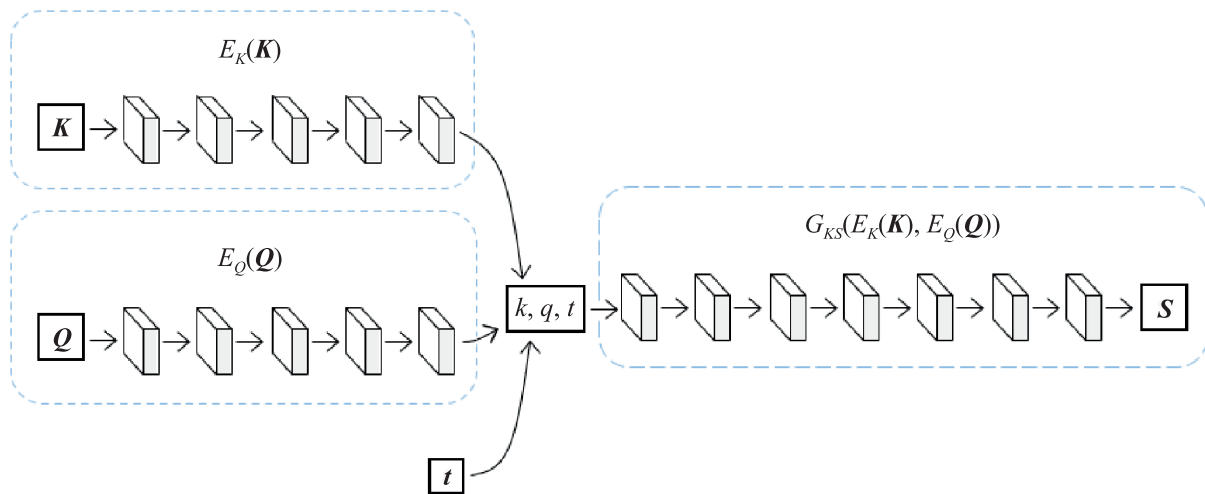


Рис. 2. Общая схема вывода системы из двух кодировщиков и объединенного генератора




Рис. 3. Архитектура ИНС-дискриминатора

Проведенные эксперименты показали ключевое значение техники состязательного обучения, в рамках которой функция потерь \mathcal{L}_G суммируется с \mathcal{L}_{D-G} , одной из целевых функций ИНС-дискриминатора D_K , изображенного на Рис. 3. Каждый из сверточных слоев D_K применяет ту же функцию активации ReLU, последние два полносвязных слоя используют классическую сигмоидную функцию $g = 1/(1 + e^{-x})$.

Обучение D_K ведется параллельно с обучением основной системы кодировщиков и генераторов, но преследует иную цель. Получая на вход \mathbf{K} , \mathbf{Q} и \mathbf{S} , дискриминатор выдает единственный бит информации, цель его обучения — отличить истинные численные решения \mathbf{S}_{true} от выводов основной ИНС \mathbf{S}_{NN} :

$$\mathcal{L}_D = (1 - D_K(\omega_D, \mathbf{K}, \mathbf{Q}, \mathbf{S}_{true}))^2 + (D_K(\omega_D, \mathbf{K}, \mathbf{Q}, \mathbf{S}_{NN}))^2. \quad (2)$$

Собственная целевая функция дискриминатора \mathcal{L}_D используется только для оптимизации его множества весов ω_D , но другая целевая функция \mathcal{L}_{D-G} направлена на достижение противоположных результатов, и \mathcal{L}_{D-G} применяется только при настройке весов ω_G , ω_{EQ} , ω_{EK} , с тем чтобы основная ИНС стремилась «обмануть» дискриминатор, производя \mathbf{S}_{NN} , трудноотличимые от \mathbf{S}_{true} :

$$\mathcal{L}_{D-G} = (D_K(\omega_D, \mathbf{K}, \mathbf{Q}, \mathbf{S}_{true}))^2 + (1 - D_K(\omega_D, \mathbf{K}, \mathbf{Q}, \mathbf{S}_{NN}))^2. \quad (3)$$

Такая формулировка целевых функций создает состязательный режим обучения, существенно улучшающий ожидаемое качество результатов и ускоряющий сходимость [Liu, Chawla, 2009]. Можно сказать, что D_K указывает основной ИНС на проблемы и слабые места ее решений.

4. Физическая модель

Имитационное моделирование гидродинамических систем на основе метода конечных объемов предполагает дискретизацию расчетной области — разбиение пространства на сетку, или решетку, состоящую из ячеек, в простейшем случае прямоугольных, также называемых расчетными блоками. Взаимодействие интегральных величин, характеризующих расчетные блоки, описывается системой линейных уравнений, решения которой для дискретных шагов по времени аппроксимируют решения континуальных уравнений.

Континуальная система уравнений, описывающая течение (фильтрацию) двух флюидов, смачивающей фазы w и несмачивающей фазы n , в пористой среде, имеет вид

$$\begin{cases} m \frac{\partial s_w}{\partial t} + \nabla \cdot \vec{v}_w = Q_w, \\ m \frac{\partial s_n}{\partial t} + \nabla \cdot \vec{v}_n = Q_n, \\ \nabla \cdot \vec{v} = Q. \end{cases} \quad (4)$$

Здесь m — пористость породы, $Q = Q_w + Q_n$ — член, соответствующий вкладу источников и стоков, или граничных условий, которые и вызывают движение флюидов в отсутствие гравитации (будем рассматривать двумерную модель и горизонтальный разрез пласта).

Для каждой фазы i осредненный макроскопический поток, или *скорость Дарси*, определяется как $\vec{v}_i = -\lambda_i \nabla p_i$. Фазовая проводимость λ_i зависит от проницаемости породы K , в рассматриваемом в данной статье случае являющейся скалярной величиной, от фазовой вязко-

сти μ_i и, через относительную проницаемость k_r , от насыщенности смачивающей фазой в данном расчетном блоке S_w , что делает λ_i также функцией времени и усиливает нелинейность системы (4).

$$\lambda_i = \frac{Kk_r(S_w)}{\mu_i}.$$

Путем линейной комбинации, с учетом того, что $S_w + S_n = 1$, из системы (4) можно вывести единственное уравнение для давлений, имеющее эллиптические свойства:

$$\bar{v} = -(\lambda_n + \lambda_w)\nabla p_n - \lambda_w\nabla p_c, \quad (5)$$

где ∇p_c — градиент капиллярного давления, возникающего за счет сил межмолекулярного взаимодействия флюидов и твердой породы; а также $N - 1$ гиперболических уравнений для насыщенностей для случая N фаз:

$$m \frac{\partial s_w}{\partial t} = -\nabla \cdot \left(\frac{\lambda_w}{\lambda_n + \lambda_w} (\bar{v} + \lambda_n \nabla p_c) \right) + Q_w. \quad (6)$$

Целью такой формулировки является сокращение количества уравнений для давлений до одного, так как в рамках *алгоритмов последовательного решения* именно нахождение неявно выраженных давлений наиболее трудоемко [Каневская, 2002]. Для каждого дискретного шага по времени Δt_i алгоритм выполняет две последовательные процедуры:

- 1) вычисление p и \bar{v} неявным способом на основе известных с предыдущего шага p , \bar{v} и S_w ; уравнение (5) в дискретизированном виде решается итеративно, например методом Ньютона;
- 2) вычисление $S_w(x, t + \Delta t)$ явным или неявным способом из уравнения (6) в предположении неизменности значений \bar{v} и p_i .

Для обновления полей скорости и давления итеративным способом ищется решение системы из N линейных уравнений (для N расчетных блоков сетки):

$$Ap = \nabla \cdot \bar{v} + Q,$$

где матрица A имеет характерную форму — трех-, пяти- или семидиагональную для случаев одно-, двух- или трехмерного моделирования. Найденное решение учитывает влияние на систему движущих сил и соблюдает условие несжимаемости.

В данной работе фазы предполагались абсолютно несжимаемыми; не учитывались также возможные эффекты сжимаемости породы (пороупругость), тепловые, химические и другие факторы, межфазный массоперенос.

В случае двухфазной фильтрации уравнение (6) для водонасыщенности единственно. Явный метод определения насыщенностей требует существенно меньших вычислений, однако его применение накладывает строгие ограничения на длительность шага Δt_i (условие Куранта–Фридрихса–Леви). Таким образом, для осуществления имитационного моделирования продолжительных периодов в данной работе был избран *полностью неявный* алгоритм последовательного решения.

5. Конвейер машинного обучения

Обучение ИНС можно рассматривать как вычислительный эксперимент, целью которого является приближение результатов работы ИНС к данным из обучающего набора образцов, а критерием успешности — сравнение с данными тестового набора образцов.

С помощью алгоритма шума Перлина [Gustavson, 2005], имитирующего фрактальные черты геологических объектов, были подготовлены 100 карт проницаемости \mathbf{K} размером 128×128 блоков, 80 из которых составили основу обучающего набора данных, 20 были отложены для тестирования.

Случайное размещение от 2 до 6 источников и от 2 до 6 стоков, симулирующих нагнетательные скважины, вводящие в пласт смачивающую фазу w , и добывающие скважины, извлекающие обе фазы в фонтанном режиме, было использовано при подготовке 520 конфигураций \mathbf{Q} .

500 из этих конфигураций, скомбинированные с 80 вариантами \mathbf{K} , образовали начальные условия для 40 000 гидродинамических моделей обучающего набора. Для каждого варианта начальных условий в обучающий набор образцов вошли 6 состояний поля насыщенностей \mathbf{S} , соответствующих 50, 100, 150, 200, 250 и 300 дням. Численные расчеты были выполнены полностью неявным методом последовательного решения с помощью программного пакета MATLAB Reservoir Simulation Toolbox [Krogstad et al., 2015].

Процесс обучения ИНС устроен по конвейерному принципу: на входы подаются начальные условия, результаты работы сети, т. е. перемножения входных значений с весами каждого слоя и суммы в соответствии с выбранной архитектурой, затем сравниваются с целевыми результатами — насыщенностями \mathbf{S}_{true} . Разница, или невязка, используется для настройки весов ω по принципу обратного распространения ошибки на основе дискретизированных частных производных функции потерь \mathcal{L} . Эти вычисления осуществляются алгоритмом оптимизации ADAM [Kingma, Ba, 2015], рассчитанным на сверточные ИНС, реализованным средствами библиотеки Pytorch. Для оптимизатора ADAM установлены типичные гиперпараметры глобальной скорости обучения $\alpha = 2 \times 10^{-4}$, малого числа $\epsilon = 1 \times 10^{-5}$, служащего для ограничения наименьших величин, участвующих в расчетах и предотвращения деления на ноль, и показатель экспоненциальной скорости затухания для импульсов инерционной оптимизации $\beta_1 = 0.5$, $\beta_2 = 0.999$.

Процесс обучения компонентов ИНС разбит на ряд последовательных этапов.

Первый этап: обучение кодировщиков E_Q и E_S и генератора G_S на ограниченном наборе образцов, включающем только модели пласта с гомогенной картой проницаемостей и единственное для каждого образца состояние насыщенностей \mathbf{S} , соответствующее 300 дням. Таким образом, образцы различаются только конфигурацией \mathbf{Q} . На каждой эпохе обучения поочередно осуществляется проход связки $E_S \rightarrow G_S$ и связки $E_Q \rightarrow G_S$, для каждой из них вычисляется отдельная функция потерь и осуществляется обновление весов, причем обе процедуры влияют на веса генератора, но каждая — только на веса одного из кодировщиков. После завершения этого этапа кодировщик E_S удаляется. Подробнее о мотивации такого решения можно прочесть в [Умановский, 2020].

Второй этап: продолжение обучения E_Q и G_S на расширенном наборе данных, включающем несколько шагов по времени для каждого образца. Значение t подается на второй слой генератора в виде числа с плавающей точкой от 0 до 1, где 0 соответствует началу имитационного моделирования, а 1 — 300-му дню.

Третий этап: обучение связки E_K и G_K реконструировать карту проницаемостей \mathbf{K} на специально подготовленном наборе из 2000 образцов \mathbf{K} с помощью классической функции потерь автоассоциатора:

$$\mathcal{L}_{EGK} = \sqrt{\sum_N \left[\mathbf{K} - G_K(\omega_{GK}, E_K(\omega_{EK}, \mathbf{K}_{NN})) \right]^2}.$$

Четвертый этап: объединение генераторов G_K и G_S . При этом количество фильтров и матриц на каждом слое, начиная со второго, удваивается в сравнении с архитектурой, пока-

занной на рис. 1. На входы гибридного генератора G_{KS} подаются сжатые отображения k и q , суммарная размерность входного вектора — 2048. Гибридный генератор затем подвергается обучению на наборе образцов с различными \mathbf{K} и \mathbf{Q} и единственным t , соответствующим 300 дням.

Обучение ведется с параллельным применением основной функции потерь (1) и дополнительных функций (2) и (3) по описанному в § 2 принципу состязательного обучения. При этом веса кодировщиков ω_{EQ} и ω_{EK} «заморожены», обновлению на каждой эпохе подвергаются только веса гибридного генератора ω_G . Этих весов в 4 раза больше, чем весов у отдельно G_K или G_S , так как каждая матрица каждого слоя обрабатывается каждым фильтром следующего слоя.

Пятый этап: продолжение обучения G_{KS} на расширенном наборе данных, включающем несколько шагов по времени.

6. Результаты и обсуждение

После завершения достаточного числа эпох обучения на всех последовательных этапах обучения ИНС может быть использована для предсказания полей насыщенности \mathbf{S} в произвольный момент времени t , варьируемый от 0 до 300 дней, на основе матрицы характеристик проницаемости \mathbf{K} и конфигурации источников и стоков \mathbf{Q} .

Система из кодировщиков E_K и E_Q и генератора G_{KS} , задействуя мощности графического процессора, выдает картину насыщенностей $\mathbf{S}_{NN} = G_{KS}(E_K(\mathbf{K}), E_Q(\mathbf{Q}))$ за порядка 0.05 секунды, в то время как проведение численной имитационного моделирования для одной такой конфигурации средствами MATLAB требует 1.5–3 секунд в зависимости от \mathbf{K} .

Для первого и четвертого этапов процедуры обучения потребовалось осуществить по 200 эпох обучения, для второго и пятого было достаточно 25 эпох. На третий этап понадобилось выделить 300 эпох, так как архитектура автоассоциатора с трудом приспособляется к высокой энтропии шума Перлина. В общей сложности обучение заняло нескольких суток, большую часть — вычислительно затратные четвертый и пятый этапы.

На Рис. 4 можно увидеть сравнение результатов численного имитационного моделирования \mathbf{S}_{true} и предсказания ИНС \mathbf{S}_{NN} (третий и четвертый столбцы), а также качество реконструкции карты проницаемостей $\mathbf{K}_{NN} = G_K(E_K(\mathbf{K}))$ системой $E_K \rightarrow G_K$ (второй столбец).

Для иллюстрации влияния гетерогенных проницаемостей на ход процесса заводнения на Рис. 4 представлена одна и та же тестовая конфигурация \mathbf{Q} в сочетании с двумя различными \mathbf{K} , тоже принадлежащими к тестовому набору. Можно убедиться, что ИНС в общих чертах верно предсказывает форму решения, включая и вызванные гетерогенной проницаемостью особенности. Эволюция сложных комбинаций, таких как тесная группа источников и стоков в левом верхнем углу, может быть предсказана с ошибками.

Мотивацией послойного объединения генераторов G_K и G_S было создание возможности для процесса обучения гибридного генератора находить закономерности влияния деталей разного масштаба на разных стадиях восстановления целевой картины из сжатых отображений k и q . Усредненное различие между всеми соответствующими водонасыщенностями ячеек \mathbf{S}_{NN} и \mathbf{S}_{true} (L_1 -расстояние) для представленных двух случаев составляет 1.4 и 1.2 % соответственно. Для сравнения можно рассчитать различие между \mathbf{S}_{true} для двух случаев с одинаковым \mathbf{Q} и разными \mathbf{K} : 1.8 % (третий ряд на Рис. 4). В среднем для тестового набора это 1.7 %; среднее различие \mathbf{S}_{NN} и \mathbf{S}_{true} — 1.5 %. Для обучающего набора этот показатель несколько ниже, что является типичной ситуацией.




Рис. 4. Первые два ряда соответствуют двум различным моделям из тестового набора. В столбцах слева направо: 1) карта проницаемостей; 2) реконструированная ИНС карта проницаемостей; 3) водонасыщенность на 300 день по результатам классического численного моделирования; 4) водонасыщенность, предсказанная ИНС; 5) модуль разности колонок 3 и 4. В третьем ряду: модуль разности соответствующих матриц из первых двух рядов




Рис. 5. Эволюция гидродинамической системы в течение 500 дней. Первый ряд: результаты классического имитационного моделирования. Второй ряд: результаты ИНС. Третий ряд: модуль разницы между одним и другим

Обученная ИНС показала способность предсказывать S для тестовых ситуаций, не входящих в набор обучающих данных. Однако общие ограничения обучающего набора должны соблюдаться и в случае новых задач. На Рис. 5 представлена эволюция гидродинамической системы в течение 500 дней, рассчитанная численным методом. Ни один из обучающих примеров для ИНС не включал более 300 дней, и стремительное падение качества предсказания наблюдается за рамками «опыта» ИНС. Еще одно ограничение связано с количеством источников и стоков, которых в моделях обучающего набора всегда было не более 6. Уже в случае 10 источников и 10 стоков отклонение возрастает более чем на 15 %.

7. Заключение

Проведенные эксперименты подтверждают применимость методики имитационного моделирования на основе обучающих данных к процессам фильтрации в гетерогенной пористой среде. Рассматриваемая архитектура ИНС в сочетании со специально разработанной процедурой обучения демонстрирует эффективное приближение к искомым характеристикам моделируемой системы. При этом вывод результатов ИНС на основании начальных условий требует в 30–60 раз меньшего времени вычислений в сравнении с численным методом.

Основным преимуществом методики имитационного моделирования на основе обучающих данных является ускорение параллельной обработки задач моделирования гидродинамических систем, в то время как классические численные методы лишь ограниченно поддаются алгоритмической параллелизации. Впрочем, следует отметить существование альтернативных направлений исследования, в частности связанных с матрицами-предобуславливателями [Naumov, 2011].

Предложенная архитектура ИНС с некоторыми модификациями может служить основой для построения высокоскоростных эвристических оценок характеристик гидродинамических систем в пористых средах. Как указывает Л. Косентино, многочисленные неопределенности, возникающие в процессе геолого-гидродинамического моделирования пластовых систем, делают малоосуществимым на практике имитационное моделирование всех вариантов, которые имело бы смысл рассматривать в процессе построения синтетических моделей, принципиально важных для современных процессов разработки месторождений [Косентино, 2007]. В практических условиях часто приходится ограничиваться рассмотрением всего нескольких вариантов, например «оптимистичного», «пессимистичного» и «промежуточного».

В этом свете доступность приближенных эвристических оценок может принести существенную пользу. Интересным направлением исследований также может быть определение множества вариантов эволюции гидродинамических систем с учетом существующих в геологической модели неопределенностей в соответствии с принципами «дифференцируемого программирования для физического моделирования» [Hu et al., 2019; Kingma, Ba, 2015], позволяющего объединять в сложных задачах оптимизации законы, управляющие физической системой и требования целевой функции.

К сожалению, машинное обучение в целом остается достаточно эмпирической областью науки, и уверенно говорить о возможностях той или иной модели можно только после проведения вычислительных экспериментов. Однако аналогия с другими исследованиями, рассматривающими турбулентную гидродинамику [Yang et al., 2016; Tompson et al., 2016], позволяет предположить что предложенная в настоящем исследовании архитектура в дальнейшем может быть успешно модифицирована для моделирования трехмерных систем (с помощью трехмерных сверточных слоев ИНС) и включения внешних движущих сил, например гравитации.

Принципы организации сверточных ИНС подсказывают некоторые другие очевидные направления развития, такие как возможность вводить в модель анизотропные характеристики проницаемости, задаваемые тензором для каждого расчетного блока, включение иных характеристик, таких как вторичная пористость, находящая применение в моделировании трещиновато-пористых коллекторов и т. п.

В целом методики имитационного моделирования на основе обучающих данных и развивающаяся область «дифференцируемого программирования» представляются перспективным направлением исследований в контексте геолого-гидродинамического моделирования. К очевидным недостаткам методологии относятся продолжительный процесс обучения и необходимость соблюдать известные ограничения для корректного функционирования обученной модели.

Список литературы (References)

- Баранов В. Е., Куреленков С. Х., Воробьева Л. В.* Прикладное моделирование пласта. — Издательство Томского политехнического университета, 2012. — 104 с.
Baranov V. E., Kurelenkov S. H., Vorob'eva L. V. Prikladnoe modelirovanie plasta [Applied collector modelling]. — Izdatel'stvo Tomskogo politekhnicheskogo universiteta, 2012. — 104 p. (in Russian).
- Каневская Р. Д.* Математическое моделирование гидродинамических процессов разработки месторождений углеводородов. — М.–Ижевск: ИКИ, 2002. — 140 с.
Kanevskaya R. D. Matematicheskoe modelirovanie gidrodinamicheskikh processov razrabotki mestorozhdenij uglevodorodov [Mathematical modelling of hydrocarbon collector exploitation hydrodynamics]. — Moscow–Izhevsk: IKI, 2002. — 140 p. (in Russian).
- Косентино Л.* Системные подходы к изучению пластов. — М.–Ижевск: Институт компьютерных исследований, 2007. — 400 с.
Cosentino L. Integrated reservoir studies. Editions TECHNIP, 2001. (Russ. ed.: Kosentino L. Sistemnye podkhody k izucheniyu plastov. — M.–Izhevsk: Institut komp'yuternykh issledovaniy, 2007.)
- Умановский А. В.* Состязательные сверточные нейронные сети в качестве эвристической модели процесса двухфазной фильтрации в пористой среде // Вычислительная механика сплошных сред. — 2020. — Т. 13, № 2. — С. 231–241.
Umanovskiy A. V. Sostyazatel'nye svertochnye nejronnye seti v kachestve evristicheskoy modeli processa dvuhfaznoj fil'tracii v poristoj srede [Generative adversarial neural networks for the heuristic modelling of a two-phase flow in porous media] // Computational Continuum Mechanics. — 2020. — Vol. 13, No. 2. — P. 231–241 (in Russian).
- Amini S., Mohaghegh S.* Application of Machine Learning and Artificial Intelligence in Proxy Modeling for Fluid Flow in Porous Media // Fluids. — 2019. — Vol. 4, No. 3. — P. 126.
- Brunton S. L., Noack B. R., Koumoutsakos P.* Machine Learning for Fluid Mechanics // Annu. Rev. Fluid Mech. — 2020. — Vol. 52, No. 1. — P. 477–508.
- Chen H., Klie H., Wang Q.* A black-box stencil interpolation method to accelerate reservoir simulations // Society of Petroleum Engineers — SPE Reservoir Simulation Symposium 2013. — 2013. — P. 537–552.
- Gorucu F. B. et al.* A Neurosimulation Tool for Predicting Performance in Enhanced Coalbed Methane and CO₂ Sequestration Projects // SPE Annual Technical Conference and Exhibition: Society of Petroleum Engineers. — 2005.
- Guo X., Li W., Iorio F.* Convolutional Neural Networks for Steady Flow Approximation // Autodesk Research // ACM SIGKDD Conference on Knowledge Discovery and Data Mining. — 2016. — P. 10.
- Gustavson S.* Simplex noise demystified. — 2005. — 17 p.
- Holl P., Koltun V., Thurey N.* Learning to Control PDEs with Differentiable Physics // Proceedings of Eighth International Conference on Learning Representation, ICLR, 2020.
- Hu Y. et al.* DiffTaichi: Differentiable Programming for Physical Simulation // 2019.
- Kingma D. P., Ba J. L.* Adam: A method for stochastic optimization // 3rd International Conference on Learning Representations, ICLR 2015 — Conference Track Proceedings. — 2015.
- Krogstad S. et al.* MRST-AD — an Open-Source Framework for Rapid Prototyping and Evaluation of Reservoir Simulation Problems // SPE Reservoir Simulation Symposium. Houston, Texas, USA: Society of Petroleum Engineers. — 2015. — P. 26.

- Ladický L. et al.* Data-driven fluid simulations using regression forests // ACM Trans. Graph. — 2015. — Vol. 34, No. 6. — P. 1–9.
- Liu W., Chawla S.* A Game Theoretical Model for Adversarial Learning // 2009 IEEE International Conference on Data Mining Workshops. — IEEE, 2009. — P. 25–30.
- Naumov M.* Incomplete-LU and Cholesky preconditioned iterative methods using CUSPARSE and CUBLAS // Nvidia white Pap. — 2011. — No. May. — P. 1–16.
- Sanchez-Gonzalez A. et al.* Learning to Simulate Complex Physics with Graph Networks // arXiv:2002.09405, 2020.
- Teixeira A. F., Secchi A. R.* Machine learning models to support reservoir production optimization // IFAC-PapersOnLine. — 2019. — Vol. 52, No. 1. — P. 498–501.
- Thuerey N. et al.* Deep Learning Methods for Reynolds-Averaged Navier–Stokes Simulations of Airfoil Flows // AIAA J. — 2020. — Vol. 58, No. 1. — P. 25–36.
- Tompson J. et al.* Accelerating Eulerian Fluid Simulation With Convolutional Networks // CoRR. — 2016. abs/1607.0. — P. 5258–5267.
- Werhahn M. et al.* A Multi-Pass GAN for Fluid Flow Super-Resolution // Proc. ACM Comput. Graph. Interact. Tech. — 2019. — Vol. 2, No. 2.
- Wiewel S., Becher M., Thuerey N.* Latent Space Physics: Towards Learning the Temporal Evolution of Fluid Flow // Comput. Graph. Forum. — 2019. — Vol. 38, No. 2. — P. 71–82.
- Xie Y. et al.* tempoGAN: A Temporally Coherent, Volumetric GAN for Super-resolution Fluid Flow // CoRR. — 2018. — T. abs/1801.0.
- Yang C., Yang X., Xiao X.* Data-driven projection method in fluid simulation // Comput. Animat. Virtual Worlds. — 2016. — Vol. 27, No. 3–4. — P. 415–424.