

DOI: [10.7242/1999-6691/2020.13.2.18](https://doi.org/10.7242/1999-6691/2020.13.2.18)

УДК 532.5

СОСТЯЗАТЕЛЬНЫЕ СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ В КАЧЕСТВЕ ЭВРИСТИЧЕСКОЙ МОДЕЛИ ПРОЦЕССА ДВУХФАЗНОЙ ФИЛЬТРАЦИИ В ПОРИСТОЙ СРЕДЕ

А.В. Умановский

Российский государственный университет нефти и газа (национальный исследовательский университет) имени И.М. Губкина, Москва, Российская Федерация

Имитационное моделирование на основе обучающих данных – перспективный подход к созданию эвристических моделей сложных физических систем. Согласно этому подходу множество весов искусственной нейронной сети оптимизируется с целью непосредственного предсказания характеристик расчетных блоков, в виде которых представляется исследуемая система. Подход впервые применен к задаче моделирования двухфазного течения в пористой среде, а именно для определения насыщенностей двух несмешивающихся фаз при их фильтрации в пространственной области в произвольный момент времени. Проведен вычислительный эксперимент, заключающийся в обучении глубокой сверточной нейронной сети состязательным методом с использованием статистических оценок отклонения от эталонных численных решений, выступающего в качестве целевой функции. Рассмотрены сеть оригинальной архитектуры и процесс обучения, включающий нетривиальную последовательность обновления весов подсетей, в частности двух кодировщиков и одного декодировщика-генератора. В рамках методологии состязательного обучения также использована сеть-дискриминатор с целевой функцией, отражающей задачу, противоречащую целевым функциям основных подсетей. Результаты обучения искусственной нейронной сети выбранной конфигурации доказали ее способность успешно генерализировать закономерности, усвоенные из набора обучающих данных. Разработанная методика, предполагающая наличие двух основных целевых функций для оптимизации множества весов каждой из подсетей, позволила эвристической модели достичь результатов, сопоставимых с эталонным имитационным моделированием двухфазного течения на основе численных методов. Специфика задач нефтегазодобывающей индустрии – неизбежное возникновение неопределенностей в геологических и гидродинамических моделях пласта, делает актуальными изыскания в области эвристических методов гидродинамического моделирования. Скорость вывода данных при расчете по разработанной модели для сравнимых значений точности выше скорости традиционных решений на 2–3 порядка. Это позволяет говорить о применимости предлагаемого синтетического моделирования к задачам прогнозирования месторождений углеводородов и планирования их разработки.

Ключевые слова: имитационное моделирование, пористая среда, гидродинамика, сверточные нейронные сети, состязательное обучение

GENERATIVE ADVERSARIAL NEURAL NETWORKS FOR THE HEURISTIC MODELLING OF A TWO-PHASE FLOW IN POROUS MEDIA

A.V. Umanovskiy

National University of Oil and Gas "Gubkin University", Moscow, Russian Federation

Data-driven simulation is a promising approach to the development of heuristic models of complex physical systems. Within this approach, an artificial neural network is trained to directly predict the dynamics of a hydrodynamic model. In this study the data-driven approach is successfully used to approximate saturations of every grid cell for a chosen timestep in a two-phase flow in a porous media setting. The uncertainties that inevitably arise in many specific tasks of the oil and gas industry make research of such heuristic methods highly relevant. In a computational experiment a deep convolutional neural net work is trained with the use of the adversarial training technique. The original architecture and training procedure are used for the training, including a non-trivial sequence of weight updating for the two encoder networks and one decoder/generator. Also, following the methodology of adversarial training, a discriminator network is used, the objective function for which is set to contradict the objective functions of the main training loop. The results of the experiment have proven the ability of the proposed architecture to successfully generalize patterns learned from a set of training data. The developed heuristic model obtains results that are comparable to the reference of traditional numerical simulation for the test initial conditions. The heuristic model exceeds the speed of traditional solvers by 2-3 orders of magnitude. The satisfactory accuracy of the heuristic model makes it applicable to the tasks of synthetic reservoir modelling.

Key words: data-driven simulation, porous media, hydrodynamics, adversarial neural networks, generative adversarial network (GAN)

1. Введение

Имитационное моделирование, основанное на анализе обучающих данных (data-driven simulation) — перспективный подход к исследованию сложных физических систем, в том числе гидродинамических [1]. Обсуждаемая в настоящей работе имитация с использованием машинного обучения позволяет предсказать результаты без экспериментов на реальном объекте и сравнить их с эталонными данными (данными классического имитационного моделирования с помощью численных методов, осуществляемого на базе моделей с физико-механическими свойствами объекта изучения, устанавливаемыми из физических опытов). Целевая функция, минимизируемая в процессе обучения, отражает невязку выводов предсказывающей модели и данных, взятых в качестве исходных (обучающих). Набор обучающих данных составляется из результатов эталонного моделирования

гидродинамической системы с различными краевыми условиями. В статье рассматривается применимость методологии имитационного моделирования с обучением к пластовым системам, в частности имеющим место в подземной гидродинамике.

Моделирование гидродинамических систем относится к числу ресурсоемких задач. Несмотря на рост доступности параллельных вычислений в последнее время, задачи подземной гидродинамики по-прежнему предъявляют высокие требования как к программным, так и аппаратным вычислительным ресурсам. В то же время возможность рассматривать большее число вариантов условий протекания того или иного гидродинамического процесса полезна для прогнозирования местоположения и планирования разработки залежей углеводородов в силу многочисленных неопределенностей, неизбежно существующих в этих процессах [2], что мотивирует изыскания в области эвристических техник.

Итак, объектом исследования является идеализированная двухфазная фильтрация в однородной пористой среде без учета влияния сжимаемости флюидов и породы, тепловых, геохимических и других факторов. Цель исследования — первичная оценка применимости методологии имитационного моделирования, основанного на анализе обучающих данных, к задачам подземной гидродинамики и сравнение полученных результатов с данными численного моделирования выбранной гидродинамической системы неявным методом из программного пакета MATLAB Reservoir Simulation Toolbox [3]. На данных имитационного моделирования, выполненного этим классическим последовательным методом, затем обучалась модель на основе глубоких сверточных искусственных нейронных сетей — модель ИНС, которая и должна была предсказать распределение насыщенностей во всех расчетных блоках системы на основе выбранных начальных условий, то есть известной конфигурации источников и стоков в пласте.

Результаты проведенного автором исследования подтверждают перспективность этого подхода. Скорость работы и приемлемая точность модели открывают возможности для разработки эвристических оценок на этой основе.

2. Релевантные работы

Современные изыскания на тему математического моделирования процессов фильтрации затрагивают такие направления, как адаптация алгоритмов численного решения к все более масштабным параллельным вычислениям [4, 5], изучение особенностей фильтрации в трещиновато-пористых средах [6], влияние специфических свойств породы (гетерогенности [7], многокомпонентности систем [8], поведения флюидов на границе раздела сред [9, 10]), а также построение аналитических и полуаналитических решений [11], впрочем, более востребованных для идеализированных случаев.

Временные промежутки (десятки и сотни миллионов секунд), свойственные практике, в сочетании с ограничением шага по времени, получаемым из условий устойчивости вычислений, затрудняют подробное классическое имитационное моделирование крупных пластовых систем. Рассмотрение многовариантных моделей, отвечающих неопределенностям геологических данных, становится трудно осуществимым в реальности. Ускорение расчетов стало мотивацией и одним из важнейших направлений исследований в области имитационного моделирования, основанного на анализе обучающих данных. Так, авторы [1] достигли увеличения скорости «лагранжевого» гидродинамического моделирования (метода сглаженных частиц) на 1–3 порядка. В случае более актуального для научно-исследовательской деятельности «эйлерова» моделирования для достижения этой цели успешно использовались техники, основанные на модификации ИНС со сверточными фильтрами ([12], а затем [13]) и системы, создающие сжатое отображение (кодировщик–декодировщик [14]) или осуществляющие соревновательное обучение [15].

Говоря о применении в имитационном моделировании физических систем различных техник, которые могут ассоциироваться, прежде всего, с распознаванием образов, стоит отметить, что речь не идет о программах, различающих некие конечные наборы возможных состояний. Скорее, процесс обучения ИНС создает статистическую модель гидродинамических явлений и с большой степенью вероятности оценивает взаимное влияние пространственно-временных областей, с учетом состояния системы в текущий момент времени. За счет этого и достигаются преимущества перед классическими численными методами [16].

Многие работы в этом направлении ориентируются на технологии, для которых приоритетом является скорость вычислений, в частности, на компьютерную графику и анимацию. В других исследованиях отмечается потенциал методологии с обучением в более точных расчетах, востребованных инженерными отраслями [17]. Различные техники машинного обучения давно применяются в нефтегазодобывающей области. Моделирование, основанное на анализе больших массивов данных, может стать основой научных исследований конкретных перспектив развития месторождений и создания их синтетических моделей в будущем [18].

Имитационное моделирование гидродинамических систем на основе обучающих данных остается на сегодняшний день довольно экзотическим подходом. Можно отметить работу [19], предлагающую обучаемую интерполяционную модель для оценки изменения давлений в пласте на основе начального состояния. Исследуется применение ИНС в качестве эвристической модели гидродинамических систем,

характеризующихся относительно малой нелинейностью (например [20, 21]). Однако методология с использованием обучения ориентирована на моделирование существенно нелинейных процессов, турбулентных или хаотических систем.

Как правило, в гидродинамике перед синтетическими моделями с машинным обучением ставится цель оценки непосредственно таких величин, как объемы добычи по истечению определенного времени, а не динамических характеристик процессов фильтрации. Так, в [22] без трудоемких численных расчетов с помощью «нейросимуляции» оценивается эффективность закачки углекислого газа в пласт. В недавней работе [23] к этой задаче с успехом применена новаторская методика, похожая на рассматриваемую в настоящей статье: ИНС, непосредственно предсказывающая динамические характеристики расчетных блоков, то есть давление, газонасыщенность и содержание CO_2 .

3. Физическая модель

Рассмотрим наиболее простой случай движения в гетерогенной пористой среде двух несжимаемых, несмешивающихся фаз (условной смачивающей $i = w$ и несмачивающей $i = n$) с пористостью m , который может быть описан системой гидродинамических уравнений:

$$\begin{cases} m \frac{\partial S_w}{\partial t} + \nabla \cdot v_w = Q_w, \\ m \frac{\partial S_n}{\partial t} + \nabla \cdot v_n = Q_n, \\ \nabla \cdot v = Q, \end{cases} \quad (1)$$

где векторное поле потока фазы i определяется по обобщенному закону Дарси $v_i = -\lambda_i \nabla p_i$ без гравитационной компоненты, так как рассматриваются двухмерные горизонтальные разрезы. Фазовая проводимость λ_i , помимо скалярной или тензорной величины проницаемости породы K и вязкости μ_i , зависит от переменной относительной проницаемости, в свою очередь являющейся функцией насыщенности смачивающей фазы S_w . Таким образом, λ_i тоже является функцией времени t :

$$\lambda_i = \frac{K k_r(S_w)}{\mu_i}. \quad (2)$$

Здесь k_r — относительная проницаемость пористой среды, определяемая, как правило, на основе только насыщенности смачивающей фазы.

Физическую модель (1), (2) применим для подготовки набора обучающих данных, то есть состояний полей насыщенности и давления, которые нужно рассчитать на основе классического численного метода и использовать далее в качестве эталона для сравнения с результатами работы ИНС при имитационном моделировании.

Для получения приближенных численных решений системы гидродинамических уравнений выберем шаг дискретизации по пространству и времени. Распространенным подходом к численному решению таких систем являются методы последовательного решения, основанные на разделении переменных в дифференциальных уравнениях. Систему уравнений двухфазной фильтрации с учетом капиллярного давления и предположения, что $S_w + S_n = 1$, можно свести к условию несжимаемости, единственному эллиптическому уравнению для давлений, решаемому неявно:

$$v = -(\lambda_n + \lambda_w) \nabla p_n - \lambda_w \nabla p_c, \quad (3)$$

где p_c обозначает капиллярную компоненту общего давления, и гиперболическому уравнению для насыщенностей, называемому также уравнением переноса или транспорта:

$$m \frac{\partial S_w}{\partial t} = -\nabla \cdot \left(\frac{\lambda_w}{\lambda_n + \lambda_w} (v + \lambda_n \nabla p_c) \right) + Q_w, \quad (4)$$

где Q_w — источники и стоки.

Для осуществления собственно физического (классического) имитационного моделирования, то есть нахождения приближенных решений дифференциальных уравнений с заданными начальными и граничными условиями, исследуемую пространственную область представим в виде дискретного аналога — сетки, в простейшем случае прямоугольной. Переменные величины аппроксимируем в отдельных узлах, или расчетных блоках сетки, — в центрах или на границах ее соответствующих ячеек, отражая интеграл искомой величины по данному конечному объему. Эволюцию системы во времени также представим как серию дискретных шагов Δt_i . Расчет на каждом таком «временном» слое включает две последовательных процедуры:

– решение уравнения для неявно выраженного давления на основе известных с предыдущего шага величин p , v и S_w ; представленное в дискретном виде уравнение (3) решается итеративно, например, методом Ньютона; находятся обновления полей p и v для всех фаз;

– вычисление в соответствии с (4) явным или неявным способом функции насыщенности $S_w(x, t + \Delta t)$ при неизменных значениях v и p_i .

Широко распространенным подходом к последовательному решению является метод IMPES (Implicit Pressure, Explicit Saturation formulation) [24], в котором неявно определяется давление и явно — насыщенности. Наиболее ресурсоемким шагом последовательного алгоритма в таком случае оказывается решение неявного уравнения для давления. Его дискретным представлением служит система N линейных уравнений (при N расчетных блоках сетки):

$$Ap = \nabla \cdot v + Q. \quad (5)$$

Матрица A системы (5) имеет характерную форму: 5- или 7-диагональную для случаев двух- или трехмерного моделирования соответственно. Итеративный поиск решений системы дает уверенность, что соблюдаются условия несжимаемости и распространения возмущений давления на всю моделируемую область. Этот процесс требует для вычислений на порядки большего времени, нежели явное обновление насыщенностей. Значительный выигрыш в скорости вычислений достигается за счет применения явной схемы для дискретизации по времени, но он отчасти нивелируется чрезмерно жесткими требованиями, налагаемыми условием стабильности Куранта–Фридрихса–Леви на размер шага по времени при использовании такой схемы.

Это мотивирует выбор полностью неявного алгоритма последовательного решения. Впрочем, к ограничению шага по времени прибегают и в этом случае, несмотря на его безусловную устойчивость. Слишком большой шаг приводит к чрезмерным погрешностям дискретизации; кроме того, увеличение размера шага влечет за собой рост числа итераций при решении неявных уравнений.

4. Процедура машинного обучения

Для проведения вычислительного эксперимента по обучению ИНС был подготовлен набор из результатов классического имитационного моделирования гидродинамических систем с 12500 вариантами начальных условий, полученных полностью неявным методом с помощью программного пакета MATLAB Reservoir Simulation Toolbox [3].

Расчет по имитационным моделям на сетке, состоящей из 128×128 расчетных блоков, длился 300 суток модельного времени и разделялся на 7 отдельных временных слоев с шагом в 50 суток. На текущем временном слое определялись картины распределения насыщенностей смачивающей фазы и давлений для каждого из вариантов начальных условий. При этом генерировалась случайная конфигурация расположения источников и стоков Q . Рассматривалось от 2 до 6 нагнетательных скважин с фиксированным значением расхода и от 2 до 6 добывающих скважин, работающих в «фонтанном» режиме. Нагнетательные скважины вводили в пласт только смачивающую фазу, добывающие, в силу забойного давления, извлекали обе фазы. На внешних границах расчетной области задавалось условие непротекания (нулевой расход каждой фазы).

В соответствии с методологией машинного обучения, помимо набора обучающих данных, аналогичным способом создается тестовый набор — вводится модель с иными начальными условиями. Тестовые данные не применяются в процессе настройки весов ИНС, но именно невязка предсказанных состояний системы с эталонными, полученными классическим методом на моделях с тестовыми начальными условиями, и служит оценкой успешности обучения. В данном случае 80% подготовленных моделей, то есть 10 тысяч конфигураций (70 тысяч отдельных временных слоев) используются для обучения ИНС; оставшиеся 20%, (2,5 тысячи конфигураций) послужили тестовым набором.

Для собственно обучения, то есть настройки весов ИНС, осуществляется процедура обратного распространения ошибки и оптимизация ADAM [25], реализованные средствами библиотеки PyTorch. Этот процесс, обычно применяемый для настройки весов нейронных сетей такого рода, заключается

в пошаговой модификации множества весов ω ИНС на основании дискретизированных частных производных целевой функции \mathcal{L} по ω .

Главная роль в обучении ИНС отдается автокодировщику, который использует невязку между входной матрицей насыщенностей — S_{true} , и выводимой ИНС — S_{gen} , в качестве целевой функции. Целью обучения, таким образом, является достижение максимального сходства, даже идентичности, результата ИНС и подаваемого на вход эталонного решения:

$$\mathcal{L}_{EG(S)} = \sqrt{\sum_N [G(E_S(S_{true}, \omega, N)) - S_{true}(N)]^2}. \tag{6}$$

Здесь целевая функция $\mathcal{L}_{EG(S)}$ отражает разности, точнее, L_2 -нормы полученных с помощью классического последовательного алгоритма матриц насыщенностей S_{true} и генерируемых обучаемой ИНС S_{gen} для каждого из N расчетных блоков системы. Работа алгоритма оптимизатора заключается в нахождении значений ω , минимизирующих $\mathcal{L}_{EG(S)}$. Способа определить глобальный минимум подобной функции для ИНС с миллионами весов не существует.

Во избежание тривиальных решений в автокодировщике используется принцип «бутылочного горла». Первая часть сети — кодировщик, выводит из входных данных сжатое отображение, здесь это 1024-мерный вектор q , затем на его основе вторая часть — генератор $G(q)$ получает S_{gen} . В данном случае ИНС-кодировщик E_S включает 6 операций свертки с окном фильтра 5×5 и единичным шагом, которые последовательно снижают размерность матрицы исходных данных S_{true} и увеличивают количество фильтров (см. Рис. 1).

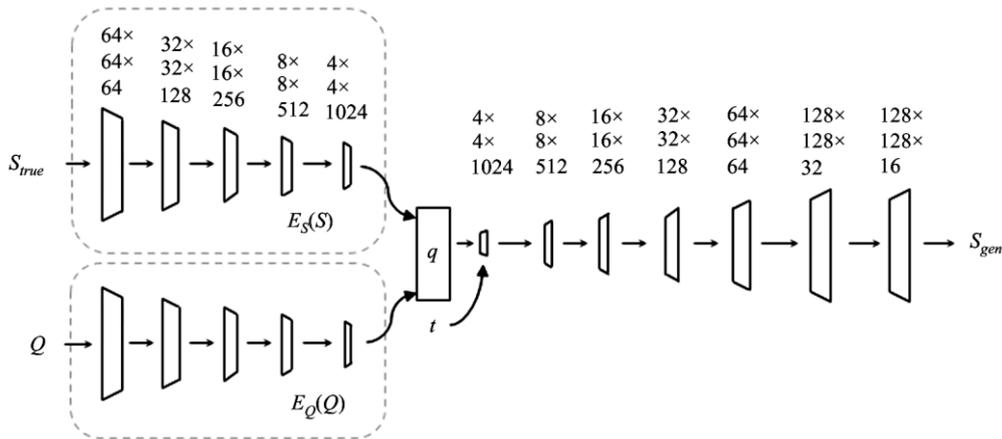


Рис. 1. Схема процедуры обучения искусственной нейронной сети

Генератор G включает 6 операций развертки, производящих обратное преобразование размерностей (веса его фильтров при этом не зависели от весов кодировщика); затем следуют 2 операции свертки 1×1 , уменьшающие исключительно число фильтров до получения единственного на выходных данных. Помимо вектора q , работа генератора обуславливается единственным числом t , соответствующим шагу по времени.

Характерной особенностью разработанного процесса обучения является применение в том же цикле второго кодировщика — E_Q . Архитектуры E_Q и E_S аналогичны, но на вход подается совсем другая информация — матрица Q , в которой ненулевые значения соответствуют исключительно расчётным блокам, содержащим источники или стоки. Веса подсети E_Q настраиваются отдельным оптимизатором, также влияющим на веса подсети G с целевой функцией

$$\mathcal{L}_{EG(Q)} = \sqrt{\sum_N [G(E_Q(Q, \omega, N)) - S_{true}(N)]^2}. \tag{7}$$

По окончании обучения на выводе, то есть при практическом приложении обученной ИНС к исследованию физической системы, кодировщик E_S не используется; единственными входами остаются Q и t .

В методологию обучения может включаться элемент состязательности. Еще одна ИНС — дискриминатор $D(S)$, схема которого дана на рисунке 2, призвана отличать сгенерированные матрицы насыщенностей от истинных. Дискриминатор включает 5 операций свертки и 2 полносвязных фильтра и выводит единственный бит информации. На выходе $D(S)$ выдает 1, если получает на входе истинную матрицу насыщенностей, и тогда целевая функция обучения

$$\mathcal{L}_{D(S)} = (1 - D_S(S_{true}))^2 + (D_S(S_{gen}))^2 \quad (8)$$

минимальна. При получении на входе продукта генератора $D(S)$ выдает 0.

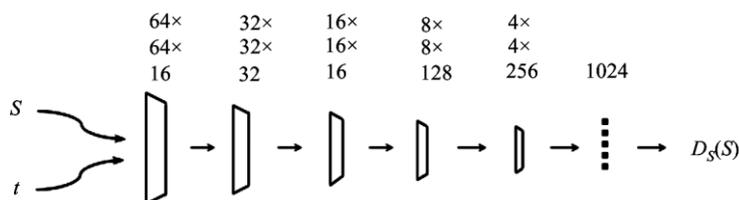


Рис 2. Сеть-дискриминатор D_S

На каждой итерации процедуры обучения (на так называемой эпохе) дискриминатор $D(S)$ стремится за счет оптимизации весов лучше различать истинные матрицы и сгенерированные. Однако в то же время другая функция, используемая для оптимизации весов основной ИНС, преследует противоположную цель: сделать результаты вывода неотличимыми от истинных. Целевая функция в этом случае имеет вид:

$$\mathcal{L}_{D-G} = (D_S(S_{true}))^2 + (1 - D_S(S_{gen}))^2. \quad (9)$$

Таким образом, процесс обучения ИНС управляется четырьмя целевыми функциями (6)–(9), при этом $\mathcal{L}_{EG(Q)}$, $\mathcal{L}_{EG(S)}$ и \mathcal{L}_{D-G} служат для настройки весов генератора, а $\mathcal{L}_{D(S)}$, \mathcal{L}_{D-G} — для настройки весов кодировщика E_S .

Для ускорения процесса вычислений первичное обучение ИНС проводилось на урезанном наборе эталонных данных, включающем только картину насыщенностей через 300 суток для каждого варианта начальных условий. Полный набор обучающих данных, превосходящий объем урезанного в 7 раз, подключался в момент, когда выводы ИНС без учета t уже достигали определенного качества.

5. Анализ результатов

Испытания обученной ИНС на тестовом наборе исходных данных показали (см. Рис. 3) практическую пригодность нейросетевого решения. ИНС корректно предсказывает картину распределения насыщенностей через выбранный промежуток времени на основе исключительно начальных условий модели (расположения источников и стоков в пласте) и запрашиваемого времени. Точность предсказания для тестового набора отстает от наблюдаемой в процессе обучения на незначительную величину, что в данной области расценивается как успех эксперимента. Иногда малозначимые детали истинной картины оказываются потерянными. Это хорошо видно на рисунке. Среднеквадратичное отклонение насыщенностей всех расчетных блоков в решении ИНС от соответствующих величин в численных решениях, служащее также целевой функцией потерь $\mathcal{L}_{EG(S)}$, в процессе обучения уменьшается от значения $\sim 0,6$ для тестового набора данных, соответствующего случайным образом инициализированным весам ИНС, до $\sim 0,007$. Детальный анализ качества использованных алгоритмов численного решения, в том числе сравнение с полуаналитическими решениями для специальных случаев, можно найти в [25].

В то время как осуществление имитационного моделирования для одной из конфигураций обучающего набора классическим методом требует порядка 1,5 секунд процессорного времени в реальном режиме, получение одной картины насыщенностей через ИНС занимает не более 0,05 с — на таком масштабе программу могут сильнее замедлять процессы перемещения данных в памяти, нежели сами вычисления.

Следует заметить, конечно, что если классическое имитационное моделирование выполняется центральным процессором, то вывод ИНС, как и ее обучение — процессором графической карты, значительно лучше приспособленным для выполнения параллельного программного кода. Тем не менее,

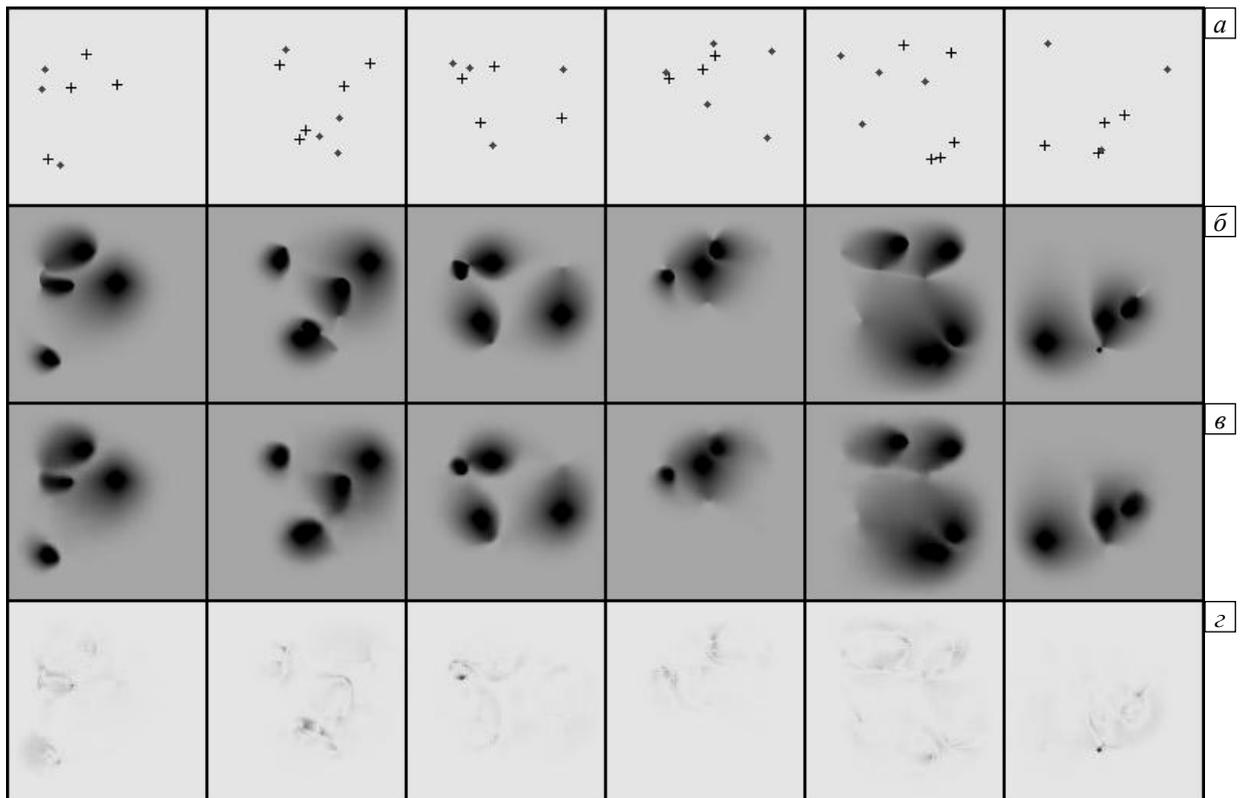


Рис. 3. Картины распределения насыщенностей двух фаз в слое пористой среды: схема расположения в момент времени $t=0$ источников (крестообразные маркеры) и стоков (круглые маркеры) (а); результаты при $t=300$ суток — классическое имитационное моделирование (эталонное) (б), на основе обученной ИНС (в), модуль разности результатов по ИНС и эталонного моделирования (г); ряды (б)–(г) окрашены с применением одной шкалы значений для наглядной иллюстрации степени отклонения

превосходство в скорости работы обученной программной системы позволяет говорить о потенциальных применениях таких эвристических оценок, недоступных с использованием только классических численных методов. Качество выдачи ИНС также не испытывает существенных изменений, если количество источников и стоков в процессе тестирования превышает их максимальное число в образцах из обучающего набора.

Хотя обучение ИНС происходило лишь на 7 временных срезах эволюции гидродинамической системы, разделяющих 300 суток модельного времени на равномерные промежутки, входной параметр генератора t задавался числом с плавающей точкой в промежутке от 0 до 1, где 1 соответствовало 300 суткам, 0 — начальному состоянию системы. Интересно отметить, что испытание ИНС на результатах дополнительного тестового моделирования с иным шагом по времени, в частности с шагом в 30 и 60 суток, показало лишь незначительное снижение точности относительно контрольных данных. На временных промежутках, существенно превышающих длительность модельного времени в обучающем наборе, данные на основе ИНС начинают быстро расходиться с более продолжительными тестовыми моделями, как и в случае значительного (на порядки) увеличения числа источников и стоков. Состязательный режим обучения и включение сети-дискриминатора придали ИНС способность корректно предсказывать нетривиальные особенности искомого поля насыщенностей.

Первоначальный вариант экспериментальной архитектуры — простой сверточный автокодировщик, соединяющий непосредственно входные данные Q с желаемой величиной S — в процессе продолжительного обучения так и не показал никаких удовлетворительных результатов. Дальнейшие эксперименты были нацелены на использование способности автокодировщика восстанавливать S из сжатого представления. Обученный в связке с кодировщиком E_s генератор G подключался к новому кодировщику E_o . Затем велось обучение только E_o ; веса генератора, успешно восстанавливающего сжатые представления, оставались «замороженными». В этом случае результат работы всей системы начинал медленно приближаться к искомому результату, но перед новым кодировщиком стояла, можно сказать, задача подбора кодировки, сформированной в иной задаче, и продолжительное обучение так и не привело к способности устойчиво предсказывать результаты имитационного моделирования.

Исходя из этого сформулирована авторская процедура поочередного обучения, которая привела к успеху. В рамках каждой итерации цикла обучения проход от кодировщика E_s к генератору G оптимизирует веса G для конкретного образца, точнее, партии образцов. Затем проход от кодировщика

E_Q и генератора, пусть и не приводит к удовлетворительной выдаче на первых стадиях обучения, но, тем не менее, подталкивает G и E_S использовать сжатое представление q , «понятное» кодировщику E_Q . При этом процесс обучения автокодировщика для S незначительно замедляется, так как E_Q влияет как на работу генератора, так и на определение «языка», на котором записывается q ; в результате такой организации процесса по истечению 100 эпох обучения кодировщик E_Q может работать с G после отключения E_S и выдавать качественные предсказания S на основе только входных сведений Q и t .

Практический опыт выявил также преимущество двухэтапного обучения. Усеченный обучающий набор гораздо компактнее полного и лучше подходит для первичного обучения ИНС. При работе с полным набором каждая эпоха обучения занимает гораздо больше времени. На рисунке 4 вертикальной чертой отмечен переход от усеченного набора к дообучению на полном наборе. Хорошо видно циклическое поведение функции невязки дискриминатора $D(S)$. Улучшение качества работы связки кодировщик–генератор приводит к снижению этого числа; затем дискриминатор обнаруживает новый набор признаков, позволяющих различить успешное предсказание и ошибку.

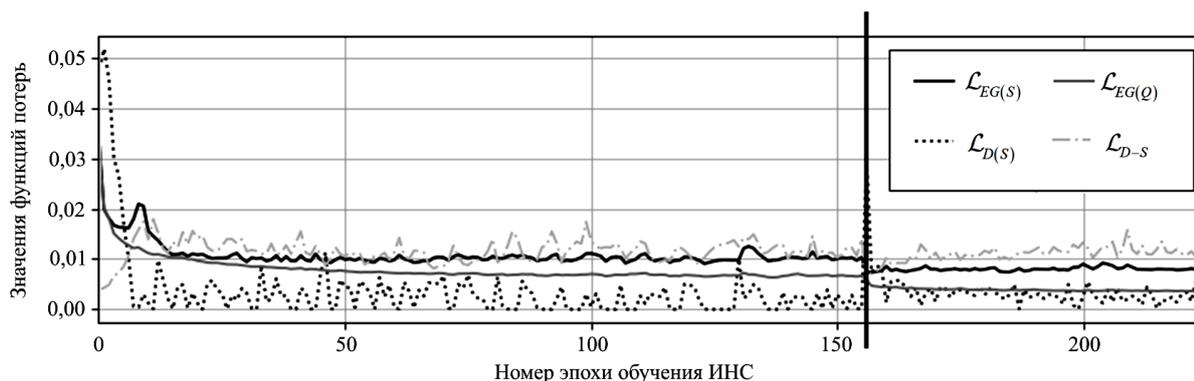


Рис. 4. Графики изменения значений функций невязки ИНС в процессе обучения; полужирная вертикальная черта отмечает переход к обучению с учетом t

Интересен факт, что закон Дарси, описывающий движение флюида в пористой среде, имеет ту же форму, что и некоторые известные уравнения, например закон Фурье для теплопроводности и закон Ома для электрического тока. Это указывает возможные сферы применения обучаемой ИНС для эвристической оценки иных физических явлений, в особенности, если будут условия для введения в модель характеристик, подобных гетерогенной проницаемости породы. Действительно, недавние исследования подтверждают пригодность методологии имитационного моделирования на основе обучающих данных к различным физическим системам, характеризующимся нелинейным и хаотическим, но в некоторой мере предсказуемым поведением (см. например [26, 27]). Успешность эвристического анализа многих видов данных с помощью ИНС — следствие способности этих моделей аппроксимировать произвольные нелинейные зависимости [28], то есть в данном случае любые алгоритмически разрешимые [29]. Применение к этой методологии подчас подвергаемого критике термина «искусственный интеллект» в этом свете выглядит небезосновательным. Процесс машинного обучения выполняет действия, похожие на работу исследователя: выявляет и обобщает закономерности, в том числе не слишком очевидные или специфические.

Методов анализа, которые позволили бы сформулировать или доказать некие ограничения устойчивости или корректности решений ИНС, подобно тому, как оценивается гладкость решений эллиптического дифференциального уравнения для давлений, в данный момент не существует. Пригодность/непригодность решений, получаемых таким образом, на данном этапе можно установить только путем сравнения с тестовым набором данных, то есть статистически. Отсутствие или даже невозможность [29] строгого доказательства корректности решения является существенным недостатком обсуждаемого в данной статье метода. По всей видимости, это означает, что методы имитационного моделирования, основанные на анализе обучающих данных, применимы скорее для предварительных эвристических оценок, нежели в качестве непосредственной замены численных решений.

6. Заключение

Проведенное исследование подтвердило возможность применения сверточной ИНС, состоящей из кодировщика и генератора, обученной с использованием состязательного принципа и оригинальной комплексной процедуры с двумя сетями–кодировщиками, для эвристической оценки насыщенностей, присущих двухфазному течению в пористой среде. Имитационное моделирование физических систем,

основанное на анализе обучающих данных, является сравнительно новым и малоисследованным подходом, применяемым пока преимущественно для сокращения объема вычислительных ресурсов. Тем не менее, особенности этой методологии могут представлять интерес для научного исследования, в том числе в практических задачах, например для предсказания расположения месторождений. В свете существования большого числа неопределенностей при моделировании пластовых систем рассмотрение более гибких, даже в ущерб точности, методов также не лишено смысла.

Свойства ИНС как универсального аппроксиматора подсказывают некоторые пути дальнейшего развития настоящего исследования. Например, перед ИНС можно поставить задачу предсказания эволюции более сложной математической модели, включающей гетерогенность пористой среды, сжимаемость движущихся фаз и породы, межфазный массоперенос, тепловые эффекты и гравитацию. Исходя из опыта исследований в области имитационного моделирования на основе обучающих данных можно создать ИНС с трехмерными сверточными фильтрами. В случае трехмерных моделей ускорение расчетов — еще более актуальная задача. Если в данной работе источники и стоки предполагались имеющими неизменные значения, не представляет труда соединение этих значений с даже весьма сложными моделями проектной эксплуатации месторождения. Вполне вероятно, что ИНС обнаружит способность эффективно предсказывать будущее и таких, более сложных нелинейных систем. В этом случае возможно ее использование для эвристической оценки перспективности тех или иных конфигураций из числа добывающих и нагнетательных скважин. Такая эвристика в свою очередь может быть включена в целевую функцию другой оптимизационной задачи — поиска наиболее экономически выгодного плана эксплуатации.

Еще более привлекательной выглядит возможность комплексной оценки многочисленных неопределенностей, возникающих в геологических и геофизических моделях пласта, создание вероятностных моделей, оптимизирующих решение для целой группы возможных ситуаций. Решение подобных задач часто входит в круг перспективных исследований в области синтетического моделирования месторождений. Так, в [30] обучение модели преследовало двойную цель: спрогнозировать уровень добычи, а также смоделировать распределения давления и газонасыщенности в условиях неопределенной проницаемости и переменных режимов работы нагнетательных скважин. Среди релевантных исследований стоит отметить применение техник машинного обучения для восстановления неизвестных характеристик пласта на основе записей колебаний давления [31], воспроизведения истории разработки месторождения [32] и исследования специфических трещиноватых сланцевых пород [33]. Использование методологии имитационного моделирования, основанного на анализе обучающих данных, позволяет в некоторой мере включать гидродинамические процессы в формулировку оптимизационных задач, стоящих перед синтетическим моделированием.

Литература

1. *Ladicky L., Jeong S., Solenthaler B., Pollefeys M., Gross M.* Data-driven fluid simulations using regression forests // ACM Transactions on Graphics. 2015. Vol. 34. 199. <https://doi.org/10.1145/2816795.2818129>
2. *Cosentino L.* Integrated reservoir studies. New-York: Editions TECHNIP, 2001. 336 p.
3. *Krogstad S., Lie K., Møyner O., Nilsen H., Raynaud X., Skaflestad B.* MRST-AD – an open-source framework for rapid prototyping and evaluation of reservoir simulation problems. Houston, USA: Society of Petroleum Engineers, 2015. 26 p. <https://doi.org/10.2118/173317-MS>
4. *Губайдуллин Р.Р., Ретин Н.В., Юлдашев А.В.* Опыт применения графических процессоров для решения разреженных систем линейных алгебраических уравнений в рамках задачи гидродинамического моделирования нефтегазовых месторождений // Вестник УГАТУ. 2015. Т. 19, № 4(70). С. 118-123.
5. *Васильев В.И., Васильева М.В., Никифоров Д.Я.* Решение задач однофазной фильтрации методом конечных элементов на вычислительном кластере // Вестник СВФУ. 2016. № 6(56). С. 31-40.
6. *Васильева М.В., Васильев В.И., Тырылгин А.А.* Консервативная разностная схема для задач фильтрации в трещиноватых средах // Математические заметки СВФУ. 2018. Т. 25, № 4. С. 84-101.
7. *Каневская Р.Д., Исакова Т.Г., Коробкин, С.В., Будкин К.Д., Маркова А.Ю., Любимова О.В., Рафиков Р.Я.* Влияние переменной смачиваемости карбонатного пласта на распределение нефтенасыщенности // Нефтяное хозяйство. 2017. № 10. С. 22-27. <https://doi.org/10.24887/0028-2448-2017-10-22-27>
8. *Любимова Т.П., Зубова Н.А.* Возникновение и нелинейные режимы конвекции трехкомпонентной смеси в прямоугольной области пористой среды с учетом эффекта Core // Вычисл. мех. сплош. сред. 2019. Т. 12, № 3. С. 249-262. <https://doi.org/10.7242/1999-6691/2019.12.3.21>
9. *Циберкин К.Б.* Двумерные течения в каналах ограниченной ширины, частично заполненных пористой средой // Вычисл. мех. сплош. сред. 2018. Т. 11, № 4. С. 438-447. <https://doi.org/10.7242/1999-6691/2018.11.4.34>
10. *Сираев Р.Р.* Фильтрация жидкости в пористой среде Фордгеймера с пространственно неоднородными пористостью и проницаемостью // Вычисл. мех. сплош. сред. 2019. Т. 12, № 3. С. 281-292. <https://doi.org/10.7242/1999-6691/2019.12.3.24>
11. *Токарева М.А.* О глобальной разрешимости задачи о движении вязкой жидкости в деформируемой вязкой пористой среде // Известия АлтГУ. 2020. № 1(111). С. 133-138. [https://doi.org/10.14258/izvasu\(2020\)1-23](https://doi.org/10.14258/izvasu(2020)1-23)
12. *Yang C., Yang X., Xiao X.* Data-driven projection method in fluid simulation // Computer Animation and Virtual Worlds. 2016. Vol. 27. P. 415-424. <https://doi.org/10.1002/cav.1695>

13. *Tompson J., Schlachter K., Sprechmann P., Perlin K.* Accelerating Eulerian fluid simulation with convolutional networks. <https://arxiv.org/abs/1607.03597v6>
14. *Wiewel S., Becher M., Thuerey N.* Latent space physics: towards learning the temporal evolution of fluid flow // *Computer Graphics Forum*. 2019. Vol. 38. No. 2. P. 71-82. <https://doi.org/10.1111/cgf.13620>
15. *Xie Y., Franz E., Chu M., Thuerey N.* tempoGAN: A temporally coherent, volumetric GAN for super-resolution fluid flow // *ACM Transactions on Graphics*. 2018. Vol. 37. 95. <https://doi.org/10.1145/3197517.3201304>
16. *Thuerey N., Weißenow K., Prantl L., Hu X.* Deep learning methods for Reynolds-averaged Navier–Stokes simulations of airfoil flows // *AIAA Journal*. 2020. Vol. 58. P. 25-36. <https://doi.org/10.2514/1.J058291>
17. *Guo X., Li W., Iorio F.* Convolutional neural networks for steady flow approximation // *Proc. of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. KDD'16, San Francisco, California, USA, August 13-17, 2016*. P. 481-490. <https://doi.org/10.1145/2939672.2939738>
18. *Harrison G.H., Safar F.* Harness oil and gas big data with analytics: optimize exploration and production with data-driven models. Wiley, 2019. 384 p.
19. *Chen H., Klie H., Wang Q.* A black-box interpolation method to accelerate reservoir simulation solutions // *Proc. of the SPE Reservoir Simulation Symposium. Woodlands, Texas, USA, February 18-20, 2013*. SPE 163614. <https://doi.org/10.2118/163614-MS>
20. *Некрасов И.В., Жагфаров И.Ф., Должин М.В.* Адаптация математической модели магистрального нефтепровода как процесс обучения нейронной сети // *Транспорт и хранение нефтепродуктов и углеводородного сырья*. 2018. № 4. С. 22-31. <https://doi.org/10.24411/0131-4270-2018-10404>
21. *Агафонов Е.Д., Ващенко Г.В.* Имитационная эвристическая модель магистрального нефтепровода // *Изв. ТулГУ. Технические науки*. 2016. № 3. С. 195-203.
22. *Gorucu F.B., Ertekin T., Bromhal G., Smith D., Sams W., Jikich S.* A neurosimulation tool for predicting performance in enhanced coalbed methane and CO₂ sequestration projects // *Proc. of the SPE Annual Technical Conference and Exhibition. Dallas, Texas, USA, October 9-12, 2005*. SPE 97164. <https://doi.org/10.2118/97164-MS>
23. *Amini S., Mohaghegh S.* Application of machine learning and artificial intelligence in proxy modeling for fluid flow in porous media // *Fluids*. 2019. Vol. 4. 126. <https://doi.org/10.3390/fluids4030126>
24. *Lie K.-A.* An introduction to reservoir simulation using MATLAB/GNU Octave. Cambridge University Press: 2019. 660 p. <https://doi.org/10.1017/9781108591416>
25. *Kingma D.P., Ba J.L.* Adam: a method for stochastic optimization. <https://arxiv.org/abs/1412.6980>
26. *Breen P.G., Foley C., Boeholt T., Zwart S.* Newton vs the machine: solving the chaotic three-body problem using deep neural networks // *Mon. Not. Roy. Astron. Soc.* 2020. Vol. 494. P. 2465-2470. <https://doi.org/10.1093/mnras/staa713>
27. *He S., Li Y., Feng Y., Ho S., Ravanbakhsh S., Chen W., Póczos B.* Learning to predict the cosmological structure formation // *PNAS*. 2019. Vol. 116, no. 28. P. 13825-13832. <https://doi.org/10.1073/pnas.1821458116>
28. *Csáji B.* Approximation with artificial neural networks / MSc Dissertation. Budapest: Eötvös Loránd University, 2011. 45 p.
29. *Kasabov N.K.* Kasabov N.K. Foundations of neural networks, fuzzy systems, and knowledge engineering // *Choice Reviews Online*. 1997. № 01 (35). С. 35-0330-35-0330. <https://doi.org/10.5860/choice.35-0330>
30. *Klie H.* Unlocking fast reservoir predictions via nonintrusive reduced-order models // *Proc. of the SPE Reservoir Simulation Symposium. Woodlands, Texas, USA, February 18-20, 2013*. SPE 163584. <https://doi.org/10.2118/163584-MS>
31. *Alajmi M.N., Ertekin T.* The development of an artificial neural network as a pressure transient analysis tool for applications in double-porosity reservoirs // *Proc. of the Asia Pacific Oil and Gas Conference and Exhibition. Jakarta, Indonesia, 30 October-1 November, 2007*. SPE 108604. <https://doi.org/10.2118/108604-MS>
32. *Shahkarami A., Mohaghegh S.D., Hajizadeh Y.* Assisted history matching using pattern recognition technology // *Int. J. Oil Gas Coal Tech.* 2018. Vol. 17. P. 412-442. <https://doi.org/10.1504/IJOGCT.2018.090966>
33. *Klie M., Florez H.* Data-driven modeling of fractured shale reservoirs // *Proc. of the 16th European Conference on the Mathematics of Oil Recovery. ECMOR XVI, Barcelona, Spain, September 3-6, 2018*. <https://doi.org/10.3997/2214-4609.201802234>

References

1. *Ladicky L., Jeong S., Solenthaler B., Pollefeys M., Gross M.* Data-driven fluid simulations using regression forests. *ACM Transactions on Graphics*, 2015, vol. 34, 199. <https://doi.org/10.1145/2816795.2818129>
2. *Cosentino L.* *Integrated reservoir studies*. New-York: Editions TECHNIP, 2001. 336 p.
3. *Krogstad S., Lie K., Møyner O., Nilsen H., Raynaud X., Skaflestad B.* *MRST-AD – an open-source framework for rapid prototyping and evaluation of reservoir simulation problems*. Houston, USA: Society of Petroleum Engineers, 2015. 26 p. <https://doi.org/10.2118/173317-MS>
4. *Gubajdullin R.R., Repin N.V., Yuldashev A.V.* *Opyt primeneniya graficheskikh protsessorov dlya resheniya razrezhennykh sistem lineynykh algebraicheskikh uravneniy v ramkakh zadachi gidrodinamicheskogo modelirovaniya neftegazovykh mestorozhdeniy* [Using the GPU for linear systems solving in reservoir simulation tasks]. *Vestnik UGATU – Vestnik USATU*, 2015, vol. 19, no. 4(70), pp. 118-123.
5. *Vasil'ev V.I., Vasil'eva M.V., Nikiforov D.Ya.* Solving one phase filtration problems using finite element method on computing cluster. *Vestnik SVFU – Vestnik of NEFU*, 2016, № 6(56), pp. 31-40.
6. *Vasilyeva M.V., Vasil'ev V.I., Tyrylgina A.A.* Conservative difference scheme for filtering problems in fractured media. *Matematicheskiye zametki SVFU – Mathematical Notes of NEFU*, 2018, vol. 25, no. 4, pp. 84-101.
7. *Kanevskaya R.D., Isakova T.G., Korobkin S.V., Budkin K.D., Markova A.Yu., Lyubimova O.V., Rafikov R.Ya.* Impact of the variable wettability of the complex carbonate reservoir on oil saturation distribution. *Neftyanoye khozyaystvo – Oil Industry*, 2017, no. 10, pp. 22-27. <https://doi.org/10.24887/0028-2448-2017-10-22-27>

8. Lyubimova T.P., Zubova N.A. Onset and nonlinear regimes of convection of ternary mixture in a rectangular porous cavity taking into account Soret effect. *Vychisl. mekh. splosh. sred – Computational Continuum Mechanics*, 2019, vol. 12, no. 3, pp. 249-262. <https://doi.org/10.7242/1999-6691/2019.12.3.21>
9. Tsiberkin K.B. Two-dimensional flows in finite-width channels partially filled with porous medium. *Vychisl. mekh. splosh. sred – Computational Continuum Mechanics*, 2018, vol. 11, no. 4, pp. 438-447. <https://doi.org/10.7242/1999-6691/2018.11.4.34>
10. Siraev R.R. Fluid transport in Forchheimer porous medium with spatially varying porosity and permeability. *Vychisl. mekh. splosh. sred – Computational Continuum Mechanics*, 2019, vol. 12, no. 3, pp. 281-292. <https://doi.org/10.7242/1999-6691/2019.12.3.24>
11. Tokareva M.A. On global solvability of a problem of a viscous liquid motion in a deformable viscous porous medium. *Izvestiya AltGU*, 2020, no. 1(111), pp. 133-138. [https://doi.org/10.14258/izvasu\(2020\)1-23](https://doi.org/10.14258/izvasu(2020)1-23)
12. Yang C., Yang X., Xiao X. Data-driven projection method in fluid simulation. *Computer Animation and Virtual Worlds*, 2016, vol. 27, pp. 415-424. <https://doi.org/10.1002/cav.1695>
13. Tompson J., Schlachter K., Sprechmann P., Perlin K. Accelerating Eulerian fluid simulation with convolutional networks. <https://arxiv.org/abs/1607.03597v6>
14. Wiewel S., Becher M., Thuerey N. Latent space physics: towards learning the temporal evolution of fluid flow. *Computer Graphics Forum*, 2019, vol. 38, no. 2, pp. 71-82. <https://doi.org/10.1111/cgf.13620>
15. Xie Y., Franz E., Chu M., Thuerey N. tempoGAN: A temporally coherent, volumetric GAN for super-resolution fluid flow. *ACM Transactions on Graphics*, 2018, vol. 37, 95. <https://doi.org/10.1145/3197517.3201304>
16. Thuerey N., Weissenow K., Prantl L., Hu X. Deep learning methods for Reynolds-averaged Navier–Stokes simulations of airfoil flows. *AIAA Journal*, 2020, vol. 58, pp. 25-36. <https://doi.org/10.2514/1.J058291>
17. Guo X., Li W., Iorio F. *Proc. of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. KDD'16, San Francisco, California, USA, August 13-17, 2016. P. 481-490.* <https://doi.org/10.1145/2939672.2939738>
18. Harrison G.H., Safar F. *Harness oil and gas big data with analytics: Optimize exploration and production with data-driven models.* Wiley, 2019. 384 p.
19. Chen H., Klie H., Wang Q. *Proc. of the SPE Reservoir Simulation Symposium. Woodlands, Texas, USA, February 18-20, 2013. 163614.* <https://doi.org/10.2118/163614-MS>
20. Nekrasov I.V., Zhagfarov I.F., Dolzhin M.V. Trunk pipeline as the process of training the neural network. *Transport i khraneniye nefteproduktov i uglevodorodnogo syr'ya – Transport And Storage Of Oil Products And Hydrocarbons*, 2018, no. 4, pp. 22-31. <https://doi.org/10.24411/0131-4270-2018-10404>
21. Agafonov E.D., Vashenko G.V. Heuristic simulation model of trunk pipeline. *Izv. TulGU. Tekhnicheskiye nauki – Proceedings of the TSU*, 2016, no. 3, pp. 195-203.
22. Gorucu F.B., Ertekin T., Bromhal G., Smith D., Sams W., Jikich S. *Proc. of the SPE Annual Technical Conference and Exhibition. Dallas, Texas, USA, October 9-12, 2005. SPE 97164.* <https://doi.org/10.2118/97164-MS>
23. Amini S., Mohaghegh S. Application of machine learning and artificial intelligence in proxy modeling for fluid flow in porous media. *Fluids*, 2019, vol. 4, 126. <https://doi.org/10.3390/fluids4030126>
24. Lie K.-A. *An introduction to reservoir simulation using MATLAB/GNU Octave.* Cambridge University Press, 2019. 660 p. <https://doi.org/10.1017/9781108591416>
25. Kingma D.P., Ba J.L. Adam: a method for stochastic optimization. <https://arxiv.org/abs/1412.6980>
26. Breen P.G., Foley C., Boekholt T., Zwart S. Newton vs the machine: solving the chaotic three-body problem using deep neural networks. *Mon. Not. Roy. Astron. Soc.*, 2020, vol. 494, pp. 2465-2470. <https://doi.org/10.1093/mnras/staa713>
27. He S., Li Y., Feng Y., Ho S., Ravanbakhsh S., Chen W., Póczos B. Learning to predict the cosmological structure formation. *PNAS*, 2019, vol. 116, no. 28, pp. 13825-13832. <https://doi.org/10.1073/pnas.1821458116>
28. Csáji B. *Approximation with artificial neural networks.* MSc Dissertation, Budapest: Eötvös Loránd University, 2011. 45 p.
29. Kasabov N.K. Foundations of neural networks, fuzzy systems, and knowledge engineering. *Choice Reviews Online*, 1997, vol. 35, no. 01, pp. 35-0330-35-0330. <https://doi.org/10.5860/choice.35-0330>
30. Klie H. *Proc. of the SPE Reservoir Simulation Symposium. Woodlands, Texas, USA, February 18-20, 2013. SPE 163584.* <https://doi.org/10.2118/163584-MS>
31. Alajmi M.N., Ertekin T. *Proc. of the Asia Pacific Oil and Gas Conference and Exhibition. Jakarta, Indonesia, 30 October-1 November, 2007. SPE 108604.* <https://doi.org/10.2118/108604-MS>
32. Shahkarami A., Mohaghegh S.D., Hajizadeh Y. Assisted history matching using pattern recognition technology. *Int. J. Oil Gas Coal Tech.*, 2018, vol. 17, pp. 412-442. <https://doi.org/10.1504/IJOGCT.2018.090966>
33. Klie M., Florez H. *Proc. of the 16th European Conference on the Mathematics of Oil Recovery. ECMOR XVI, Barcelona, Spain, September 3-6, 2018.* <https://doi.org/10.3997/2214-4609.201802234>

Поступила в редакцию 12.06.2020; после доработки 05.07.2020; принята к опубликованию 11.07.2020

Сведения об авторе

Умановский Арсений Вячеславович, асп., Российский государственный университет нефти и газа (национальный исследовательский университет) имени И.М. Губкина (РГУ нефти и газа (НИУ) имени И.М. Губкина), 119991, г. Москва, Ленинский пр., д. 65, корп. 1; e-mail: lynx.ff@gmail.com