

Арсений Вячеславович УМАНОВСКИЙ¹

УДК 662.5

ГРАФОВЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ ПРОКСИ-МОДЕЛИРОВАНИЯ ГИДРОДИНАМИКИ ПЛАСТА

¹ аспирант, РГУ Нефти и Газа (НИУ) им. И. М. Губкина, Москва
lynx.ff@gmail.com

Аннотация

Основной задачей гидродинамического моделирования пласта является предсказание показателей работы добывающих скважин в будущем, точнее, зависимости этих показателей от выбора тех или иных воздействий на пласт, от плана разработки месторождения. Решение данной задачи затрудняется недостатком точных сведений о свойствах пласта, заключение о которых приходится так или иначе делать из косвенных данных, прежде всего из исторических показателей уже функционирующих скважин. Эта информация используется для адаптации численной модели пласта, или прокси-моделей, менее информативных, но имеющих преимущества скорости и гибкости.

В статье предлагается метод прокси-моделирования пласта, основанный на использовании специфической искусственной нейронной сети (ИНС). Особенность предложенного метода — инновационная графовая сверточная архитектура ИНС, принимающая входные данные в формате графа, вершинам и ребрам которого сопоставлены известные характеристики пласта наряду с историей функционирования скважин. Такая архитектура делает возможным обучение ИНС не для одного конкретного случая, но для целого класса ситуаций. В соответствии с принципами развивающегося направления нейросетевых моделей физических процессов (Physics-Informed Neural Networks, PINN), задачей ИНС является вывод не просто корреляции между зависимыми вели-

Цитирование: Умановский А. В. Графовые нейронные сети для прокси-моделирования гидродинамики пласта / А. В. Умановский // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2022. Том 8. № 3 (31). С. 155-177.
DOI: 10.21684/2411-7978-2022-8-3-155-177

чинами, но более общего физического закона, обуславливающего такие корреляции в различных случаях. Преимуществами такого подхода перед большинством применяемых сегодня прокси-моделей, основанных на ИНС, являются, во-первых, скорость: адаптация к историческим данным и вывод прогноза не требуют трудоемкого обучения, и даже для сотен скважин осуществляются за секунды; во-вторых, определенная степень физической содержательности.

Ключевые слова

Геолого-гидродинамическое моделирование, автоматизированная адаптация, нейросетевые модели физических процессов, прокси-моделирование пласта.

DOI: 10.21684/2411-7978-2022-8-3-155-177

Введение

Адекватное гидродинамическое моделирование способно кардинально повысить эффективность разработки нефтяных и газовых месторождений. Первоначальная гидродинамическая модель может быть построена еще до того, как пробурена первая скважина; как правило, однако, именно данные об истории функционирования скважин предоставляют наиболее актуальную картину характеристик пласта. Возможности адаптации модели к этим историческим данным (что также называется воспроизведением истории разработки) играют определяющую роль в выборе средств гидродинамического моделирования пласта.

Математически задача воспроизведения истории разработки формулируется как обратная задача гидродинамики. Прямой задачей называют предсказание эволюции гидродинамической системы на основании начальных и краевых условий: в случае пласта — характеристик проницаемой среды, объемов и давлений, числа и свойств движимых флюидов, движущих сил и т. д. Обратная задача — выявление начальных условий, в случае задания которых гидродинамическая система демонстрировала бы определенное поведение, как раз то, которое наблюдается на практике.

Обратная задача гидродинамики характеризуется как математически некорректная: число неизвестных здесь превосходит число вводных, один и тот же наблюдаемый феномен может иметь несколько возможных объяснений и причин. Это свойство задачи не делает ее неразрешимой на практике, но не позволяет доказать оптимальность конкретного численного решения.

Применяется ряд подходов к задаче автоматизированного воспроизведения истории разработки. Некоторые из них направлены на подстройку характеристик сложной численной гидродинамической модели (симулятора) в трех измерениях, наиболее полно отражающей свойства реальной системы. Другие работают с *прокси-моделями*, которые менее точно соответствуют моделируемой системе, но имеют существенные преимущества в гибкости и скорости расчетов.

В данной статье рассматривается инновационный способ моделирования гидродинамики пласта с применением специфической архитектуры искусственной нейронной сети (ИНС) для непосредственного предсказания дебитов множества добывающих скважин на основе исторических данных о давлениях и дебитах в прошлом, режимов работы нагнетательных скважин в прошлом и плане их работы в будущем, и взаимного расположения скважин в трех измерениях.

Методы исследования

Предлагаемая прокси-модель пласта (далее: ИНС-модель) использует оригинальную мультимодальную графовую сверточную архитектуру для учета сведений о положении скважин относительно друг друга. Предварительное обучение ИНС-модели проводится не для конкретного исследуемого пласта, но заранее, для целого класса ситуаций, на наборе синтетических учебных образцов, созданном с помощью традиционного численного симулятора. Задачей предварительного обучения является определение принципов, которые могут связывать исторические показатели добывающих и нагнетательных скважин в зависимости от их пространственного расположения. Таким образом обученная ИНС-модель содержит некое представление о поведении самой физической системы, управляемой законами гидродинамики. Это отличает предлагаемую ИНС-модель от других основанных на ИНС методов прокси-моделирования.

Собственно, адаптация ИНС-модели к конкретным историческим данным не требует обучения в значении настройки весов нейронов сети. Генеративная архитектура позволяет получать на выходе ИНС сложные структуры данных, в данном случае — векторы прогнозных значений интересующих нас показателей для конкретной добывающей скважины. На вход ИНС-модель принимает: граф, описывающий положения скважин; исторические данные за некий период; и план работы нагнетательных скважин в дальнейшем.

Адаптация к историческим данным и предсказание показателей в будущем осуществляются за один проход сложной мультимодальной архитектуры в режиме вывода (inference) — то есть весьма экономно в отношении вычислительных ресурсов. Если процедуры, связанные с предварительным обучением, требуют известных затрат времени и вычислительных мощностей, уже обученная ИНС-модель показывает существенное превосходство в скорости работы перед традиционными численными моделями.

Для сотен отдельных скважин адаптация и прогнозирование с помощью ИНС-модели требуют в общей сложности нескольких секунд — в тысячи раз быстрее, чем при использовании современного метода «сглаженного ансамбля» и классического численного моделирования, в десятки раз быстрее прокси-модели CRM. Преимуществом предлагаемого метода перед статистическими прокси-моделями, сравнимыми с ним по скорости, является частичное сохранение физического смысла.

Предшествующие работы

Применяемые сегодня методы автоматизированного воспроизведения истории разработки можно подразделить на три категории в соответствии с типом вычислительной модели, подстройка параметров которой осуществляется в процессе адаптации к историческим данным:

1. Работающие с полноценной трехмерной численной гидродинамической моделью;
2. Работающие со статистическими прокси-моделями;
3. Работающие с физически содержательными прокси-моделями.

Численная гидродинамическая модель представляет собой *расчетную сетку*, подразделяющую пространственное представление пласта на расчетные ячейки. Каждой ячейке сетки сопоставлен ряд параметров, таких как пористость и проницаемость, и ряд динамических характеристик — давление, насыщенность перемещающимися флюидами и т. д. Эволюция динамических характеристик во времени затем вычисляется посредством решения уравнений гидродинамики для пористой среды численными методами. Численная модель может служить мощнейшим инструментом планирования и управления, в случае корректно установленных параметров расчетной сетки. Действующими регламентами предполагается создание таких моделей как для проектной документации, подготавливаемой до начала разработки месторождения, так и в качестве постоянно действующей гидродинамической модели, призванной служить цифровым отражением процесса разработки.

Принципиальная детерминированность численных моделей затрудняет оценку неопределенности, вызванной несовершенством геологических данных, на которых основывается численная модель, и адаптацию модели к историческим промысловым данным. Большинство существующих решений этих задач построены на создании *ансамблей* родственных численных моделей. Например, когда существуют различные предположения о распределении фильтрационных свойств пласта, проводится расчет ансамбля численных моделей, основанных на различных реализациях расчетной сетки, с различными картинками распределения проницаемостей; на основе расхождения прогнозов выводится оценка ожидаемой погрешности, оптимистичный и пессимистичный варианты прогноза. Процедура адаптации к историческим данным также часто начинается с создания ансамбля различающихся вариантов модели. Для каждого из них проводится расчет эволюции гидродинамической системы, результатом которого оказываются прогнозные, или модельные значения $m(p_1, \dots, p_n)$ таких показателей, как дебиты скважин и пластовое давление, где p — начальные условия и другие параметры гидродинамической модели. Эти значения сравниваются с фактическими показателями истории разработки x , и если функцией $f(x, m(p_1, \dots, p_n))$ обозначить невязку исторических и модельных значений, задачу адаптации гидродинамической модели можно свести к поиску значений параметров p , минимизирующих функцию f .

Размеры множества p не позволяют вести речь о полном переборе возможных вариантов, тем более что для получения каждого прогноза $m(p_1, \dots, p_n)$

необходимо проводить трудоемкую численную симуляцию. Как правило на основании результатов моделирования первичного ансамбля формируется следующее поколение реализаций, прогнозы которых ближе к целевым показателям x . Для поиска наилучших обновлений параметров p на очередной итерации успешно применяются стохастические методы, в частности варианты метода Монте Карло, дополненные различными техниками регуляризации, градиентным спуском и анализом чувствительности для определения наиболее значимых параметров [25]. Многообещающие результаты показывают генетические алгоритмы, подвергающие модели ансамбля скрещиванию и «естественному отбору» [10], и методы «сглаживания», в основе которых лежит предположение, что точки пространства параметров p , соответствующие моделям ансамбля, также лежат в подмножестве p , обладающем определенными свойствами, что позволяет применять более эффективные градиентные методы [12]. Все перечисленные методы полагаются на сокращение числа настраиваемых параметров, заменяя реальное множество параметров численной модели условными параметрами, что осложняет достижение желаемой ситуации, когда численная модель соответствует реальному объекту.

На настоящий момент не существует универсального алгоритма или программного продукта, корректно проводящего автоадаптацию всякой численной модели. Часто параметры модели подстраиваются вручную, самоочевидным вариантом чего является добавление к ней данных каротажных и иных исследований. Однако в результате предсказательная способность модели не всегда улучшается. Успешная адаптация численной модели месторождения к данным истории разработки требует кропотливого труда, и часто служит темой диссертационных работ, в рамках которых методы и алгоритмы модифицируются для конкретной ситуации.

Трудности адаптации численных моделей служат одной из причин использования *прокси-моделей*, соответствие которых реальным гидродинамическим процессам слабее теоретически обосновано. Однако такие модели не только позволяют осуществлять прогноз и адаптацию гораздо быстрее, но и в некоторых случаях точнее обычных численных моделей [8]. В свете этого встречается мнение, что затраты на настройку численных моделей не оправданы и применение прокси-моделей предпочтительно [2].

Некоторые прокси-модели рассматривают показатели со скважин месторождения в отрыве от гидродинамики, в качестве временных рядов, т. е. абстрактных переменных, изменяющихся во времени, выявляя статистические зависимости между ними. Для таких моделей типично рассмотрение нескольких близлежащих скважин, например «геометрического элемента заводнения» [5, с. 54]. Статистический анализ осуществляется с использованием таких инструментов как коэффициенты Спирмена, разложения Фурье [1, 3], и варианты ИНС, известных как гибкие аппроксиматоры нелинейных зависимостей: простых перцептронов [2], рекуррентных ИНС [14] и комбинированных архитектур, способных учитывать и некоторые известные характеристики пласта [24]. Практически такой подход вполне эффективен, но имеет существенную

уязвимость: такие модели могут неправильно отражать зависимость между показателями, корреляция которых не проявилась в исторический период. Грубо говоря, если режим работы нагнетательной скважины не изменялся на протяжении периода обучения, эффект его изменений в будущем будет упущен. Таким образом «статистические» прокси-модели необходимо применять с осторожностью, имея в виду их слабые стороны.

Физически содержательные прокси-модели основаны на обобщенных уравнениях, выведенных из гидродинамических законов. Как правило, эти уравнения тоже решаются численными методами, но требуют меньших вычислительных затрат в сравнении с «истинными» численными моделями и/или лучше отражают неопределенности или задачи моделирования. К этой категории относятся методы CRM (Capacitance Resistive Model), описывающей взаимодействие пары скважин несколькими коэффициентами [5]; INSIM-FT (Interwell Numerical Simulation Front Tracking), предполагающий замену трехмерной модели сетью условно-одномерных численных моделей, связывающих каждую скважину с каждой [15]; метод С. В. Соколова, сопоставляющий скважинам участки пласта, ограниченные их регионами Вороного [4, с. 154] и др.

Представленная типологизация методов автоматизированного воспроизведения истории не является исчерпывающей, более подробный обзор существующих подходов к прокси-моделированию можно найти в [19] и [4], обзор подходов к автоматизированной подстройке численных моделей — в [25].

Отдельно следует отметить работу [18], где ИНС используется не для аппроксимации показателей как функций времени, но в качестве физически содержательного замещения численной модели, предсказывающей результат эволюции гидродинамической системы на основе начальных условий. Поскольку вывод ИНС гораздо быстрее работы традиционного симулятора, ИНС-прокси с успехом используется для подбора параметров, дающих искомые показатели методом оптимизации. Такая идеология близка данной работе.

Мотивация и принципиальные особенности

Задачей данного исследования был поиск способа применить возможности современных ИНС для сохраняющего определенную степень физической достоверности прокси-моделирования пластовой гидродинамики с как можно более полным учетом доступной информации о месторождении, сведя при этом к минимуму неблагоприятные особенности большинства методов, основанных на ИНС, такие как необходимость создавать новую архитектуру сети и проводить трудоемкое обучение для каждой модели нового пласта.

Излагая особенности предложенного в данной статье метода, следует прежде всего подчеркнуть различие между понятиями *предварительного обучения* и *адаптации* ИНС-модели. Эта терминология тем более способна ввести в заблуждение, что в контексте воспроизведения истории разработки адаптация гидродинамической модели к историческим данным иногда называется и обучением на историческом периоде. В контексте же ИНС обучение — это всегда процесс настройки весов нейронов сети методом обратного распространения

ошибки, на обучающем наборе образцов. Как правило в работах, затрагивающих ИНС и воспроизведение истории месторождения, обучение той или иной ИНС связано с процедурой адаптации модели.

Однако данное исследование следует скорее принципам, характерным для Physics-Informed Neural Networks (PINN) — направления исследований, развившегося в последние 5 лет. Мотивацией PINN послужило наблюдение, что некоторые архитектуры ИНС возможно применять для приближенного моделирования определенных физических систем, в т. ч. гидродинамических. В рамках PINN нейронные сети применяются не для решения классических задач вроде распознавания образов, но для непосредственного предсказания эволюции физической системы. Обучение проводится на синтетических наборах данных, созданных с помощью «традиционных» численных симуляторов, причем критерием успеха обучения является генерализация, или обобщение — возможность ИНС предсказывать поведение систем, выходящих за рамки обучающего набора [9, 27]. Дальнейшее развитие темы привело к описанию способности таких ИНС в некотором смысле формулировать широкий спектр решений дифференциального уравнения, описывающего физические системы [22].

Бурный рост этого направления принес значительные достижения в самых разных областях, от неточной декоративной гидродинамики для компьютерной анимации до моделирования процессов, длительное время представляющих сложность для физической науки, таких как свертывание протеинов и ядерный синтез в плазме [21]. Предшествующие исследования автора данной статьи подтвердили применимость PINN к задачам пластовой гидродинамики [6]; авторы исследований [18] и [13] делают аналогичный вывод. Отличием нейросетевых моделей физических процессов от традиционных численных моделей является изначальная открытость автоматическому дифференцированию, что представляет интерес в свете ряда обратных задач и задач контроля, возникающих в нефтегазодобывающей отрасли [17, 26].

Современные программные средства предоставляют обширный инструментарий для обработки информации, описывающей физические системы. Некоторые из работ в области PINN передают ИНС-моделям на вход динамические характеристики ячеек расчетной сетки, другие — положения и скорости движущихся объектов или псевдочастиц. Для обработки гидродинамических моделей пласта удачным выбором оказались графовые сверточные архитектуры ИНС, позволяющие осуществлять обучение и дальнейшее применение ИНС на данных, распределенных по вершинам и ребрам графов различного пространственного положения и топологии.

Для подготовки к применению ИНС-модели на основе трехмерной расчетной сетки строится *граф пласта* (рис. 1), вершинами которого являются только забои скважин любого типа. Ребрам графа пласта сопоставлены по два числа — длина $d_{i,j}$, т. е. расстояние до смежной вершины, и уклон $a_{i,j}$. Ребра между вершинами строятся алгоритмом триангуляции Делоне, стремящимся максимизировать минимальный угол между ребрами, соединяя близлежащие точки. Вершинам ставятся в соответствие оценочные объемы V_i — сумма

объемов активных ячеек сеточной модели, попадающих в соответствующий вершине регион Вороного, т. е. находящихся ближе к вершине i , чем к любой другой.




Рис. 1. Построение графа пласта (на примере модели из датасета EGG [20])




Fig. 1. Graph description of a reservoir model (a model from the EGG dataset [20])

С вершинами также связаны динамические показатели, некоторые из которых вводятся в ИНС-модель. Для добывающих скважин это дебиты воды $Q_W(t)$ и нефти $Q_O(t)$, для нагнетательных — давления $P(t)$ и объем закачки воды $W(t)$. Все динамические характеристики представляются в виде временных рядов с постоянным шагом по времени τ , в рамках данной работы $\tau = 30$ сут.

Архитектура ИНС-модели

В основу мультимодальной, т. е. интегрирующей разнородные входные данные, архитектуры ИНС-модели положена классическая схема «кодировщик-генератор». Модули-кодировщики ИНС-модели преобразуют некие входные данные в формат *сжатых отображений*, заключающих информацию, с помощью которой модуль-генератор способен сгенерировать выходные данные — вывод ИНС-модели (рис. 2). Размерность сжатых отображений меньше размерности как входных значений, так и выводов, которые должна производить ИНС, что создает эффект «бутылочного горлышка», подталкивая ИНС искать принципы организации данных, в контексте PINN — отношения, позволяющие предсказывать поведение физических систем.

В данном случае задачей ИНС-модели является предсказание двух 16-мерных векторов $Q_O^{(F)}$ и $Q_W^{(F)}$ — будущих значений дебита для конкретной добывающей скважины на 16 временных шагов вперед, руководствуясь всей информацией, включенной в граф пласта, и в первую очередь историческими значениями для рассматриваемой скважины, $Q_O^{(H)}$ и $Q_W^{(H)}$, где индекс (H) указывает на исторические данные, а именно 64 временных шага, последний из которых непосредственно предшествует предсказываемому периоду, это настоящий момент. На вход ИНС всегда подаются по 64 значения для каждого показателя. Если в этот период попадает время до начала разработки, дебиты приравниваются к нулю, давления к начальному давлению. Аналогично обрабатываются данные для всех вершин графа пласта \mathcal{G} .




Рис. 2. Принципиальная схема ИНС-модели

Fig. 2. Principal encoder-decoder architecture of the neural net

Общая схема ИНС-модели включает два различных кодировщика E_H и E_G , выводящих соответственно 4-мерный вектор сжатого отображения h и 8-мерный g . E_G является графовой сверточной ИНС, самым «глубоким» модулем ИНС-модели, обрабатывающим большую часть входных данных. 4-мерный вектор x выводится из h и g посредством единичного полносвязного слоя, т. е. простейшего однослойного перцептрона: каждое из 12 входных значений связано с каждым из 4-х выходных взвешенной связью. Генераторы $G(x)$ аналогичны друг другу. Они выводят разные показатели, но используют одну и ту же архитектуру, разумеется, с различными весами. Процедуры обучения G_O и G_W независимы, но осуществляются параллельно для экономии времени на прямом проходе ИНС.

В соответствии с принципами обучения ИНС, после инициализации весов всех модулей случайными значениями образцы обучающего набора подаются на входы кодировщиков (прямой проход); выведенные генератором значения сравниваются с целевыми, также содержащимися в учебном образце. Невязка целевых, истинных значений с предсказанными ИНС-моделью значениями измеряется *функцией потерь*, для генератора G_O это

$$\mathcal{L}_O = \left(\sum_N \sum_k \left[G_O \left(E_H \left(Q_O^{(H)}(N, k), Q_W^{(H)}(N, k) \right), E_G(\mathcal{G}(N, k)) \right) - Q_O^{(F)}(N, k) \right]^2 \right)^{1/2}, \quad (1)$$

где N — номер образца в обучающем наборе, точнее, в партии образцов, рассматриваемой на данном шаге цикла обучения; k — номер добывающей скважины в графе пласта в данном образце. Вычисленная для всех образцов функция потерь \mathcal{L}_O применяется для настройки весов связей нейронов ИНС по принципу обратного распространения ошибки. Алгоритм обучения ADAM, хорошо зарекомендовавший себя в обучении глубоких архитектур ИНС, минимизирует значения функций потерь, меняя веса нейронов в модулях ИНС-модели посредством градиентного спуска с запоминанием пути и моментов инерции для каждой итерации [23]. Для обучения генератора G_W применяется

аналогичная (1) функция потерь \mathcal{L}_W , отличающаяся только применением G_W вместо G_O , и $Q_W^{(F)}$ в качестве целевого значения.

Эмпирически было установлено, что сходимость процедуры обучения значительно улучшается применением оригинальной техники перекрестного обучения, ранее опробованной автором в смежной задаче [7]. Для этого *параллельно* с обучением основной ИНС-модели на основе базовой функции потерь (1) проводится обучение упрощенной архитектуры $G(E(X))$. Эта архитектура по сути является простейшим автокодировщиком, задача которого — корректно восстановить входные значения X , пропущенные через «бутылочное горлышко» сжатого отображения x . Автокодировщик обучается на основе функции потерь

$$\mathcal{L}_{ae(O)} = \sqrt{\sum_N \sum_k \left[G_O \left(E \left(Q_O^{(F)}(N, k) \right) \right) - Q_O^{(F)}(N, k) \right]^2}. \quad (2)$$

Задачу обучения $G(E(X))$ можно назвать простой — уже по окончании первой эпохи, т. е. прохождению всего обучающего набора, автокодировщик способен достаточно качественно воспроизводить целевые значения. Задача обучения основной архитектуры значительно сложнее, и кодировщик $E(X)$ становится *направляющим* этот процесс. Функция потерь \mathcal{L}_{ae} применяется только для настройки весов связки $E(X), G$; базовая же функция потерь \mathcal{L}_O используется для настройки весов и генератора G , и кодировщиков E_G и E_H , но не затрагивает направляющий кодировщик $E(X)$. Таким образом направляющий автокодировщик с его простой задачей обучения «подсказывает» основной архитектуре эффективный «язык» сжатых отображений x . После окончания обучения направляющий кодировщик $E(X)$ удаляется.

Применена еще одна техника, улучшающая качество сжатых отображений — состязательное наращивание энтропии [11]. Дополнительная ИНС-дискриминатор, простой трехслойный перцептрон D с 64, 32 и 16 нейронами в скрытых слоях выдает на выходе единственное число. Задача обучения дискриминатора — выдавать 1, если на вход подано сжатое отображение x , созданное кодирующими модулями ИНС, и выдавать 0 для случайных значений z , формулируется функцией потерь

$$\mathcal{L}_D = \sum_N \sum_k \left[\log(D(z)) + \log \left(1 - D \left(E_H \left(Q_O^{(H)}, Q_W^{(H)} \right), E_G(G) \right) \right) \right], \quad (3)$$

причем обучение дискриминатора преследует цель минимизировать \mathcal{L}_D , а к базовой функции потерь основной архитектуры \mathcal{L}_D добавляется с отрицательным знаком, таким образом обучение весов основных кодировщиков стремится *максимизировать* \mathcal{L}_D , т. е. сделать сжатые отображения трудноотличимыми от случайного распределения, увеличить их колмогоровскую информационную энтропию. Противоположные задачи создают ситуацию антагонистической

игры, благодаря чему «язык» сжатых отображений x лучше сохраняет нужную генераторам информацию.

ИНС-модель широко применяет *сверточные* слои, отличие которых от полносвязных слоев обычного перцептрона в том, что не каждое значение входных данных связано с каждым нейроном следующего слоя взвешенной связью, вместо этого, по вектору входных данных проходит «скользящее окно», также называемое *фильтром* свертки. Размер фильтра гораздо меньше размера входных данных (предыдущего слоя), таким образом гораздо меньше весов настраиваются в процессе обучения для отдельного фильтра, нежели требовалось бы в обычном перцептроне, и каждый слой сверточной сети может включать множество фильтров. Как правило, сверточная ИНС включает ряд слоев, постепенно снижающих размер входных данных. Значения нейронов одномерного сверточного слоя ℓ определяются как

$$X_{\ell}[i] = (\omega_F * X_{\ell-1})[i] = \sum_{n=1}^m \varrho \left(X_{\ell-1} \left[i + \left(n - \frac{m-1}{2} \right) \cdot s \right] \cdot \omega_F[n] \right), \quad (4)$$

где ω_F — веса фильтра свертки; $\varrho(X)$ — функция активации нейрона; m — размер фильтра. На рис. 3 каждый сверточный слой обозначен стрелкой. Первая цифра над стрелкой — размер фильтра m , вторая — шаг s ; эти характеристики определяют, как меняется от слоя к слою размер данных, указанный в серых прямоугольниках. Первое число — размер вектора данных, скажем, 64 входных значения для E_H , второе — число каналов. Каждый канал связан с каждым каналом предыдущего слоя отдельным фильтром. Сингулярная свертка с характеристиками (1, 1) аналогична полносвязному слою — каждый фильтр принимает единственную скалярную величину.




Рис. 3. Архитектура сверточных модулей ИНС-модели

Fig. 3. Layered architecture of neural network modules

Генераторы состоят из развертывающих слоев, производящих операцию свертки в обратном направлении, с транспонированной матрицей ω_F — из одного значения с предыдущего слоя выводятся m значений для каждого фильтра, выводы всех фильтров с прошлого слоя суммируются между собой для каждого канала следующего слоя.

Самый сложный модуль ИНС-модели — графовый сверточный кодировщик E_G . Исследования архитектур ИНС, принимающих на вход данные,

организованные в графовые структуры, начались только в 2017 г. В отличие от классических сверточных ИНС, работающих с 1-, 2-, 3-мерными входными данными на регулярной сетке, что подходит для обработки растровых изображений, видео, и временных рядов, графовые архитектуры призваны работать с различными конфигурациями входных данных. Индуктивная графовая архитектура [16], взятая за основу E_G , ассоциирует с ребром графа (i, j) его длину $d_{i,j}$; кодировщик E_G учитывает также уклон $a_{i,j}$ и расстояние $d_{i,k}$ до добывающей скважины k , для которой осуществляется прогнозирование. Все эти величины включены в ИНС в виде нейронов со взвешенными связями, и процесс обучения устанавливает меру влияния скважин (вершин графа) друг на друга в зависимости от их положения и исторических показателей.

Для конкретной добывающей скважины k граф пласта разворачивается в дерево (рис. 4, слева), причем, так как граф пласта всегда содержит циклы, этот процесс может продолжаться сколь угодно долго и в рамках данного исследования ограничен тремя слоями. Наиболее удаленный от k слой считается первым, нейрон каждого *следующего* слоя суммирует и усредняет значения, получаемые через взвешенные и обучаемые связи от всех нейронов (вершин) предыдущего слоя, соединенных с данным нейроном этого слоя. Различия возможного количества вершин на предыдущем слое вынуждают графовые ИНС тем или иным способом обобщать входы со множества нейронов. Подход, названный индуктивным, предполагает суммирование и осреднение:

$$\phi(E_\ell[i]) = \sum_{j \in \mathcal{N}(i)} \frac{E_\ell(P_i, W_i, Q_O^{(H)}, d_{i,j}, a_{i,j}, d_{i,k}, \phi(E_{\ell-1}[j]))}{\sqrt{\deg(i)} \cdot \sqrt{\deg(j)}}, \quad (5)$$

где $\deg(i)$ — степень вершины i ; $\mathcal{N}(i)$ — ее окрестность, точнее, все связанные с i вершины с предыдущего слоя. Эти операции также доступны автоматическому дифференцированию, применяемому при обучении ИНС.

С вершинами графа пласта связаны динамические характеристики, в т. ч. плановые значения приемистости для нагнетательных скважин в будущем. Эти временные ряды обрабатываются одномерным сверточным кодировщиком E_ℓ , архитектура которого изображена на рис. 4 справа. Архитектура E_ℓ всегда одинакова, однако веса для каждого слоя ℓ различны и обучаются независимо. При прохождении последнего слоя E_G ($\ell = 3$) последняя свертка E_ℓ заменяется сингулярной, и $\phi(E_3[k])$ выводит 8 значений сжатого отображения g . На остальных слоях выходы каждого E_ℓ 4-мерны, и $\phi(E_\ell[i])$ также передает кодировщику следующего слоя 4 осредненных и взвешенных значения. Веса E_ℓ также различны для добывающих и нагнетательных скважин на каждом слое. Для добывающей скважины i в выражении (5) место векторов P_i и W_i занимают $Q_{W(i)}$ и $Q_{O(i)}$.

Из 32 значений вводимых в E_ℓ векторов первые 16 чисел относятся к прошлому, вторые 16 — расписание на будущее для тех векторов, где они есть — для управляемых величин. В данном исследовании такова только приемистость W_i .

Если значения показателя неизвестны, вводится «-1» — принцип, заимствованный из задач «дорисовывания» и достраивания неизвестных значений с помощью ИНС. Еще один входной канал, общий для всех E_ℓ — исторические значения того показателя, который ИНС-модель обучается предсказывать, для целевой скважины k . Последние 16 значений вектора $Q_0^{(H)}$ или $Q_W^{(H)}$ выравниваются по времени с другими двумя каналами.

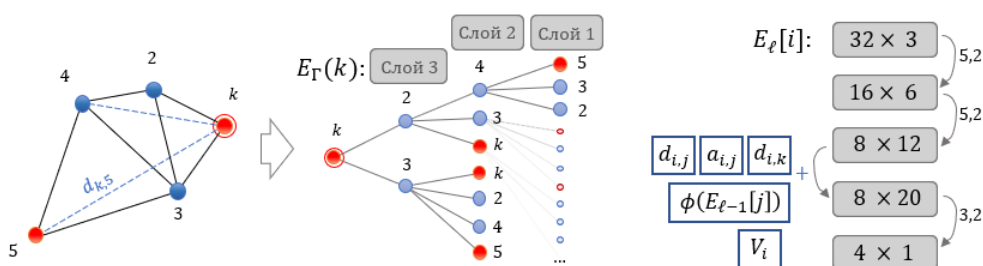


Рис. 4. Принцип работы графовой сверточной ИНС, и архитектура модуля E_ℓ (справа)

Fig. 4. Inductive graph unrolling, and the layered architecture of an internal encoder E_ℓ (to the right)

Характерная особенность графовой ИНС E_Γ : ввод данных с предыдущего слоя E_Γ осуществляется сразу на третий слой соответствующего E_ℓ , вместе с условным объемом V_i , рассчитываемым как сумма объемов всех ячеек численной модели, входящих в соответствующий вершине регион Вороного, и характеристиками соответствующих ребер графа пласта (рис. 4, справа). Каждая из этих скалярных величин вводится как целый канал для сверточного слоя. Такое решение подтвердило свою уместность; его мотивация — предоставить ИНС возможность оценивать запаздывание, силу и свойства отклика показателей данной скважины на изменения показателей $\phi(E_{\ell-1}[j])$ всех соседних с ней скважин j .

Результаты исследования и их обсуждение

Обучение ИНС-модели является вычислительным экспериментом. Для его осуществления подготавливается обучающий набор данных и непересекающийся с ним тестовый набор данных. Критерий успешности эксперимента — способность обученной ИНС-модели предсказывать дебиты воды и нефти для добывающих скважин из моделей пластов, не включенных в обучающий набор, на основе входных исторических данных и расписания на будущее.

Обучающий набор данных представляет из себя 20 тыс. отдельных симуляций (трехмерных численных моделей), конкретнее, показатели скважин в виде временных рядов и граф пласта, описывающий взаимное положение скважин, для каждой из этих симуляций. Пласты описываются расчетными сетками из $50 * 50 * 5$ ячеек, регулярных и прямоугольных в горизонтальной плоскости. По вертикали сетка имеет случайно выбираемый уклон от 0°

до 30° , сторона ячейки в горизонтальной плоскости варьируется от 10 до 50 м. Пористость одинакова для всех ячеек, карта гетерогенной проницаемости генерируется случайным шумом Перлина. Движущиеся фазы — вода и нефть, свойства флюидов одинаковы во всех образцах набора. Каждый образец включает от 5 до 15 добывающих скважин и от 5 до 15 нагнетательных, располагаются они случайным образом. Добывающие скважины всегда открыты, режим управления — поддержание забойного давления на определенном уровне. Нагнетательные скважины имеют случайно сгенерированное расписание — объемы закачки воды меняются во времени отнюдь не оптимально; задача этих случайных расписаний — предоставить ИНС-модели примеры поведения изучаемой системы в *различных* обстоятельствах.

Обучающий набор данных содержит регулярности: для каждого варианта пласта проведено 100 симуляций с различными расписаниями и положениями скважин, для одного расположения скважин — 10 симуляций с различными расписаниями. Каждая симуляция включает 128 контрольных шагов по времени $\tau = 30$ сут., т. е. более 10 лет модельного времени. Для вывода конкретного предсказания ИНС-моделью во времени симуляции выбирается случайный момент, 16 шагов после избранного момента становятся целью предсказания, предшествующие избранному моменту значения показателей — историческими данными. Таким образом, реальное число образцов, рассматриваемых в протяжении полной *эпохи* обучения, превышает 2 млн.

Обучающий набор был подготовлен с помощью численного симулятора ОРМ-Flow. Также был подготовлен тестовый набор из 500 аналогичных симуляций, отличающихся как свойствами пластов, так и расписаниями, и положением скважин. Архитектура ИНС-модели была реализована с применением библиотеки PyTorch. Проведение 1000 полных эпох обучения потребовало порядка двух суток с видеопроцессором Nvidia GTX 1080.

По итогам процедуры обучения ИНС-модель демонстрирует успешную генерализацию за рамками обучающего набора. На рис. 5 показаны графики дебита воды и нефти одной и той же добывающей скважины для трех реализаций модели пласта из набора синтетических данных EGG. Этот набор данных применяется для апробирования алгоритмов моделирования и планирования [20]. Все образцы из набора EGG имеют одинаковое размещение 4 добывающих и 8 нагнетательных скважин и различаются только гетерогенной проницаемостью породы. Симуляция трех вариантов осуществлена с одним и тем же расписанием работы скважин; однако геологические различия вызывают серьезное расхождение показателей.

ИНС-модель не имеет никакой информации о характеристиках проницаемости пласта, кроме той, которую извлекает из корреляции исторических данных и расписания работы скважин в прошлом — т. е. данных численного моделирования до избранного момента (на рис. 5 четыре таких момента отмечены флажками).

ИНС-модель предсказывает значения дебитов на 16 месяцев вперед. Эксперименты показали, что расширение этого периода существенно затрудняет

процесс обучения, на порядки увеличивая пространство возможных выводов ИНС. Создание ИНС-модели, прогнозирующей большие временные периоды, по видимости, требует не столько большего числа эпох обучения, сколько более обширных обучающих наборов.




Рис. 5. Предсказанные ИНС-моделью показатели (сплошные линии) в сравнении с данными численного моделирования (штриховые линии) для определенной добывающей скважины с различными реализациями проницаемости

Fig. 5. Neural network predictions (solid lines) compared with the ground truth numerical modeling (dashed lines) for the same production well with different permeability realisations

Прогнозирование 16 значений дебитов с помощью, обученной ИНС-модели, в узком смысле решение обратной и прямой задачи гидродинамики, для всех скважин резервуара EGG требует *менее одной секунды* на современном персональном компьютере. Следует подчеркнуть, что высокопроизводительные предсказания возможны для резервуаров, не входящих в обучающий набор.

Как и в случае с другими средствами прокси-моделирования, ИНС-модель демонстрирует значительно лучшие результаты, когда исторические данные включают нетривиальную активность нагнетательных скважин, из анализа которой можно делать выводы о взаимовлиянии скважин пласта и вызываемых им корреляциях показателей. На рис. 6 показано влияние перемен в плане работы одной из трех нагнетательных скважин на показатели единственной добывающей скважины, и способность ИНС-модели правильно реагировать на изменение плана (рис. 6а, 6б), опять же, основываясь исключительно на анализе исторических данных.

Две из трех нагнетательных скважин в данной тестовой модели имеют весьма нетривиальные и «хорошо различимые» расписания, однако третья (красная линия) осуществляет закачку воды в постоянном объеме, и только в случае (в) объем закачки меняется, причем именно в момент осуществления прогнозирования. Таким образом, ИНС-модель не имеет достаточной исторической информации, что является существенной проблемой для «статистических» прокси-моделей, к которым относится большинство прокси-моделей, основанных на ИНС и обучаемых на истории одного конкретного месторождения, или даже отдельной скважины. Однако, данных о резервуаре, заключенных в графе пласта, оказывается достаточно для выполнения достаточно достоверного прогноза (рис. 6в).

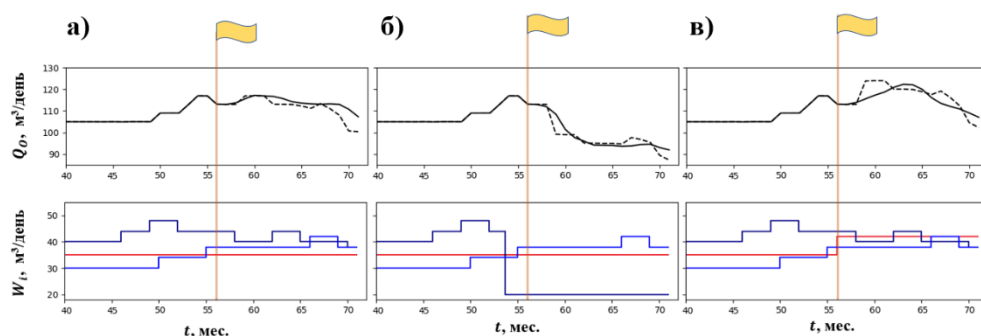


Рис. 6. Предсказания ИНС-модели (сплошная линия после флажка) в сравнении с эталонным численным моделированием (штриховая линия) для модели пласта с тремя нагнетательными скважинами и одной добывающей

Fig. 6. Neural network predictions (solid line after the flag) compared with the ground truth (dashed line) for a three injectors, one producer test case

Предложенная ИНС-модель, обучаемая не для конкретного случая, но на множестве симуляций с различными условиями, может быть охарактеризована как в некоторой степени физически содержательная, или по крайней мере обладающая некоторыми из преимуществ физически содержательных прокси-моделей.

Необходимо отметить, впрочем, известные ограничения, которые накладываются на ИНС-модель свойствами обучающего набора. На данной стадии исследования обученная ИНС-модель корректно работает с различными пластами, любым количеством скважин, различными пластовыми давлениями по крайней мере в пределах ситуаций, встречающихся в обучающих данных; обучение, однако, велось только для простой системы нефть-вода, более того, петрофизические свойства флюида не меняются в рамках обучающего набора. Это означает, что при существенном отклонении данных характеристик предсказания ИНС-модели становятся недостоверны. Кроме того, обучающий

набор включает единственный режим управления работой добывающих скважин, поддержание давления на заданном уровне.

Предложенная мультимодальная архитектура на основе графовой сверточной ИНС имеет обширный потенциал расширения. Речь идет в первую очередь о возможности ввода данных различной модальности: как относящихся ко всему резервуару, так и к конкретным скважинам, или ребрам графа пласта. Большая часть информации, достоверно известной о пласте, может быть пространственно связана с расположением скважин. Например, кроме длины и уклона с ребром графа может быть связана такая информация, как: пересекает ли это ребро геологические разломы и другие известные формации. Таким образом и сейсмические данные теоретически возможно использовать для улучшения качества предсказаний гибкой ИНС-модели. В непосредственном будущем данного исследования возможно включение в предложенную архитектуру еще одного кодировщика, дополнительно обуславливающего работу ИНС свойствами флюидов, принимаемых в формате таблицы PVT или иных характеристик. Другое очевидное расширение — возможность модификации планов работы добывающих скважин, по меньшей мере возможность их открытия и закрытия.

В первом приближении, расширение возможностей ИНС-модели представляется прежде всего вопросом подготовки обширных обучающих наборов и проведения вычислений. При этом обучение достаточно универсальной промышленной ИНС-модели потребует вычислительной инфраструктуры и затрат времени. Однако обученная ИНС-модель, даже включая много больше модулей, чем рассмотренная в данной статье, по-прежнему будет доступна для применения с потребительским компьютерным оборудованием. Частью идеологии современного ПО, использующего ИНС, становится централизованное обучение моделей, проводимое компанией-разработчиком, и дистрибуция подготовленных продуктов.

С другой стороны, способность той или иной архитектуры ИНС провести генерализацию для произвольных обучающих данных не гарантирована. Проблема, известная как коллапс апостериорного распределения, может быть вызвана слишком большим, в сравнении с объемами обучающего набора, разнообразием целевых ситуаций. Упрощенно говоря, процесс настройки весов ИНС обнаруживает все больше неудачных локальных минимумов функции потерь, и генерализация модели не осуществляется. Кроме непосредственного расширения выборки и времени обучения, для преодоления проблемы применяются различные техники регуляризации — весьма широкое понятие в современной теории нейронных сетей. Однако универсальной рецептуры для анализа любых данных не существует. В этом смысле машинное обучение в целом остается достаточно эмпирической и экспериментальной областью.

Заключение

Проведенное исследование подтвердило возможность применения графовых сверточных ИНС для непосредственного предсказания показателей работы добывающих скважин, обуславливаемых планом разработки месторождения, на

основании исключительно промысловых данных и самой общей информации о расположении забоев в пласте.

Предложенная графовая сверточная архитектура обладает широким потенциалом интеграции разнородных сведений. Подтверждена способность таких ИНС обрабатывать информацию, организованную в виде временных рядов, и связанные с ней пространственные характеристики.

Основными преимуществами предложенного метода перед другими методами прокси-моделирования, основанными на применении ИНС, представляются: существенное увеличение скорости адаптации, вызванное отсутствием необходимости производить вычислительно затратное обучение для каждого нового резервуара, и улучшение физической содержательности модели за счет «опыта» обработки множества ситуаций, различия которых обуславливают целевые значения. Преимуществом перед физически обоснованными методами моделирования может быть названа гибкость, характерная для сугубо «статистических» моделей, возможность модификации предложенного метода для обработки несколько иных входных данных, и предсказания иных целевых показателей.

В целом методология нейросетевого моделирования физических процессов и графовые ИНС представляются современными инструментами, в перспективе способными объединить достоинства различных способов моделирования пластовой гидродинамики.

СПИСОК ЛИТЕРАТУРЫ

- 1 Абабков А. В. Экспресс-метод оценки степени взаимодействия скважин с использованием частотного анализа данных истории эксплуатации нагнетательных и добывающих скважин / А. В. Абабков, В. М. Васильев, Н. И. Хисамутдинов, И. Р. Сафиуллин, В. Ш. Шаисламов // Нефтепромысловое дело. 2014. № 7. С. 10-13.
- 2 Бриллиант Л. С. Управление добычей нефти на основе нейросетевой оптимизации режимов работы скважин на участке опытно-промышленных работ пласта ЮВ1 Ватъеганского месторождения ТПП «Повхнефтегаз» / Л. С. Бриллиант, М. Р. Дулкарнаев, М. Ю. Данько, А. О. Елишева, Д. Х. Набиев, А. И. Хуторная, И. Н. Мальков // Георесурсы. 2022. № 1 (24). С. 3-15.
- 3 Проскурин В. А. Способы оценки эффективности формирования системы заводнения на объекте Западно-Усть-Балыкского месторождения / В. А. Проскурин, Н. И. Хисамутдинов, М. С. Антонов, Д. К. Сагитов // Автоматизация, телемеханизация и связь в нефтяной промышленности. 2013. № 6. С. 36-38.
- 4 Степанов С. В. Проблематика оценки взаимовлияния добывающих и нагнетательных скважин на основе математического моделирования / С. В. Степанов, С. В. Соколов, А. А. Ручкин, А. В. Степанов, А. В. Князев, А. В. Корытов // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2018. № 3 (4). С. 146-164.
- 5 Степанов С. В. Сопровождение разработки нефтяных месторождений с использованием моделей CRM / С. В. Степанов, А. Д. Бекман, А. А. Ручкин, Т. А. Поспелова // ИПЦ «Экспресс». 2022.

- 6 Умановский А. В. Методика имитационного моделирования на основе обучающих данных для двухфазного течения в гетерогенной пористой среде / А. В. Умановский // Компьютерные исследования и моделирование. 2021. № 4 (13). С. 779-792.
- 7 Умановский А. В. Состязательные сверточные нейронные сети в качестве эвристической модели процесса двухфазной фильтрации в пористой среде / А. В. Умановский // Вычислительная механика сплошных сред. 2020. № 2 (13). С. 231-241.
- 8 Шевцов Н. О. Исследование прогностической способности, численной и аналитической моделей на примере оценки взаимовлияния скважин / Н. О. Шевцов, С. В. Степанов, Т. А. Поспелова // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2020. № 3 (6). С. 131-142.
- 9 Cai S. Physics-informed neural networks (PINNs) for fluid mechanics: A review / S. Cai, M. Zhiping et al. // Acta Mechanica Sinica. 2022. Pp. 1-12.
- 10 Chakra N. C. C. History matching of petroleum reservoirs employing adaptive genetic algorithm / N. C. C. Chakra, D. N. Saraf // Journal of Petroleum Exploration and Production Technology. 2016. № 4 (6). Pp. 653-674.
- 11 Chen X. InfoGAN: Interpretable representation learning by information maximizing generative adversarial nets / X. Chen, Y. Duan, R. Houthoof et al. // Advances in Neural Information Processing Systems. 2016. Pp. 2180-2188.
- 12 Evensen G. Analysis of iterative ensemble smoothers for solving inverse problems / G. Evensen // Computational Geosciences. 2018. № 3 (22). Pp. 885-908.
- 13 Gasmi C. F. Physics informed deep learning for flow and transport in porous media / C. F. Gasmi, H. Tchelepi // ArXiv: 2104.02629. 2021.
- 14 Gopa K. Cognitive analytical system based on data-driven approach for mature reservoir management / K. Gopa, S. Yamov, M. Naugolnov // Society of Petroleum Engineers. 2018.
- 15 Guo Zh. A physics-based data-driven model for history matching, prediction, and characterization of waterflooding performance / Zh. Guo, A. C. Reynolds, H. Zhao // SPE Journal. 2018. Vol. 23. No 2. Pp. 367-395.
- 16 Hamilton W. Inductive representation learning on large graphs / W. Hamilton, Z. Ying, J. Leskovec, I. Guyon et al. // Curran Associates. Inc., 2017.
- 17 Holl P. Learning to control PDEs with differentiable physics / P. Holl, N. Thuerey, V. Koltun // International Conference on Learning Representations. 2020.
- 18 Illarionov E. End-to-end neural network approach to 3D reservoir simulation and adaptation / E. Illarionov, P. Temirchev, D. Voloskov et al. // Journal of Petroleum Science and Engineering. 2022. № 208. Pp. 109-332.
- 19 Jaber A. K. A review of proxy modeling applications in numerical reservoir simulation / A. K. Jaber, S. N. Al-Jawad, A. K. Alhuraishawy // Arabian Journal of Geosciences. 2019. Vol. 12. № 22. Pp. 1-16.
- 20 Jansen J. D. The egg model — a geological ensemble for reservoir simulation / J. D. Jansen, R. M. Fonseca, S. Kahrobaei et al. // Geoscience Data Journal. 2014. № 2 (1). Pp. 192-195.
- 21 Karniadakis G. E. Physics-informed machine learning / G. E. Karniadakis, P. Perdikaris, S. Wang, L. Yang et al. // Nature Reviews Physics. 2021. № 6 (3). Pp. 422-440.
- 22 Karumuri S. Simulator-free solution of high-dimensional stochastic elliptic partial differential equations using deep neural networks / S. Karumuri, R. Tripathy, I. Bilonis et al. // Journal of Computational Physics. 2020. № 404. Pp. 109-120.

- 23 Kingma D. P. Adam: A method for stochastic optimization / D. P. Kingma, J. L. Ba // 3rd International Conference on Learning Representations. 2015.
- 24 Ng C. S. W. Smart proxy modeling of a fractured reservoir model for production optimization: Implementation of metaheuristic algorithm and probabilistic application / C. S. W. Ng // Natural Resources Research. 2021. № 3 (30). Pp. 2431-2462.
- 25 Oliver D. S. Recent progress on reservoir history matching: A review / D. S. Oliver, Y. Chen // Computational Geosciences. 2011. Vol. 15. № 1. Pp. 185-221.
- 26 Raissi M. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations / M. Raissi, P. Perdikaris, G. E. Karniadakis // Journal of Computational Physics. 2019. № 378. Pp. 686-707.
- 27 Wang H. Mosaic flows: A transferable deep learning framework for solving PDEs on unseen domains / H. Wang // Computer Methods in Applied Mechanics and Engineering. 2022. № 389. Pp. 114-424.

Arseny W. UMANOVSKIY¹

UDC 662.5

PROXY MODELING OF RESERVOIR HYDRODYNAMICS WITH GRAPH NEURAL NETWORKS

¹ Postgraduate Student,
The Gubkin Russian State University of Oil and Gas
lynx.ff@gmail.com

Abstract

The primary goal of hydrodynamic reservoir modeling is to predict the production wells performance, or more precisely, the dependence of this performance on the choice of the reservoir development plan. The achievement of this goal is hampered by the lack of accurate information about the properties of the reservoir. These properties have to be inferred from indirect data, first of all from the historical indicators of already functioning wells. This information is used to perform the adaptation of the numerical reservoir model or proxy models, which are less informative but have the advantage of speed and flexibility.

The article proposes a reservoir proxy modeling method based on the use of a specific artificial neural network (ANN). The novel graph convolutional architecture of the ANN takes in the graph data describing the reservoir. The edges and vertices of the graph contain a spatial description of the reservoir along with the history of the well performance. Such architecture makes it possible to train the neural network for a whole class of situations instead of only one case. In accordance with the principles of the Physics-Informed Neural Networks (PINN), the task of the ANN is to derive a kind of formulation of a physical law guiding the system, rather than just a correlation between time series. The advantages of this approach over most ANN-based proxy models used today are, firstly, speed: adjustment to historical data and forecast output are made in seconds even for hundreds of wells; secondly, a certain degree of physical meaningfulness.

Citation: Umanovskiy A. W. 2022. "Proxy modeling of reservoir hydrodynamics with graph neural networks". Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy, vol. 8, no. 3 (31), pp. 155-177.
DOI: 10.21684/2411-7978-2022-8-3-155-177

Keywords

Reservoir hydrodynamics, automatic adaptation, physics-informed neural networks, reservoir proxy modeling.

DOI: 10.21684/2411-7978-2022-8-3-155-177

REFERENCES

- 1 Ababkov A. V., Vasilyev V. M., Khisamutdinov N. I., Safiullin I. R., Shaislamov V. Sh. 2014. "Express method for assessing the degree of interaction between wells using frequency analysis of data from the history of operation of injection and production wells". *Oilfield business*, no. 7, pp. 10-13. [In Russian]
- 2 Brilliant L. S., Dulkarnaev M. R., Danko M. Yu., Olisheva A. O., Nabiev D. Kh., Khutorная A. I., Malkov I. N. 2022. "Oil production management based on neural network optimization of well operation modes at the site of pilot works of the YuV1 formation of the Vatyeganskoye field TPE 'Povkhneftegaz'". *Georesources*, no. 1 (24), pp. 3-15. [In Russian]
- 3 Proskurin V. A., Khisamutdinov N. I., Antonov M. S., Sagitov D. K. 2013. "Methods for assessing the effectiveness of the formation of a waterflooding system at the site of the West-Ust-Balykskoye field". *Automation, telemechanization and communication in the oil industry*, no. 6, pp. 36-38. [In Russian]
- 4 Stepanov S. V., Sokolov S. V., Ruchkin A. A., Stepanov A. V., Knyazev A. V., Korytov A. V. 2018. "The problems of assessing the mutual influence of production and injection wells based on mathematical modeling". *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*, no. 3 (4), pp. 146-164. [In Russian]
- 5 Stepanov S. V., Beckman A. D., Ruchkin A. A., Pospelova T. A. 2022. "Maintenance of oil field development using CRM models". *IPC Express*. [In Russian]
- 6 Umanovskiy A. V. 2021. "Simulation method based on training data for two-phase flow in a heterogeneous porous medium". *Computer research and modeling*, no. 4 (13), pp. 779-792. [In Russian]
- 7 Umanovskiy A. V. 2020. "Adversarial convolutional neural networks as a heuristic model of the two-phase filtration process in a porous medium". *Computational mechanics of continuous media*, no. 2 (13), pp. 231-241.
- 8 Shevtsov N. O., Stepanov V. S., Pospelova T. A. 2020. "Study of predictive ability, numerical and analytical models on the example of well interference assessment". *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*, no. 3 (6), pp. 131-142. [In Russian]
- 9 Cai S., Zhiping M. et al. 2022. "Physics-informed neural networks (PINNs) for fluid mechanics: A review". *Acta Mechanica Sinica*. Pp. 1-12.
- 10 Chakra N. C. C., Saraf D. N. 2016. "History matching of petroleum reservoirs employing adaptive genetic algorithm". *Journal of Petroleum Exploration and Production Technology*, no. 4 (6), pp. 653-674.
- 11 Chen X., Duan Y., Houthoof R. 2016. "InfoGAN: Interpretable representation learning by information maximizing generative adversarial nets". *Advances in Neural Information Processing Systems*. Pp. 2180-2188.
- 12 Evensen G. 2018. "Analysis of iterative ensemble smoothers for solving inverse problems". *Computational Geosciences*, no. 3 (22), pp. 885-908.

- 13 Gasmi C. F., Tchelepi H. 2021. "Physics informed deep learning for flow and transport in porous media". ArXiv: 2104.02629.
- 14 Gopa K., Yamov S., Naugolnov M. 2018. "Cognitive analytical system based on data-driven approach for mature reservoir management". Society of Petroleum Engineers.
- 15 Guo Zh., Reynolds A. C., Zhao H. 2018. "A physics-based data-driven model for history matching, prediction, and characterization of waterflooding performance". SPE Journal, vol. 23, no 2, pp. 367-395.
- 16 Hamilton W., Ying Z., Leskovec J., Guyon I. et al. 2017. "Inductive representation learning on large graphs". Curran Associates. Inc.
- 17 Holl P., Thuerey N., Koltun V. 2020. "Learning to control PDEs with differentiable physics". International Conference on Learning Representations.
- 18 Illarionov E., Temirchev P., Voloskov D. et al. 2022. "End-to-end neural network approach to 3D reservoir simulation and adaptation". Journal of Petroleum Science and Engineering, no. 208, pp. 109-332.
- 19 Jaber A. K., Al-Jawad S. N., Alhuraishawy A. K. 2019. "A review of proxy modeling applications in numerical reservoir simulation". Journal of Geosciences, vol. 12, no. 22, pp. 1-16.
- 20 Jansen J. D., Fonseca R. M., Kahrobaei S. et al. 2014. "The egg model — a geological ensemble for reservoir simulation". Data Journal, no. 2 (1), pp. 192-195.
- 21 Karniadakis G. E., Perdikaris P., Wang S., Yang L. et al. 2021. "Physics-informed machine learning". Nature Reviews Physics, no. 6 (3), pp. 422-440.
- 22 Karumuri S., Tripathy R., Bilonis I. et al. 2020. "Simulator-free solution of high-dimensional stochastic elliptic partial differential equations using deep neural networks". Journal of Computational Physics, no. 404, pp. 109-120.
- 23 Kingma D. P., Ba J. L. 2015. "Adam: A method for stochastic optimization". 3rd International Conference on Learning Representations.
- 24 Ng C. S. W. 2021. "Smart proxy modeling of a fractured reservoir model for production optimization: Implementation of metaheuristic algorithm and probabilistic application". Natural Resources Research, no. 3 (30), pp. 2431-2462.
- 25 Oliver D. S., Chen Y. 2011. "Recent progress on reservoir history matching: A review". Computational Geosciences, vol. 15, no. 1, pp. 185-221.
- 26 Raissi M., Perdikaris P., Karniadakis G. E. 2019. "Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations". Journal of Computational Physics, no. 378, pp. 686-707.
- 27 Wang H. 2022. "Mosaic flows: A transferable deep learning framework for solving PDEs on unseen domains". Computer Methods in Applied Mechanics and Engineering, no. 389, pp. 114-424.