

ЭКСПЕРИМЕНТАЛЬНЫЕ И ТЕОРЕТИЧЕСКИЕ ИССЛЕДОВАНИЯ ТЕРМОДИНАМИЧЕСКИХ СВОЙСТВ И ФАЗОВЫХ ПРЕВРАЩЕНИЙ УВ СМЕСЕЙ

Обзорная статья

УДК 004.032.26

<https://doi.org/10.29222/ipng.2078-5712.2024-15-3.art1>

Применение нейросетей для определения параметров PVT-моделей, используемых при решении задач гидродинамического моделирования

Д.П. Аникеев ✉, Э.С. Аникеева

Институт проблем нефти и газа РАН, Москва, Россия

Аннотация. В статье представлен обзор применения подхода нейросетевого обучения для задач моделирования фазового состояния углеводородных систем. Определение состояния углеводородной системы в присутствии или отсутствии неуглеводородных компонентов в пластовых условиях необходимо при выполнении гидродинамических расчетов на многофазных моделях. Такие расчеты востребованы как при решении задач прогнозирования, так и адаптации моделей месторождений к фактическим данным разработки. Показано, что при настройке моделей на фактические данные точность воспроизведения лабораторных экспериментов в ряде случаев выше, чем при использовании уравнений состояния. Но в некоторых случаях применение нейронных сетей оказывается бесполезным. Для относительно «простых» флюидальных систем рост сложности использованного инструмента не дает прироста точности по сравнению с простыми регрессионными моделями. Другой проблемой является отсутствие рабочего инструмента, который позволил бы заменить в полной мере использование уравнений состояния для оценки состояния флюидальной модели при выполнении гидродинамических расчетов.

Ключевые слова: машинное обучение, нейронные сети, гидродинамические модели, флюидальные модели

Финансирование: работа выполнена в рамках государственного задания ИПНГ РАН (тема № 122022800272-4).

Для цитирования: Аникеев Д.П., Аникеева Э.С. Применение нейросетей для определения параметров PVT-моделей, используемых при решении задач гидродинамического моделирования // Актуальные проблемы нефти и газа. 2024. Т. 15, № 3. С. 202–218. <https://doi.org/10.29222/ipng.2078-5712.2024-15-3.art1>

✉ Аникеев Даниил Павлович, e-mail: anikeev@ogri.ru

© Аникеев Д.П., Аникеева Э.С., 2024



Контент доступен под лицензией Creative Commons Attribution 4.0 License.

Введение

В связи с бурным развитием искусственного интеллекта и машинного обучения значительно расширился спектр задач, для решения которых он применяется. Если говорить о задачах, свойственных разработке месторождений нефти и газа, то данные технологии востребованы на всем жизненном цикле месторождений – от обработки сейсмике и результатов разведочного бурения до решения задач ликвидации скважин.

В большинстве современных гидродинамических симуляторов отдельно выделяется расчетный блок, который по данным о текущем общем составе флюида в поровой среде и текущих давлении и температуре определяет наличие и состав жидкой и газообразной фазы. Обычно в этом же блоке вычисляется вязкость жидкой и газовой фаз (при их наличии), хотя, несомненно, вязкость является кинетическим свойством системы. Но выделять вычисление вязкости в отдельный блок, как правило, не разумно, так как все необходимые для вычисления вязкости данные есть в PVT-модуле. При этом используемые модели могут сильно различаться. Например, наиболее популярными при моделировании процесса разработки месторождений нефти и газа являются две модели: нелетучей нефти (известная как модель black oil) и композиционная. Определяемые параметры в моделях во многом совпадают, но сами модели различаются достаточно сильно. Для ряда смесей эти различия могут быть настолько велики, что анализ результатов получения двух разных цифровых моделей для одной и той же физической смеси может представлять отдельную, достаточно сложную задачу.

При выполнении гидродинамических расчетов можно говорить, о наличии «черного ящика», который при получении

информации о состоянии системы возвращает данные о количестве фаз и их составе. Внутри же этого «черного ящика» возможно использование различных инструментов. Одним из таких инструментов может являться задание различных уравнений состояния.

Решения на основе машинного обучения можно рассматривать как альтернативу использования различных уравнений состояния (EOS), построенных на простых функциональных зависимостях.

Для оценки перспектив использования нейронных сетей определим, какая точность моделей может быть доступна, на уже существующих решениях. С инженерной точки зрения решения на основе нейросетей интересны, если они обеспечат более высокую точность, чем существующие, полученные с использованием уравнений состояния.

Уравнения состояния создавались в разное время для различных задач, и не существует какого-то одного универсального. Так, в работе [1] сопоставлено фазовое поведение и объемные характеристики шести уравнений состояния и трех их модификаций (всего 9 моделей) с лабораторными данными. Авторы установили, что газоконденсатные системы лучше всего представляются с помощью немодифицированных трехпараметрических уравнений: Пателя–Тея (Patel–Teja, PT), Шмидта–Венцеля, Эсмаилзаде–Рошанфекра (Esmailzadeh–Roshanfekar). Традиционное поведение нефтяной фазы наиболее надежно прогнозируется с использованием оригинальных уравнений Совье–Редлиха–Квонга (Soave–Redlich–Kwong, SRK) или Пенга–Робинсона (PR). В работе [2], например, ошибки между предсказаниями модели и лабораторными данными по газосодержанию составляют 9% для PR и 17% для модели SRK.

В работе [3] рассмотрены, кроме указанных выше, модификация уравнения PR, модификация в версии 1978 г. (PR78) и модифицированный (расширенный) вариант – PRA, а также модификация уравнения Совье–Редлиха–Квонга (SRKA); ошибки по газосодержанию составляют 9% для PR и 15% для модели SRKA.

Нефти с низкой температурой кипения, богатые промежуточными компонентами, в целом кажутся относительно нечувствительными к типу используемого уравнения состояния [1].

Классификация и краткое описание используемых моделей

Объем статьи не позволяет сколько-нибудь подробно остановиться на используемых моделях нейронных сетей и их классификации. Поэтому очень кратко опишем характеристики упомянутых в статье моделей.

Один нейрон может выполнять простейшие вычисления, но рабочей единицей является слой. Однослойный перцептрон представляет собой простейшую сеть, состоящую из группы нейронов, которые образуют слой.

Входные данные представляют собой вектор, подаваемый на вход каждого нейрона в слое. В свою очередь, нейроны вычисляют выход независимо друг от друга. Количество синапсов у всех нейронов совпадает с размерностью входного сигнала. Многослойная нейронная сеть (многослойный перцептрон) – это нейронная сеть, состоящая из входного, выходного и расположенных между ними одного (или нескольких) скрытых слоев нейронов. Обучение нейронных сетей с помощью генетического алгоритма основывается на генерации случайных наборов параметров,

исключении из дальнейшей обработки наименее эффективных вариантов и их отбрасывании.

Радиально-базисные функции (РБФ, RBF) – это функции, основанные на расстоянии до заданной точки или центра. РБФ работают на принципе, предполагающем зависимость от настройки или весов выходного значения нейронной сети, которые определяют, какую важность следует придавать каждому входному сигналу. Эти функции являются непрерывными, дифференцируемыми. Наиболее часто используемой радиально-базисной функцией является гауссовская функция. Есть также сети РБФ, обладающие особой трехслойной архитектурой. Верхний слой: получает входные данные и передает их скрытому слою, каждый нейрон во входном слое отвечает за один признак (параметр) входных данных. Скрытый слой – это ключевая часть модели. Каждому нейрону в скрытом слое соответствует радиально-базисная функция. Каждый нейрон получает данные из входного слоя, применяет к ним радиально-базисную функцию и передает результаты в выходной слой. Один из основных параметров, который необходимо настроить в скрытом слое, – количество нейронов. Выходной слой принимает данные от скрытого слоя и формирует окончательный вывод. Обычно выходной слой состоит из нейронов, которые объединяют выходные данные скрытого слоя. Чтобы уменьшить ошибку между прогнозами сети и фактическими целевыми значениями, комбинации весов изменяются во время обучения. Обучение нейронной сети РБФ должно проходить в три этапа: выбор центров, определение параметров распространения и обучение выходных весов.

Обучение выходных весов может происходить различными методами: линейной регрессии, псевдоинверсным методом, с помощью генетического алгоритма (ГА). Последний метод включает два этапа: первый этап – обучение на основе ГА. Его цель – оценить подходящие положения центров радиально-базисных функций скрытого слоя. На каждой итерации поиска ГА самостоятельно выбирает, в каких точках пространства входных сигналов сети разметить центры активационных функций нейронов скрытого слоя, и назначает для каждой из них ширину окна.

Второй этап – обучение с учителем. На этом этапе создание сети завершается оценкой линейных весов выходного слоя. Также существует гибридный генетический нейросетевой алгоритм, в котором радиально-базисная нейронная сеть выполняет функцию аппроксиматора целевой функции.

Адаптивная сеть на основе системы нечеткого вывода ANFIS представляет собой пятислойную нейронную сеть с различным назначением слоев:

первый слой – обработка входных переменных;

второй слой – выполнение нечетких правил;

третий слой – нормализация выполненных правил;

четвертый слой – заключения правил;

пятый слой – агрегирование результата, полученного по различным правилам.

Метод опорных векторов (SVM), или машина опорных векторов, – это группа алгоритмов обучения с учителем, который является развитием и обобщением подходов регрессионного анализа. Первоначально метод был предложен для классификации

и разделения набора объектов на классы, но позже его применение было расширено для целей векторной регрессии. Метод хорошо показал себя при выполнении оценки нелинейной регрессии на выборках относительно малого размера.

Также можно рекомендовать работы [4–7] как обзорные по применяемым нейросетям.

Определение параметров PVT-модели

Как уже говорилось, модуль для расчета PVT-состояния системы занимает достаточно обособленное место при проведении гидродинамических вычислений. Поэтому у многих производителей гидродинамических пакетов есть свои модули для расчета моделей PVT. И хотя во многих вопросах они совпадают, например, в вопросе реализации наиболее распространенных уравнений состояния, у каждого производителя есть своя специфика и особенности. Если раньше пакеты для построения PVT-моделей ориентировались только на уравнения состояния, то сейчас их функционал расширяется, в том числе некоторые пакеты предоставляют инструменты для работы с нейронными сетями и для автоматической адаптации моделей к результатам лабораторных экспериментов. Среди лабораторных экспериментов важным является определение параметров смеси в экспериментах истощения при постоянной массе (CCE) и истощение при постоянном объеме (CVD).

В работах [8–10] эмпирические корреляции разного типа рассматриваются как альтернатива реальным физическим экспериментам из-за их большой длительности и сложности.

В работе [8] использовались данные из 166 наборов данных, полученных по 22 различным образцам. Разработанные нейросетевые модели способны прогнозировать давление насыщения, объемный коэффициент нефти и вязкость в зависимости от газового фактора смеси, удельного веса газа, удельного веса нефти и температуры смеси. При этом коэффициент детерминации (R^2) между фактическими значениями и рассчитанными по уравнениям состояния на той же выборке составил от 0,881 до 0,962.

В ряде случаев нейронные сети используются для моделей, где достаточно применения более простых зависимостей, которые использовались ранее. Например, в работе [9] для прогнозирования вязкости нефти альтернативой использованию нейронной сети выступал метод регрессии. При этом построенная зависимость вязкости от давления показывает линейную корреляцию между этими переменными. Аналогичное сравнение метода регрессии и результатов работы нейронных сетей в работе [11] показало, что в данном случае метод регрессии работает не хуже.

В работе [2] было использовано 250 наборов данных. В работе [11] набор из 218 проб сырой нефти, представляющих различные иранские пласты, был разделен на две части: группа из 190 образцов выбрана для обучения модели и 28 образцов предназначены для проверки модели. Полученные результаты показывают, что при прогнозировании объемного коэффициента нефти при давлении насыщения имеют место лучшие характеристики прогнозирования по сравнению с использованием традиционных уравнений состояния. Рост коэффициента корреляции составил от 0,83 до 0,99.

В работе [12] 577 значений данных были выбраны для использования в проекте и случайным образом разделены на две части:

486 – для обучения сети и 91 – для тестирования. Результаты работы сети хорошо согласовывались с экспериментальными данными, средняя относительная ошибка с использованием обучающей выборки при оценке объемного коэффициента и плотности нефти составила 0,557% и 0,509%, соответственно, а с использованием тестовых данных – 1,032% и 1,104%, соответственно.

В работе [13] использовались разные инструменты: искусственная нейронная сеть (сеть обратного распространения ошибки – BPN и сеть радиальных базисных функций – RBF), нечеткая логика (FL). Модели BPN, RBF и FL позволяют прогнозировать давление насыщения с коэффициентами корреляции 0,9926, 0,9969 и 0,9995, соответственно.

В статье [14] разрабатываются и сравниваются четыре нейрокомпьютерные модели с применением алгоритмов, состоящих из многослойного персептрона (MLP), радиальной базисной функции, обученной с помощью генетического алгоритма (RBF-GA), комбинированной гибридной адаптивной системы нейро-нечеткого вывода с оптимизацией роя частиц (CHPSO-ANFIS) и метода наименьших квадратов опорных векторов (LSSVM), настроенного с помощью оптимизатора «имитации отжига». Промысловые данные по нефтяному месторождению Ахваз (Иран) случайным образом разделены на обучающую (80% выборки – 79 записей) и тестовую (20%) подгруппы.

Хотя четыре предложенные модели дают приемлемые результаты, модель CHPSO-ANFIS имеет наилучшие характеристики со средним абсолютным относительным отклонением 0,846, стандартным отклонением 0,0126, среднеквадратичной ошибкой 43,21 и коэффициентом корреляции 0,9902.

В работе [15] рассмотрены методы построения искусственной нейронной сети (ANN), адаптивной системы нейро-нечеткого вывода (ANFIS) и машины опорных векторов (SVM). Полученные результаты показали, что модель ANN использует методы ANFIS и SVM для прогнозирования поведения PVT. Значения коэффициента детерминации для различных моделей составляют 0,995, 0,959 и 0,948 для данных тестирования с использованием моделей ANN, ANFIS и SVM, соответственно.

В работе [16] представлены результаты прогнозирования вязкости ненасыщенной, насыщенной и дегазированной нефти методами искусственной нейронной сети (ANN) и опорных векторов (SVM) с коэффициентом детерминации от 0,95 до 0,97.

В работе [17], которая является продолжением работы [8], представлено сравнение рассчитанных по трем моделям параметров из тестовой выборки с фактическими данными (рис. 1). На основе работы нейронной сети подобраны коэффициенты для соответствующей зависимости. Значение коэффициента R^2 для нее составило 0,98.

В работах [13, 14, 18] авторы предложили подход к прогнозированию газового фактора (ГФ) по результатам анализа бурового раствора и геофизических исследований в процессе бурения. Значительное повышение точности модели по сравнению с традиционными подходами моделирования позволяет оценить ГФ пластового флюида на основе данных по пробам флюида во время бурения перед началом операций на кабеле. Это решение было опробовано в Норвегии.

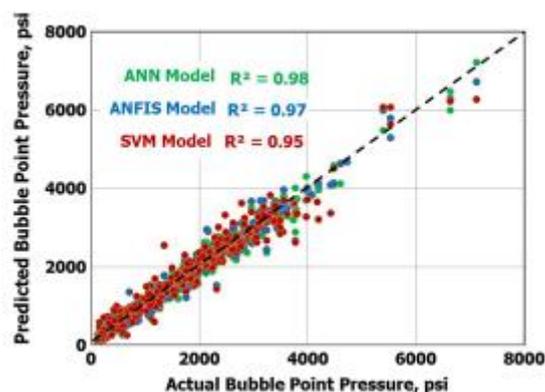


Рис. 1. Коэффициент детерминации (R^2) для прогнозирования давления насыщения пластового флюида с помощью методов искусственного интеллекта для обучающих данных

Fig. 1. Coefficient of determination (R^2) for bubble point pressure prediction using artificial intelligence techniques for the training data

Источник/Source: [17]

В работе [18] проведена оценка эффективности применения методов машинного обучения для достоверного прогнозирования ряда параметров пластовых флюидов: давления насыщения нефти газом, объемного коэффициента нефти, плотности нефти и газа. Тестировали несколько широко известных методов: регрессию опорных векторов, нейронные сети, методы дерева решений, случайного леса и k-ближайших соседей. Для обучения использовались данные по анализу проб нефти с месторождений. Всего выборка составила 250 замеров. Из них сформированы три группы данных: для обучения (163 замеров), для проверки (37 замеров), для тестирования (50 замеров). Результаты расчетов для оценки давления насыщения, объемного коэффициента, плотности нефти и газа свидетельствуют о том, что методы машинного обучения дают хороший прогноз данных тестов.

Для оценки плотности нефти использовались исходные данные: плотность дегазированной нефти и ее газонасыщенность. Входными данными для оценки плотности газа во всех методах было содержание метана и азота. Коэффициенты корреляции (для различных методов) по давлению насыщения составили (в д. ед.) от 0,82 до 0,94, для объемного коэффициента нефти – от 0,9 до 0,99, для плотности нефти – от 0,84 до 0,95, для плотности газа – от 0,65 до 0,89. При этом нет единой методики прогнозирования, которая показала бы хорошие результаты по всем четырем рассматриваемым параметрам. Таким образом, можно утверждать, что есть хороший потенциал для прогнозирования давления насыщения и объемного коэффициента нефти. Несколько хуже обстоит дело с прогнозированием плотности газа и нефти.

В дальнейшем авторы используют два подхода для прогнозирования свойств флюидальной системы. По первому подходу они разрабатывают модели машинного обучения для прогнозирования плотности пластового флюида, аналогичные подходу прогнозирования газового фактора, описанному в [13]. На основе обширной базы данных флюидов авторами создаются модели машинного обучения для прогнозирования плотности пластовых флюидов от C_1 до C_5 .

В качестве второго подхода вместо разработки модели машинного обучения для отдельных свойств жидкости с составами от C_1 до C_5 авторы исследуют наиболее важные свойства для характеристики жидкости с использованием уравнений состояния: составы C_6 и C_{7+} , а также молекулярную массу и плотность фракции C_{7+} . Как только эти свойства будут определены, весь спектр свойств жидкости можно будет рассчитать с помощью уравнений состояния.

В дальнейшем, в работах [16, 19] авторы публикуют результаты последующих исследований для прогнозирования других свойств жидкости, помимо газового фактора.

Результаты прогнозирования свойств жидкости при обоих подходах являются удовлетворительными. Прогноз плотности пластовой нефти имеет среднюю ошибку 0,039 г/см³. Точность превосходит типичную плотность, полученную на основе градиента давления по данным каротажа на кабеле. Для основных свойств жидкости, необходимых для прогнозирования модели EOS, общая точность приемлема по сравнению с лабораторными измерениями. Предсказания свойств пластовых флюидов на основе уравнений состояния аналогичны или лучше, чем у предсказаний на основе отдельных моделей машинного обучения.

В работах [20–22] представлены практические примеры, когда результаты лабораторных исследований бурового раствора на одном объекте позволяют настроить PVT-модель для применения ее на других объектах. Таким образом, данные решения можно рассматривать как более технологичное воплощение метода аналогий, позволяющее заменить расчет свойств флюидальной системы на решение системы более простых уравнений.

Замена решения уравнений состояния на результаты работы нейронных сетей

Если производить замену решений на основе уравнений состояния на результаты работы нейронных сетей, то возникает вопрос о возможной потере «физичности» получаемого решения. Лет 10–20 назад был «бум» использования фильтра Калмана для решения различных задач, в том числе прогнозирования процесса разработки, адаптации моделей к истории разработки.

Объем статьи не позволяет подробно остановиться на этом вопросе, но его применение также ставило вопрос о получении решений, не соответствующих физике процесса. Были предложены подходы к урегулированию данной проблемы.

В целом, можно говорить, что при выполнении достаточно тщательного тестирования получаемых нейронных сетей и контроле «физичности» решения проблема его потери может быть устранена.

В настоящее время для решения гидродинамических задач активно применяется подход с использованием явно-неявных схем. При этом подходе динамически определяется область, в которой выполняется решение системы нелинейных уравнений. Вне этой области используется явная схема. Размер такой области зависит от особенностей расчетной схемы и протекающих в модели процессов. В сложных случаях область может охватывать большую часть сеточной модели. Получаемая система уравнений содержит в себе как уравнения гидродинамики, так и уравнения состояния, описывающие флюидальную систему.

Таким образом, для сложных PVT-систем, поведение которых можно описать уравнениями состояния, возможны ситуации, когда вычислительные затраты для определения состояния флюида в сеточной ячейке велики и необходимо вычислять состояние флюида в каждой ячейке сеточной модели на каждом временном шаге (а иногда – на каждой итерации) гидродинамического расчета. В таких случаях расчет состояния сложной PVT-модели может сильно влиять на результат всей гидродинамической задачи.

В статье [23] на основе общепризнанного физического подхода, опираясь на фундаментальные законы и теорию молекулярного

взаимодействия, авторы разработали модели нейронных сетей для замены уравнений состояния. Рассматриваемый диапазон давления и температуры в моделях существенно перекрывает возможные значения этих параметров при разработке месторождений нефти и газа, в том числе глубокозалегающих. Авторы построили две нейронные сети. Разница между двумя нейросетями заключалась в том, что одна из них использовала выходные данные расчетов взаимодействия атомов в качестве входных данных для нейросети. Другая просто основывалась на фундаментальных физических характеристиках, таких как температура и плотность. Обе эти модели продемонстрировали способность точно предсказывать давления при значениях средней абсолютной процентной ошибки, равной 1,9% (первый вариант нейронной сети) и 2,6% (второй вариант нейронной сети) по всему диапазону температур, соответственно. Авторы протестировали предварительно обученные сети на результатах физических экспериментов с чистым веществом.

Но даже для относительно простых моделей нелетучей нефти были предприняты попытки заменить построение PVT-модели использованием нейронной сети. Однако мотивация тут несколько иная. Использование нейронной сети в данном случае – попытка уйти от ограничений модели нелетучей нефти [24].

В работе [24] предложен метод, который использует статистический эстиматор, который позволяет заменить все пространство возможных PVT-моделей, отвечающих различным значениям параметров, на упрощенную прокси-модель. Для этого осуществляется серия расчетов для различных комбинаций исходных параметров и строится кусочно-полиномиальная поверхность отклика (прокси-модель).

Она позволяет приближенно предсказать отклик PVT-модели на комбинацию различных исходных параметров. После построения прокси-модели выполняются дополнительные расчеты PVT-модели с различными комбинациями варьируемых параметров, по результатам которых

уточняется прокси-модель. По скорости предложенный метод значительно уступает линейной регрессии, но позволяет построить более точную модель. На рис. 2, приведенном из работы [25], представлены результаты адаптации модели к фактическим данным.

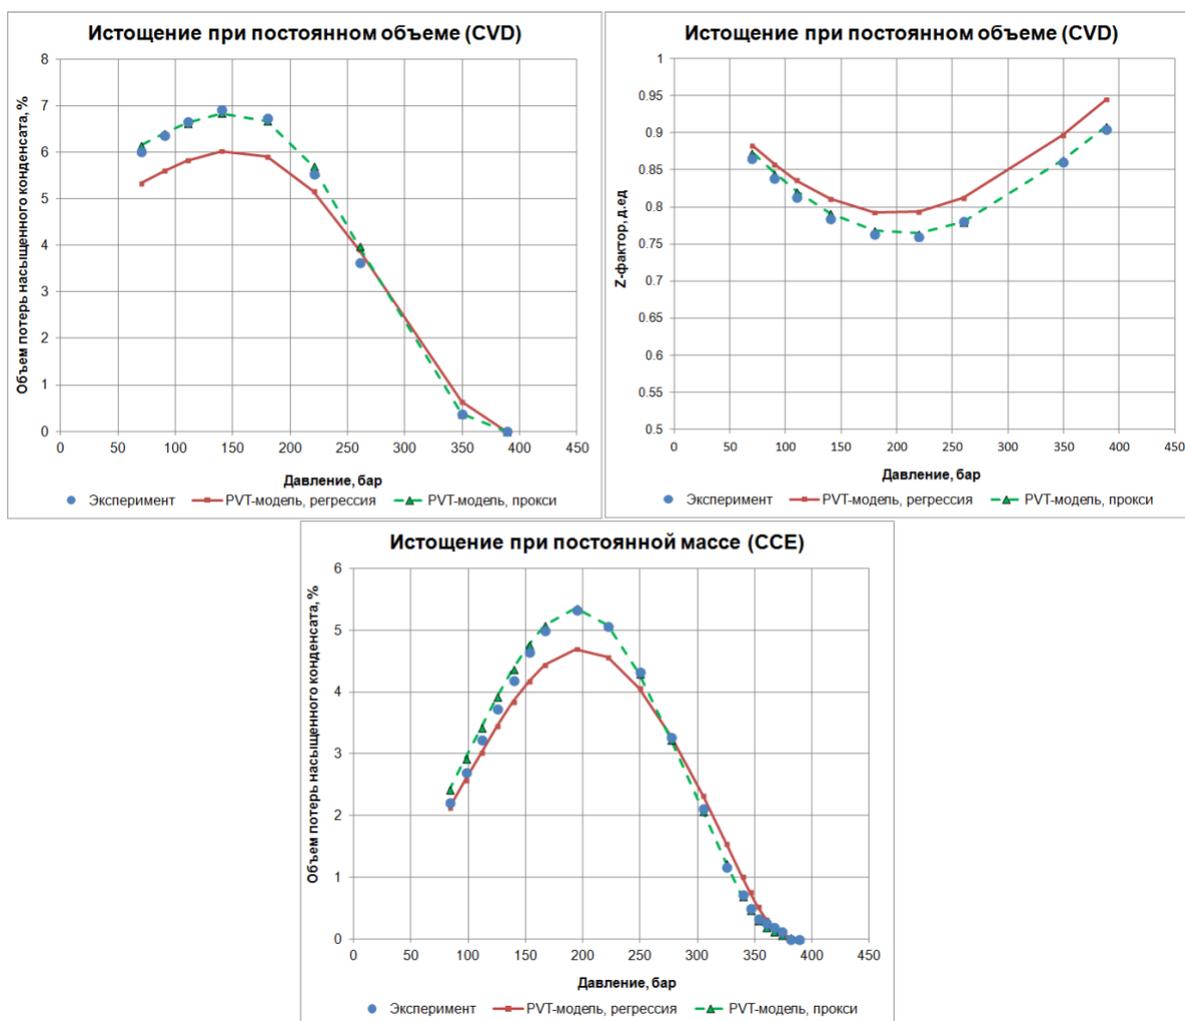


Рис. 2. Сравнение результатов моделирования и данных лабораторных экспериментов

Fig. 2. Comparison of modeling results and laboratory data

Источник/Source: [25]

Еще одним направлением является использование физически информированных нейронных сетей (ФИНС, Physics-Informed Neural Networks, PINN). В данном случае нейронная сеть используется для непосредственного предсказания эволюции физической системы. Обучение проводится

на синтетических наборах данных, которые являются результатом расчетов на «классических» гидродинамических моделях. Критерием успеха обучения является возможность ФИНС предсказывать поведение систем, выходящих за рамки обучающей выборки [25–27].

Например, на рис. 3, представленном из статьи [28], для моделей с различными значениями проницаемости показаны предсказанные нейронной сетью временные

зависимости показателей дебита воды Q_w и нефти Q_o одной и той же добывающей скважины в сравнении с данными численного моделирования.

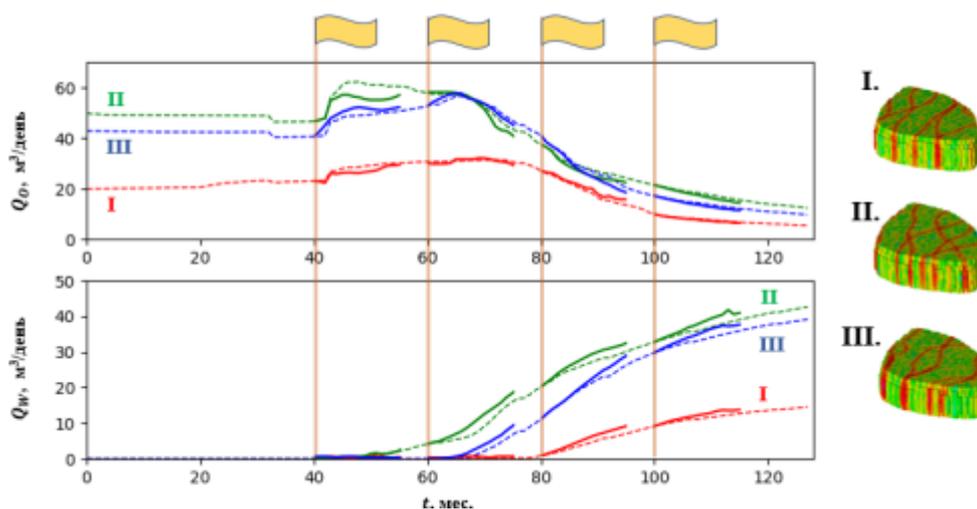


Рис. 3. Предсказанные нейронной сетью показатели (сплошные линии) в сравнении с данными численного моделирования (штриховые линии) для трех вариантов модели

Fig. 3. Neural network predictions (solid lines) compared with numerical modeling data (dashed lines) for the three model variants

Источник/Source: [28]

В работе [29] произведено сравнение решения задачи о неизотермическом течении в пористой среде с учетом геотехнических эффектов с решением, полученным с помощью пакета COMSOL, который решает классические дифференциальные уравнения. В таком подходе нейронная сеть отдельно не решает задачу о фазовом состоянии флюида, но учитывает физические превращения. Сопоставления решений показали хорошие совпадения.

Выводы

Если рассматривать задачу о состоянии флюидальной системы как изолированную, то нейронные сети позволяют получить лучшую точность воспроизведения лабораторных экспериментов по сравнению

с использованием классических уравнений состояния. Но для этого требуется массив валидных лабораторных экспериментов для обучения в объеме нескольких сотен исследований.

Если рассматривать эту задачу как подчиненную задаче гидродинамического моделирования, то возникают дополнительные ограничения и условия. Поскольку задача о разделении флюида на фазы решается многократно на каждом временном шаге прямой задачи, требуется быстрое ее решение.

В данном случае можно выделить два рабочих подхода и несколько теоретически разрабатываемых. Последние еще не реализованы на уровне коммерческих решений.

К рабочим решениям можно отнести:

1. Использование нейронной сети для настройки коэффициентов существующего уравнения состояния или построения нового уравнения состояния. В дальнейшем расчет идет только с использованием уравнения состояния.

2. Использование прокси-моделей разного рода, в которых задача о состоянии флюидальной системы не решается в явном виде, или аппроксимаций на основе ранее полученных решений.

К решениям, не нашедшим широкого коммерческого применения, можно отнести:

1. «Быстрые» нейронные сети, которые предсказывают состояние флюидальной системы с точностью, достаточной для вычисления гидродинамической задачи.

2. Нейронные сети, которые являются подвариантом прокси-модели, но работают не с объектами уровня секторных или полноразмерных моделей, а отвечают за решение гидродинамической задачи в рамках одной сеточной ячейки.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Список источников

1. *O'Reilly D.I.* Comparative PVT simulation: An application to Australasian fluid samples // SPE Annual Technical Conference and Exhibition, New Orleans, Louisiana, USA, 4–7 October 2009. Paper SPE-129517-STU. <https://doi.org/10.2118/129517-STU>

2. *Hassan A., Abdulraheem A., Mohamed A.* Reliable models for determining the pressure-volume-temperature PVT properties using artificial intelligence technique // International Petroleum Technology Conference, Dhahran, Saudi Arabia, 13–15 January 2020. Paper IPTC-19884-Abstract. <https://doi.org/10.2523/IPTC-19884-Abstract>

3. *Farkha S.A., Zangana M.H.S., Shoham O.* Evaluation of compositional models and PVT correlations for Iraqi light crude oils properties // Energy Science & Engineering. 2023. Vol. 11, No. 7. P. 2654–2667. <https://doi.org/10.1002/ese3.1456>

4. *Ghorbani H., Wood D.A., Choubineh A.* et al. Performance comparison of bubble point pressure from oil PVT data: Several neurocomputing techniques compared // Experimental and Computational Multiphase Flow. 2019. Vol. 2, No. 4. P. 225–246. <https://doi.org/10.1007/s42757-019-0047-5>

5. *Karaboga D., Kaya E.* Adaptive network based fuzzy inference system (ANFIS) training approaches: A comprehensive survey // Artificial Intelligence Review. 2019. Vol. 52, No. 4. P. 2263–2293. <https://doi.org/10.1007/s10462-017-9610-2>

6. *Казакова Е.М.* Краткий обзор методов оптимизации на основе роя частиц // Вестник КРАУНЦ. Физико-математические науки. 2022. Т. 39, № 2. С. 150–174. <https://doi.org/10.26117/2079-6641-2022-39-2-150-174>

7. *Wang G., Pu X.-L., Tao H.-Z.* A support vector machine approach for the prediction of drilling fluid density at high temperature and high pressure // Petroleum Science and Technology. 2012. Vol. 30, No. 5. P. 435–442. <https://doi.org/10.1080/10916466.2011.578095>

8. *Rammy M.H., Abdulraheem A.* PVT correlations for Pakistani crude oils using artificial neural network // *Journal of Petroleum Exploration and Production Technology*. 2017. Vol. 7, No. 1. P. 217–233. <https://doi.org/10.1007/s13202-016-0232-z>
9. *Obanijesu E.O., Omidiora E.O.* The artificial neural network's prediction of crude oil viscosity for pipeline safety // *Petroleum Science and Technology*. 2009. Vol. 27, No. 4. P. 412–426. <https://doi.org/10.1080/10916460701853846>
10. *Adetiloye B.* Determination of the dew-point pressure (Dpp) for a gas condensate fluid by genetic algorithm (Ga) // *SPE Annual Technical Conference and Exhibition, New Orleans, Louisiana, USA, 30 September – 2 October 2013*. Paper SPE 167620-STU. <https://doi.org/10.2118/167620-STU>
11. *Moghadam J.N., Salahshoor K., Kharrat R.* Introducing a new method for predicting PVT properties of Iranian crude oils by applying artificial neural networks // *Petroleum Science and Technology*. 2011. Vol. 29, No. 10. P. 1066–1079. <https://doi.org/10.1080/10916460903551040>
12. *Mehrizadeh M.* Estimation of PVT properties using artificial neural networks and comparison of results with experimental data // *Khazar Journal of Science and Technology*. 2020. Vol. 4, No. 1. P. 97–110. <https://doi.org/10.5782/2520-6133.2020.4.1.97>
13. *Alakbari F.S., Elkatatny S.* Prediction of bubble point pressure using artificial intelligence AI techniques // *SPE Middle East Artificial Lift Conference and Exhibition, Manama, Bahrain, 30 November – 1 December 2016*. Paper SPE-184208-MS. <https://doi.org/10.2118/184208-MS>
14. *Ghorbani H., Wood D.A., Choubineh A.* et al. Performance comparison of bubble point pressure from oil PVT data: Several neurocomputing techniques compared // *Experimental and Computational Multiphase Flow*. 2020. Vol. 2, No. 4. P. 225–246. <https://doi.org/10.1007/s42757-019-0047-5>
15. *Ahmed M.E., Sultan A.S., Hassan A.* et al. Predicting the performance of constant volume depletion tests for gas condensate reservoirs using artificial intelligence techniques // *Neural Computing & Applications*. 2022. Vol. 34, No. 24. P. 22115–22125. <https://doi.org/10.1007/s00521-022-07682-8>
16. *Хадавимогоаддам Ф., Чебышев И.С., Чапанова И.В., Хао Ю.* Новый подход к оценке вязкости сырой нефти на основе метода машинного обучения // *Территория Нефтегаз*. 2020. № 9–10. С. 12–18.
17. *Elkatatny S., Mahmoud M.* Development of a new correlation for bubble point pressure in oil reservoirs using artificial intelligent technique // *Arabian Journal for Science and Engineering*. 2018. Vol. 43, No. 5. P. 2491–2500. <https://doi.org/10.1007/s13369-017-2589-9>
18. *Bandyopadhyay P.* Improved estimation of bubble point pressure of crude oils: Modelling by regression analysis // *SPE Annual Technical Conference and Exhibition, Denver, Colorado, USA, 30 October – 2 November 2011*. Paper SPE 152371-STU. <https://doi.org/10.2118/152371-STU>
19. *Хадавимогоаддам Ф., Мищенко И.Т., Мостаджеран М.* Применение методов искусственного интеллекта в прогнозировании основных свойств нефти // *Газовая промышленность*. 2019. № 12(794). С. 28–32.
20. *Yang T., Uleberg K., Cely A.* et al. Unlock large potentials of standard mud gas for real-time fluid typing // *SPWLA 63rd Annual Logging Symposium, Stavanger, Norway, 11–15 June 2022*. Paper SPWLA-2022-0007. <https://doi.org/10.30632/SPWLA-2022-0007>
21. *Kopal M., Yerkinkyzy G., Nygård M.T.* et al. Real-time fluid identification from integrating advanced mud gas and petrophysical logs // *SPWLA 63rd Annual Logging Symposium, Stavanger, Norway, 11–15 June 2022*. Paper SPWLA-2022-0009. <https://doi.org/10.30632/SPWLA-2022-0009>

22. Ungar F., Yerkinzy G., Bravo M.C., Yang T. Improved reservoir fluid estimation for prospect evaluation using mud gas data // SPE Offshore Europe Conference & Exhibition, Aberdeen, Scotland, UK, 5–8 September 2023. Paper SPE-215538-MS. <https://doi.org/10.2118/215538-MS>
23. Callow T.J., Nikl J., Kraisler E., Cangi A. Physics-enhanced neural networks for equation-of-state calculations // Machine Learning: Science and Technology. 2023. Vol. 4, No. 4. P. 045055. <https://doi.org/10.1088/2632-2153/ad13b9>
24. Sola-Aremu O. An inferable machine learning approach to predicting PVT properties of Niger Delta crude oil using compositional data // SPE Annual Technical Conference and Exhibition, Calgary, Alberta, Canada, 30 September – 2 October 2019. Paper SPE-199783-STU. <https://doi.org/10.2118/199783-STU>
25. Ambarian T., Olenchikov D. An application of proxy-modeling framework for numerical PVT-models matching on laboratory measured data // SPE Russian Petroleum Technology Conference, Moscow, Russia, 16–18 October 2017. Paper SPE-187815-MS. <https://doi.org/10.2118/187815-MS>
26. Cai S., Mao Z., Wang Z. et al. Physics-informed neural networks (PINNs) for fluid mechanics: A review // Acta Mechanica Sinica. 2021. Vol. 37, No. 12. P. 1727–1738. <https://doi.org/10.1007/s10409-021-01148-1>
27. Almajid M.M., Abu-Al-Saud M.O. Prediction of porous media fluid flow using physics informed neural networks // Journal of Petroleum Science and Engineering. 2022. Vol. 208. P. 109205. <https://doi.org/10.1016/j.petrol.2021.109205>
28. Умановский А.В. Графовые нейронные сети для прокси-моделирования гидродинамики пласта // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2022. Т. 8, № 3(31). С. 155–177. <https://doi.org/10.21684/2411-7978-2022-8-3-155-177>
29. Amini D., Haghghat E., Juanes R. Physics-informed neural network solution of thermo-hydro-mechanical (THM) processes in porous media // Journal of Engineering Mechanics. 2022. Vol. 148, No. 11. [https://doi.org/10.1061/\(asce\)em.1943-7889.0002156](https://doi.org/10.1061/(asce)em.1943-7889.0002156)

Информация об авторах

Даниил Павлович Аникеев – к.т.н., заведующий лабораторией, старший научный сотрудник, Институт проблем нефти и газа РАН, Москва, Россия; SPIN-код: 5132-4200, <https://orcid.org/0000-0001-9188-9586>; e-mail: anikeev@ogri.ru

Эльвира Сергеевна Аникеева – младший научный сотрудник, Институт проблем нефти и газа РАН, Москва, Россия; SPIN-код: 3984-0948; e-mail: esanikeeva@ogri.ru

Поступила в редакцию 05.06.2024

EXPERIMENTAL AND THEORETICAL STUDIES OF THERMODYNAMIC FEATURES AND PHASE BEHAVIOR OF HYDROCARBON MIXTURES

Review

<https://doi.org/10.29222/ipng.2078-5712.2024-15-3.art1>

Application of neural networks for determining the parameters of PVT-models used in solving hydrodynamic modeling problems

D.P. Anikeev ✉, E.S. Anikeeva

Oil and Gas Research Institute, Russian Academy of Sciences, Moscow, Russia

Abstract. The article presents an overview of the application of machine learning models for problems of modeling the phase state of hydrocarbon systems. Determination of the state of a hydrocarbon system is possible in the presence of nonhydrocarbon components when performing hydrodynamic calculations on multiphase models. Such calculations are in demand when solving problems of both forecasting and adapting models to actual development data. It is shown that when adjusting models to actual data, the accuracy of reproducing laboratory experiments is in some cases higher than when using equations of state. But in some cases, the use of neural networks turns out to be useless. For relatively “simple” fluid systems, an increase in the complexity of the tool used does not provide an increase in accuracy compared to simple regression models. Another problem is the lack of a working tool that would completely replace the use of equations of state to assess the state of a fluid model when performing hydrodynamic calculations.

Keywords: machine learning, neural networks, hydrodynamic models, fluid models

Funding: the work was funded by the Ministry of Science and Higher Education of the Russian Federation (State Assignment No. 122022800272-4).

For citation: Anikeev D.P., Anikeeva E.S. Application of neural networks for determining the parameters of PVT-models used in solving hydrodynamic modeling problems. *Actual Problems of Oil and Gas*. 2024. Vol. 15, No. 3. P. 202–218. (In Russ.). <https://doi.org/10.29222/ipng.2078-5712.2024-15-3.art1>

✉ Daniil P. Anikeev, e-mail: anikeev@ogri.ru

© Anikeev D.P., Anikeeva E.S., 2024



The content is available under Creative Commons Attribution 4.0 License.

Conflict of interests

The authors declare no conflict of interests.

References

1. O'Reilly D.I. Comparative PVT simulation: An application to Australasian fluid samples. In: *SPE Annual Technical Conference and Exhibition*, New Orleans, Louisiana, USA, 4–7 October 2009. Paper SPE-129517-STU. <https://doi.org/10.2118/129517-STU>
2. Hassan A., Abdulraheem A., Mohamed A. Reliable models for determining the pressure-volume-temperature PVT properties using artificial intelligence technique. In: *International Petroleum Technology Conference*, Dhahran, Saudi Arabia, 13–15 January 2020. Paper IPTC-19884-Abstract. <https://doi.org/10.2523/IPTC-19884-Abstract>
3. Farkha S.A., Zangana M.H.S., Shoham O. Evaluation of compositional models and PVT correlations for Iraqi light crude oils properties. *Energy Science & Engineering*. 2023. Vol. 11, No. 7. P. 2654–2667. <https://doi.org/10.1002/ese3.1456>
4. Ghorbani H., Wood D.A., Choubineh A. et al. Performance comparison of bubble point pressure from oil PVT data: Several neurocomputing techniques compared. *Experimental and Computational Multiphase Flow*. 2019. Vol. 2, No. 4. P. 225–246. <https://doi.org/10.1007/s42757-019-0047-5>
5. Karaboga D., Kaya E. Adaptive network based fuzzy inference system (ANFIS) training approaches: A comprehensive survey. *Artificial Intelligence Review*. 2019. Vol. 52, No. 4. P. 2263–2293. <https://doi.org/10.1007/s10462-017-9610-2>
6. Kazakova E.M. A concise overview of particle swarm optimization methods. *Vestnik KRAUNC. Fiziko-matematicheskie nauki*. 2022. Vol. 39, No. 2. P. 150–174. (In Russ.). <https://doi.org/10.26117/2079-6641-2022-39-2-150-174>
7. Wang G., Pu X.-L., Tao H.-Z. A support vector machine approach for the prediction of drilling fluid density at high temperature and high pressure. *Petroleum Science and Technology*. 2012. Vol. 30, No. 5. P. 435–442. <https://doi.org/10.1080/10916466.2011.578095>
8. Rammay M.H., Abdulraheem A. PVT correlations for Pakistani crude oils using artificial neural network. *Journal of Petroleum Exploration and Production Technology*. 2017. Vol. 7, No. 1. P. 217–233. <https://doi.org/10.1007/s13202-016-0232-z>
9. Obanijesu E.O., Omidiora E.O. The artificial neural network's prediction of crude oil viscosity for pipeline safety. *Petroleum Science and Technology*. 2009. Vol. 27, No. 4. P. 412–426. <https://doi.org/10.1080/10916460701853846>
10. Adetiloye B. Determination of the dew-point pressure (Dpp) for a gas condensate fluid by genetic algorithm (Ga). In: *SPE Annual Technical Conference and Exhibition*, New Orleans, Louisiana, USA, 30 September – 2 October 2013. Paper SPE 167620-STU. <https://doi.org/10.2118/167620-STU>
11. Moghadam J.N., Salahshoor K., Kharrat R. Introducing a new method for predicting PVT properties of Iranian crude oils by applying artificial neural networks. *Petroleum Science and Technology*. 2011. Vol. 29, No. 10. P. 1066–1079. <https://doi.org/10.1080/10916460903551040>
12. Mehrizadeh M. Estimation of PVT properties using artificial neural networks and comparison of results with experimental data. *Khazar Journal of Science and Technology*. 2020. Vol. 4, No. 1. P. 97–110. <https://doi.org/10.5782/2520-6133.2020.4.1.97>

13. Alakbari F.S., Elkatatny S. Prediction of bubble point pressure using artificial intelligence AI techniques. In: *SPE Middle East Artificial Lift Conference and Exhibition*, Manama, Bahrain, 30 November – 1 December 2016. Paper SPE-184208-MS. <https://doi.org/10.2118/184208-MS>
14. Ghorbani H., Wood D.A., Choubineh A. et al. Performance comparison of bubble point pressure from oil PVT data: Several neurocomputing techniques compared. *Experimental and Computational Multiphase Flow*. 2020. Vol. 2, No. 4. P. 225–246. <https://doi.org/10.1007/s42757-019-0047-5>
15. Ahmed M.E., Sultan A.S., Hassan A. et al. Predicting the performance of constant volume depletion tests for gas condensate reservoirs using artificial intelligence techniques. *Neural Computing & Applications*. 2022. Vol. 34, No. 24. P. 22115–22125. <https://doi.org/10.1007/s00521-022-07682-8>
16. Hadavimoghaddam F., Chebyshev I.S., Chapanova I.V., Hao Yu. A new approach to estimating crude oil viscosity based on machine learning method. *Territorija Neftegaz*. 2020. No. 9–10. P. 12–18. (In Russ.).
17. Elkatatny S., Mahmoud M. Development of a new correlation for bubble point pressure in oil reservoirs using artificial intelligent technique. *Arabian Journal for Science and Engineering*. 2018. Vol. 43, No. 5. P. 2491–2500. <https://doi.org/10.1007/s13369-017-2589-9>
18. Bandyopadhyay P. Improved estimation of bubble point pressure of crude oils: Modelling by regression analysis. In: *SPE Annual Technical Conference and Exhibition*, Denver, Colorado, USA, 30 October – 2 November 2011. Paper SPE 152371-STU. <https://doi.org/10.2118/152371-STU>
19. Hadavimoghaddam F., Mishchenko I.T., Mostajeran M. Application of artificial intelligence methods in forecasting the key oil properties. *Gazovaya promyshlennost*. 2019. No. 12(794). P. 28–32. (In Russ.).
20. Yang T., Uleberg K., Cely A. et al. Unlock large potentials of standard mud gas for real-time fluid typing. In: *SPWLA 63rd Annual Logging Symposium*, Stavanger, Norway, 11–15 June 2022. Paper SPWLA-2022-0007. <https://doi.org/10.30632/SPWLA-2022-0007>
21. Kopal M., Yerkinzy G., Nygård M.T. et al. Real-time fluid identification from integrating advanced mud gas and petrophysical logs. In: *SPWLA 63rd Annual Logging Symposium*, Stavanger, Norway, 11–15 June 2022. Paper SPWLA-2022-0009. <https://doi.org/10.30632/SPWLA-2022-0009>
22. Ungar F., Yerkinzy G., Bravo M.C., Yang T. Improved reservoir fluid estimation for prospect evaluation using mud gas data. In: *SPE Offshore Europe Conference & Exhibition*, Aberdeen, Scotland, UK, 5–8 September 2023. Paper SPE-215538-MS. <https://doi.org/10.2118/215538-MS>
23. Callow T.J., Nikl J., Kraiser E., Cangi A. Physics-enhanced neural networks for equation-of-state calculations. *Machine Learning: Science and Technology*. 2023. Vol. 4, No. 4. P. 045055. <https://doi.org/10.1088/2632-2153/ad13b9>
24. Sola-Aremu O. An inferable machine learning approach to predicting PVT properties of Niger Delta crude oil using compositional data. In: *SPE Annual Technical Conference and Exhibition*, Calgary, Alberta, Canada, 30 September – 2 October 2019. Paper SPE-199783-STU. <https://doi.org/10.2118/199783-STU>
25. Ambarian T., Olenchikov D. An application of proxy-modeling framework for numerical PVT-models matching on laboratory measured data. In: *SPE Russian Petroleum Technology Conference*, Moscow, Russia, 16–18 October 2017. Paper SPE-187815-MS. <https://doi.org/10.2118/187815-MS>

26. Cai S., Mao Z., Wang Z. et al. Physics-informed neural networks (PINNs) for fluid mechanics: A review. *Acta Mechanica Sinica*. 2021. Vol. 37, No. 12. P. 1727–1738. <https://doi.org/10.1007/s10409-021-01148-1>
27. Almajid M.M., Abu-Al-Saud M.O. Prediction of porous media fluid flow using physics informed neural networks. *Journal of Petroleum Science and Engineering*. 2022. Vol. 208. P. 109205. <https://doi.org/10.1016/j.petrol.2021.109205>
28. Umanovskiy A.W. Proxy modeling of reservoir hydrodynamics with graph neural networks. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy* 2022. Vol. 8, No. 3(31). P. 155–177. (In Russ.). <https://doi.org/10.21684/2411-7978-2022-8-3-155-177>
29. Amini D., Haghghat E., Juanes R. Physics-informed neural network solution of thermo-hydro-mechanical (THM) processes in porous media. *Journal of Engineering Mechanics*. 2022. Vol. 148, No. 11. [https://doi.org/10.1061/\(asce\)em.1943-7889.0002156](https://doi.org/10.1061/(asce)em.1943-7889.0002156)

Information about the authors

Daniil P. Anikeev – Cand. Sci. (Eng.), Head of Laboratory, Senior Researcher, Oil and Gas Research Institute, Russian Academy of Sciences, Moscow, Russia; <https://orcid.org/0000-0001-9188-9586>; e-mail: anikeev@ogri.ru

Elvira S. Anikeeva – Junior Researcher, Oil and Gas Research Institute, Russian Academy of Sciences, Moscow, Russia; e-mail: esanikeeva@ogri.ru

Received 05.06.2024