

ГИДРОТЕРМОДИНАМИЧЕСКОЕ И ГЕОМЕХАНИЧЕСКОЕ МОДЕЛИРОВАНИЕ ПРОЦЕССОВ В НАСЫЩЕННЫХ ГЕОСРЕДАХ

Оригинальная статья

УДК 681.5.017

<https://doi.org/10.29222/ipng.2078-5712.2024-15-4.art3>

Оптимизация системы заводнения: преимущества гибридного подхода к разработке нейросетевых моделей фильтрации

Р.Ю. Пономарев, Р.Р. Зиязев ✉, А.А. Лещенко, Р.Р. Мигманов, М.И. Ивлев

ООО «Тюменский нефтяной научный центр», Тюмень, Россия

Аннотация. *Актуальность.* В последнее время нейронные сети все чаще используются для обработки и прогнозирования динамики технологических показателей работы скважин. Однако есть ряд ограничений в их применении для оптимизации системы заводнения. *Цель работы.* Разработка моделей, позволяющих корректно воспроизвести процесс влияния системы поддержания пластового давления на работу добывающих скважин. Рассмотрена задача моделирования реакции добывающих скважин на изменение режимов закачки воды в нагнетательных скважинах с помощью методов нейросетевого моделирования. *Результаты.* Предложены подходы к созданию и обучению физико-информированных нейронных сетей для моделирования откликов в добыче нефти по изменениям режимов в системе поддержания пластового давления. Приведены результаты тестирования обучения и прогностических способностей моделей PINN (physics-informed neural network), проведено сравнение с результатами прогнозирования на классической нейронной сети LSTM. *Выводы.* При гибридном обучении моделей с учетом фактических данных модели PINN позволяют нивелировать ограничения классических нейронных сетей.

Ключевые слова: нейросетевое моделирование, разработка месторождений, физико-информированные нейронные сети, оптимизация режимов работы нагнетательных скважин

Финансирование: источники финансирования отсутствовали.

Для цитирования: Пономарев Р.Ю., Зиязев Р.Р., Лещенко А.А., Мигманов Р.Р., Ивлев М.И. Оптимизация системы заводнения: преимущества гибридного подхода к разработке нейросетевых моделей фильтрации // Актуальные проблемы нефти и газа. 2024. Т. 15, № 4. С. 349–363. <https://doi.org/10.29222/ipng.2078-5712.2024-15-4.art3>

✉ Зиязев Рамиль Ришатович, e-mail: rrziyazev@tnnc.rosneft.ru

© Пономарев Р.Ю., Зиязев Р.Р., Лещенко А.А., Мигманов Р.Р., Ивлев М.И., 2024



Контент доступен под лицензией Creative Commons Attribution 4.0 License.

Введение

В настоящее время отмечается тенденция к цифровизации добывающего промысла в России. Успешно внедряются термоманометрические и телеметрические системы для быстрого получения информации о состоянии скважин и оперативного управления процессом разработки. В ручном режиме обработать такие объемы информации не представляется возможным, либо этот процесс занимает очень большой объем человеческих ресурсов и времени. Поэтому текущий вектор развития нефтегазовой отрасли требует создания инструментов для автоматизированного анализа большого объема геолого-промысловых данных и выдачи рекомендаций с целью решения поставленных задач производства. В работе рассматривается процесс управления системой заводнения пласта, как одна из перспективных областей для апробации инструментов интеллектуального управления.

Заводнение – это процесс закачки воды в пласт, направленный на увеличение и поддержание отборов нефти. Эффективность системы поддержания пластового давления (ППД) успешно доказана и заключается в увеличении коэффициента извлечения нефти относительно варианта разработки на естественном режиме. Также отметим, что управление системой ППД на четвертой стадии разработки является эффективным и экономически оправданным методом управления базовой добычей месторождения [1]. Классический подход для управления ППД – это постанализ событий, произошедших на месторождении. Мероприятия при таком подходе подбираются итерационно при анализе

потерь добычи нефти. Эффективность управления можно повысить с помощью проактивного подхода: до выдачи рекомендаций проводить этап многовариантного моделирования с определением оптимального режима работы скважин [1]. Методы машинного обучения и нейросетевого моделирования являются перспективным направлением для решения такой задачи [2, 3]. Таким образом, цель работы – проанализировать классические подходы к нейросетевому моделированию и разработать модели, позволяющие воспроизвести процесс влияния системы ППД на добывающие скважины.

Моделирование на базе нейронных сетей

Машинное обучение базируется на процессе самообучения – процедуре адаптации расчетной модели под экспериментальные данные. В работе рассматривается один из методов машинного обучения – нейронные сети. Теоретически нейронные сети позволяют воспроизвести любую сложную монотонную функцию, что придает методу характер универсальности [4, 5]. Математическая постановка задачи обучения нейронной сети описывается так: есть некая произвольная модель нейронной сети, например модель многослойного персептрона, с произвольной функцией активации [4]:

$$y = W_y \cdot f(W_x \cdot x + b_x) + b_y, \quad (1)$$

где x – входной вектор данных, который подается на вход нейросети;

W_x, W_y, b_x, b_y – векторы настроечных коэффициентов (веса модели);

операция « \cdot » – матричное умножение;

f – произвольная функция активации.

Обучить нейронную сеть – это найти минимум некоторой целевой функции $loss$ (функция потерь), которая характеризует степень отклонения расчетных данных от фактических замеров:

$$loss = \sum (y_{\text{факт}} - y_{\text{расчет}})^2 \rightarrow 0, \quad (2)$$

где $y_{\text{факт}}$ – фактические данные из обучающей выборки,

$y_{\text{расчет}}$ – рассчитанные значения нейронной сети.

Нейронные сети в процессе обучения на экспериментальных данных позволяют решать такие задачи, как классификация, восстановление функциональной связи между параметрами, прогнозирование и оптимизация. Данного функционала достаточно для того, чтобы обработать и спрогнозировать динамику технологических показателей работы скважин [6, 7]. Однако есть ряд ограничений возможностей классических нейронных сетей:

а) нейронные сети – интерполяционный инструмент, не позволяющий достоверно прогнозировать за пределами обучающей выборки;

б) при обучении только на экспериментальных данных нейронная сеть может сформировать нефизичные зависимости.

Поэтому в классическом представлении нейронные сети показывают качественные результаты при достоверной и разнообразной обучающей выборке. К примеру, нейронные сети можно эффективно использовать для аппроксимации решений уравнений гидродинамической модели (ГДМ) [8–10], где ГДМ выступает как объект для генерации обучающей выборки. Обученные нейронные сети показывают высокую скорость расчетов

и приемлемую точность относительно объекта обучения. В дальнейшем обученные нейронные сети используются для расчета оптимизационных задач, решение которых с помощью ГДМ невозможно из-за длительного времени расчета.

При обучении нейронных сетей на фактических данных возникают проблемы с адаптацией модели из-за низкого качества обучающей выборки. В нефтегазовой отрасли проблемы обучающей выборки связаны:

а) с наличием «шумных» замеров;

б) с низкой дискретностью замеров для ряда параметров (например, обводненность).

Также следует отметить ограниченность изменения фактических параметров в обучающей выборке: например, при использовании ГДМ можно сгенерировать любые альтернативные сценарии по изменению закачки в произвольном диапазоне. При использовании реальных данных есть только фактический вариант изменения закачки, который может быть ограничен небольшим диапазоном регулирования. Это накладывает значительные ограничения на возможности применения нейронных сетей.

Таким образом, резюмируя все вышесказанное, можно сделать вывод, что прогнозирование на реальных данных – это нетривиальная задача машинного обучения, требующая дополнительных работ как при обработке исходных данных, так и при разработке математических моделей нейронных сетей.

В последнее время нейросетевое моделирование все чаще используется при нахождении приближенного аналитического решения краевых задач для дифференциальных уравнений [4, 11].

Такого рода модели называют физико-информированные нейронные сети (PINN – physics-informed neural network). По сравнению с традиционными методами на основе сеток машинное обучение представляет бессеточный подход к аппроксимации искомого решения.

Данные модели можно использовать совместно с экспериментальными данными и в таком случае дифференциальные уравнения, описывающие некоторое физическое явление (3), выступают в роли регуляризации итогового решения [4].

Функция F может быть представлена в виде многомерной векторной функции.

$$F \left(x_1, x_2, \dots, x_m, z, \frac{\partial z}{\partial x_1}, \frac{\partial z}{\partial x_2}, \dots, \frac{\partial z}{\partial x_m}, \frac{\partial^2 z}{\partial x_1^2}, \frac{\partial^2 z}{\partial x_1 \partial x_2}, \frac{\partial^2 z}{\partial x_2^2}, \dots, \frac{\partial^n z}{\partial x_m^n} \right) = 0, \tag{3}$$

Иными словами, добавленная физико-математическая модель ограничивает область поиска итогового решения при обучении нейронной сети. В таком случае целевая функция обучения может быть записана в виде:

$$\text{loss} = \sum (y_{\text{факт}} - y_{\text{расчет}})^2 + \|F\|_2 \rightarrow 0 \tag{4}$$

где $\|F\|_2$ – L₂ норма выражения (3).

Данный подход, на взгляд авторов, является достаточно перспективным для решения задач нейросетевого моделирования при ограниченном наборе обучающих примеров и является приоритетным в реализованном решении для разработки алгоритмов моделирования процессов заводнения.

Разработка моделей PINN для решения задач моделирования отклика в системе ППД

Рассмотрим классический пример элемента заводнения: в центре – добывающая скважина, окруженная несколькими нагнетательными скважинами (рис. 1).

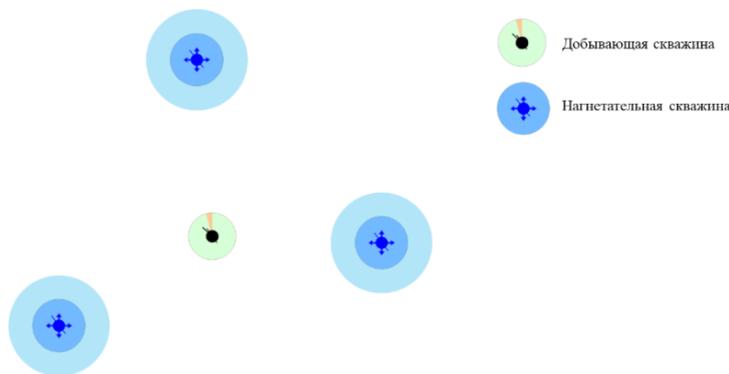


Рис. 1. Схема элемента заводнения
Fig. 1. Schematic diagram of a flooding element

В процессе разработки режимы на нагнетательных скважинах изменяются, что приводит к отклику в добыче нефти на добывающей скважине. Влияние нагнетательной скважины можно разделить на две составляющие: влияние на динамику отборов жидкости и влияние на динамику обводненности добываемой продукции. Оба фактора напрямую влияют на итоговый объем добываемой нефти. Для моделирования также предлагается разделить влияние и использовать две нейросетевые модели для расчета.

*Моделирование отклика
по дебиту жидкости*

Для упрощенного описания притока жидкости к добывающей скважине можно успешно использовать модель однофазного потока. На практике известны способы упрощенного описания изменения дебита жидкости от изменения закачки, которые основаны только на моделировании однофазного процесса (модель CRM) [12, 13].

В данной работе для описания однофазного потока используется дифференциальное уравнение движения упругой жидкости в упругой пористой среде – уравнение пьезопроводности:

$$\frac{\partial P}{\partial t} = a \left(\frac{\partial^2 P}{\partial x^2} + \frac{\partial^2 P}{\partial y^2} + \frac{\partial^2 P}{\partial z^2} \right), \quad (4)$$

где P – давление;

x, y, z – пространственные координаты;

a – коэффициент пьезопроводности.

Решение уравнения (4), а именно функция $P(x, y, z, t)$, позволяет определить

давление в разных точках пласта. Зная давление, фильтрационные свойства пласта и площадь притока можно пересчитать суммарный приток жидкости к скважине через выражение (5):

$$Q = - \frac{k \cdot S}{\mu} \cdot \nabla P, \quad (5)$$

где P – давление;

k – коэффициент проницаемости;

μ – вязкость флюида;

S – площадь притока;

Q – дебит жидкости добывающей скважины,

∇ – операция градиент.

Воспользуемся моделью PINN для моделирования описанной задачи: в качестве базовой используется модель многослойного персептрона с одним скрытым слоем и тангенциальной функцией активации (1). Нейронная сеть в такой постановке должна рассчитывать давление в различных точках пласта при заданных забойных давлениях в скважинах. Итоговое решение нейронной сети должно максимально удовлетворять уравнению (4), но при этом при подстановке рассчитанных значений в уравнение (5) рассчитанный дебит жидкости должен максимально удовлетворять фактическим значениям.

Для упрощения и ускорения обучения модели задача сводится к решению системы одномерных уравнений, где давление рассчитывается вдоль линии между нагнетательной и добывающей скважинами, а суммарный дебит жидкости будет равен сумме притоков жидкости с каждого направления (рис. 2).

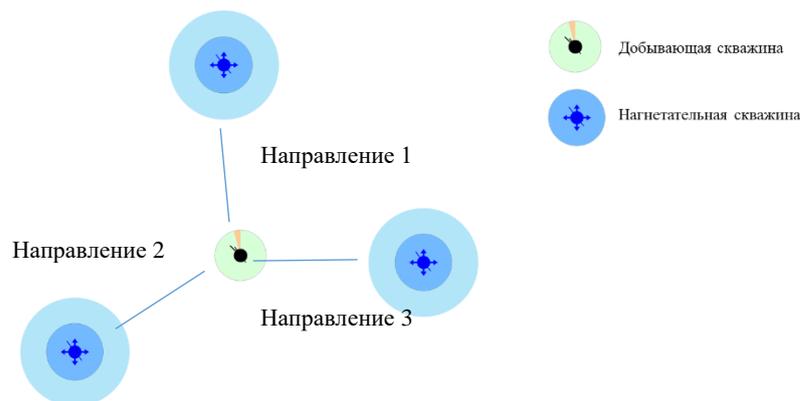


Рис. 2. Схема подбора параметров для расчета модели (пояснения в тексте)

Fig. 2. Schematic diagram of selecting the parameters for model calculation (further explanations in the text)

Тогда уравнения (4) и (5) можно записать в виде системы одномерных уравнений для каждого направления:

$$\begin{cases} \frac{\partial P_1}{\partial t} - a_1 \frac{\partial^2 P_1}{\partial x_1^2} = 0, \text{ для направления 1} \\ \frac{\partial P_2}{\partial t} - a_2 \frac{\partial^2 P_2}{\partial x_2^2} = 0, \text{ для направления 2} \\ \frac{\partial P_3}{\partial t} - a_3 \frac{\partial^2 P_3}{\partial x_3^2} = 0, \text{ для направления 3} \\ Q = \sum_{i=1}^3 J_i \frac{dP_i}{dx_i} \end{cases}, \quad (6)$$

где интегральный параметр $J = -\frac{k}{\mu} S$;

k, S, μ – фильтрационные параметры пласта.

Параметры пласта – коэффициенты пьезопроводности и коэффициенты J – подбираются в ходе обучения для достижения максимальной сходимости с фактическим дебитом жидкости для каждого направления течения.

Целевая функция обучения нейронной сети записывается так:

$$\text{Loss} = \sum_{i=1}^N \left\| \frac{\partial P_i}{\partial t} - a_i \frac{\partial^2 P_i}{\partial x_i^2} \right\|_2 + \sum_{t=1}^T (Q_{t \text{ факт}} - Q_{t \text{ расчет}})^2 + \sum_{t=1}^T (P_{t \text{ заб.факт.}} - P_{t \text{ заб.расчет}})^2 \rightarrow 0 \quad (7)$$

где N – общее количество нагнетательных скважин;

T – количество точек для обучения.

Производные $\frac{\partial P_i}{\partial t}$ и $\frac{\partial^2 P_i}{\partial x_i^2}$ рассчитываются аналитически для модели многослойного персептрона с одним скрытым слоем (1) по формулам (8) и (9):

$$\frac{\partial P}{\partial t} = W_y \cdot f'(W_x \cdot (x, t) + b_x) \cdot W_x(2), \quad (8)$$

$$\frac{\partial^2 P}{\partial x^2} = W_y \cdot f''(W_x \cdot (x, t) + b_x) \cdot W_x^2(1), \quad (9)$$

где (1) и (2) – индексы строк матрицы W_x

Тогда L_2 норму в выражении (7) для i -й нагнетательной скважины можно записать как:

$$\left\| \frac{\partial P}{\partial t} - a \frac{\partial^2 P}{\partial x^2} \right\|_2 = \sqrt{\sum_{j=1}^X \sum_{i=1}^T (W_y \cdot f'(W_x \cdot (x_j, t_i) + b_x) \cdot W_x(2) - a \cdot W_y \cdot f''(W_x \cdot (x_j, t_i) + b_x) \cdot W_x^2(1))^2}, \quad (10)$$

где T – количество точек для обучения;

X – расстояние до добывающей скважины.

Протестируем модель для моделирования элемента заводнения, представленного на рис. 2. В качестве экспериментальных данных для обучения используются данные, рассчитанные с использованием ГДМ за последние 180 дней. Последние 30 точек расчета отводятся для тестирования прогностической способности нейронной сети. Модель

быстро обучается – основное падение ошибки при обучении происходит за первые 50 эпох обучения, а основная доля ошибки образуется за счет отклонения жидкости.

В результате обучения модели средняя абсолютная ошибка адаптации (MAPE, %) модели составляет 1,4%, что говорит о высокой точности настройки модели (рис. 3).



Рис. 3. Результаты оценки качества настройки модели

Fig. 3. Results of quality assessment of history matching

В процесс обучения нейронная сеть восстанавливает давление в разрезе каждой пары нагнетательной и добывающей скважин. Отклонение восстановленной динамики давления от динамики в ГДМ составляет 3,8% или порядка 6 атм.

Для тестирования прогностической способности нейросетевой модели рассчитаны два прогнозных варианта:

- а) закачка равна минимальному значению за историю;
- б) отключение закачки.

Отметим, что в обучающей выборке не было события с отключением нагнетательных скважин, минимальный дебит жидкости в период обучения составляет 370 м³/сут, а среднее время удержания стабильных уровней закачки – порядка двух месяцев.

Отклонение прогнозов PINN от рассчитанных с использованием гидродинамической модели составляет 4,8% на период один год, что можно считать хорошим показателем.

Для сравнения проведено обучение классической рекуррентной нейронной сети LSTM без использования физической модели фильтрации (рис. 4). В примере «а» средняя ошибка прогнозирования составляет 13%

на весь период прогнозирования и 5% на период три месяца. В эксперименте «б» средняя ошибка LSTM составляет 41% на весь период прогнозирования и 32% на период три месяца.

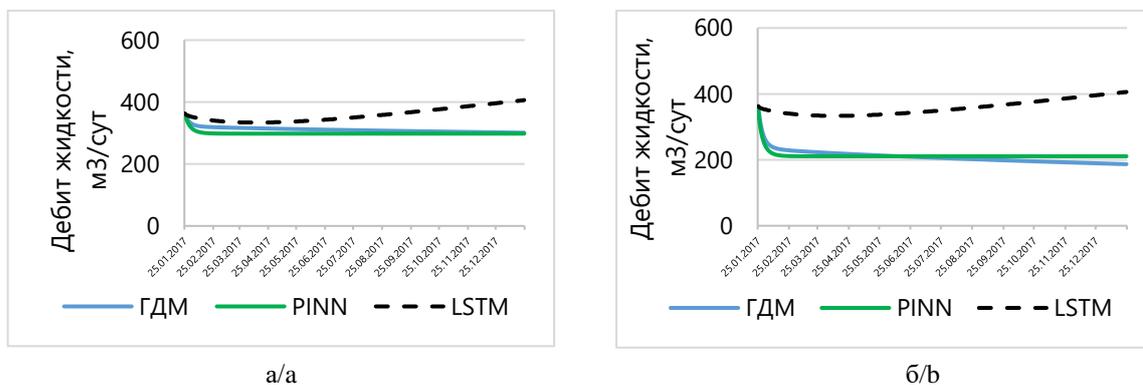


Рис. 4. Сопоставление результатов нейросетевых прогнозов:

а – минимальные режимы закачки по обучающей выборке; б – отключение закачки

Fig. 4. Comparison of neural network forecasting results:

а – minimum injection modes by training set; б – disabling of injection

Результаты эксперимента подтверждают ограничения классических нейронных сетей: при прогнозировании в пределах значений обучающей выборки можно получить достаточно точный краткосрочный прогноз с ошибкой 5%. Но при прогнозировании за пределами обучающей выборки значение ошибки у модели LSTMкратно увеличивается, даже при расчетах

на краткосрочный период. В свою очередь нейронная сеть PINN обеспечивает достаточно точные результаты прогноза.

Модель также протестирована на реальном наборе данных. Для тестирования выбрано небольшое нефтяное месторождение. Кроссплот сопоставления средних тестовых дебитов жидкости на этапе обучения представлен на рис. 5.

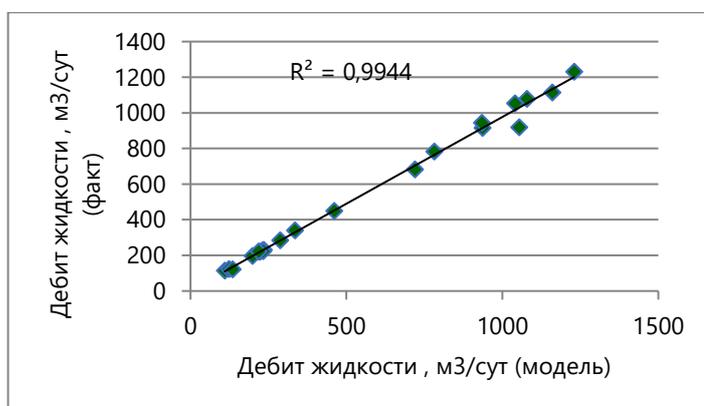


Рис. 5. Результат проверки точности настройки модели на реальные данные

Fig. 5. Result of testing the accuracy of history matching

Для тестирования прогностической способности модели PINN был рассчитан прогнозный вариант с подстановкой фактических режимов работы нагнетательных скважин.

Длительность прогноза составляет 365 дней. Точность прогнозирования в среднем по динамике – 4,3%. Примеры прогнозов по скважинам представлены на рис. 6.



а/а



б/б

Рис. 6. Результаты тестирования точности ретропрогноза
а – для первой скважины; б – для второй скважины

Fig. 6. Results of testing the accuracy of retrospective forecast
а – for the first well; б – for the second well

Скачкообразные изменения дебита жидкости до нуля связаны с фактическим отключением добывающих скважин. В период фактического отключения скважин прогноз по нейросети был принудительно «обнулен» и этот период времени не участвовал в расчете средней ошибки прогнозирования. Остальная немонотонность динамики объясняется фактическим изменением режимов работы добывающей скважины и ее окружения.

По результатам расчетов можно сделать вывод, что разработанная модель PINN на основе уравнения пьезопроводности успешно позволяет моделировать отклик системы ППД на добычу жидкости.

Моделирование отклика по обводненности

Аналогичным способом создадим модель PINN для моделирования обводненности продукции. Для описания двухфазного потока в системе нефть–вода используется

теория Баклея–Левретта. Теория описывает изменение водонасыщенности по пласту в зависимости от времени и кривых фазовых проницаемостей. Распределение водонасыщенности описывается гиперболическим дифференциальным уравнением:

$$m \frac{\partial s}{\partial t} + V(t) \cdot f'(s) \frac{\partial s}{\partial x} = 0, \quad (11)$$

где m – пористость;

s – водонасыщенность;

$V(t)$ – суммарная скорость фильтрации фаз;

$f(s)$ – функция Баклея.

Как и в случае с моделированием жидкости, для упрощения и ускорения расчетов задача сводится к решению системы одномерных уравнений, где водонасыщенность рассчитывается вдоль линии между нагнетательной и добывающей скважинами, а суммарный приток воды будет равен сумме притоков воды с каждого направления.

Нейронная сеть при такой подстановке воспроизводит водонасыщенность в различных направлениях пласта. При обучении нейронной сети также нужно подобрать параметры пласта – кривые фазовых проницаемостей. Кривые фазовых проницаемостей аппроксимируются на основе корреляции Кори.

Модель протестирована на синтетических данных ГДМ: обучение производилось на 180 точках динамики.

Отметим, что обучение сети по модели производится в разы медленнее, чем по жидкости: ошибка продолжительно и монотонно снижается в течение всего периода обучения. Основной вклад в ошибку вносит дифференциальное уравнение (6).

Результаты обучения нейросетевой модели и сопоставление результатов прогноза для разных моделей представлены на рис. 7. Средняя ошибка обучения составляет 1%.

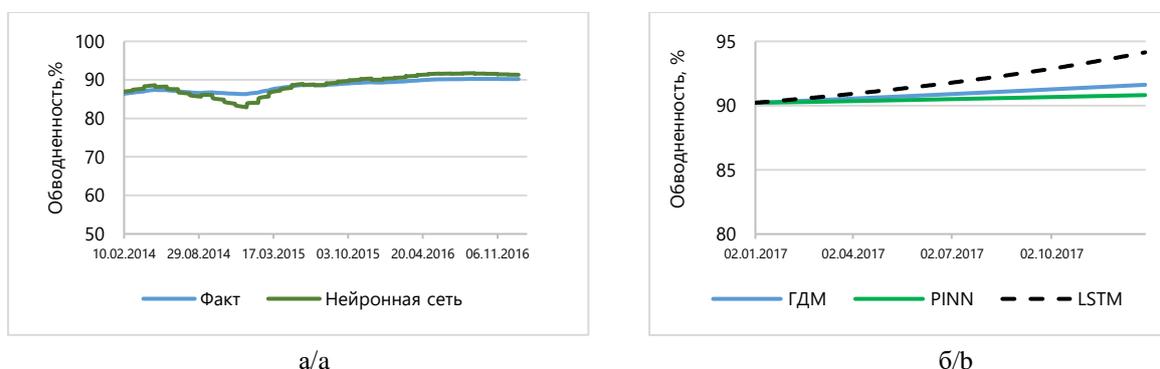


Рис. 7. Результаты обучения и прогноза:
а – результат обучения PINN; б – прогноз обводненности на один год

Fig. 7. Training and forecast results:
a – PINN training result; b – one-year water cut forecast

Для проверки прогностической способности модели заданы произвольные уровни закачки в нейросетевую модель и в ГДМ, точность прогнозов на период 365 дней равна 0,4%, что при пересчете на дебит нефти составляет 4% (см. рис 6б).

Для сравнения был рассчитан аналогичный вариант на модели LSTM. Точность прогноза на весь период прогнозирования составляет 2%, а на период три месяца – 0.3%. При пересчете на дебит нефти ошибки равны 15% и 3% соответственно. При этом скорость обучения модели LSTM в три раза выше, чем у разработанной модели PINN.

Модель PINN находится на стадии доработки: в данный момент PINN с теорией

Баклея–Левретта уступает классической модели LSTM по времени обучения, а на «коротком горизонте» прогнозирования точность расчета модели LSTM не уступает более сложной модели PINN, поэтому пока для решения промысловых задач по оптимизации закачки используется модель LSTM для прогнозирования обводненности в комбинации с моделью PINN по жидкости.

Заключение

Управление заводнением – важный процесс мониторинга разработки, требующий оперативного реагирования и наличия инструментов, способных обрабатывать большие объемы информации.

Проанализированы и выявлены ограничения классических методов нейросетевого моделирования при использовании реальных промысловых данных.

Разработаны подходы для моделирования откликов в системе ППД на основе физико-информированных нейронных сетей. Для обучения модели используется упрощенное физическое описание процесса, которое не полностью описывает поведение системы. Несмотря на это, по результатам тестов модели показали хорошую сходимость при прогнозировании технологических показателей работы скважин при различных уровнях закачки.

Предлагаемые модификации и подходы для нейросетевого моделирования достаточно точно моделируют процессы заводнения с использованием реальных промысловых данных: средняя ошибка прогнозирования дебита нефти менее 10% на период три месяца. Краткосрочность прогнозирования напрямую связана с применением модели LSTM для моделирования обводненности. В данный момент проводится доработка модели PINN для решения аналогичной задачи – моделирования обводненности продукции, что позволит нивелировать ограничения классических нейронных сетей.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Список источников

1. Потрясов А.А., Бриллиант Л.С., Печеркин М.Ф., Комягин А.И. Автоматизация процессов управления заводнения на нефтяном месторождении // Недропользование XXI век. 2016. № 6(63). С. 112–121.
2. Бриллиант Л.С., Комягин А.И., Бляшук М.М. и др. Пат. RU 2614338 С1 Способ оперативного управления заводнением пластов № 2015156293; Заявл. 25.12.2015; Опубл. 24.03.2017 // Изобретения. Полезные модели. 2017. Бюл. № 9. 20 с.
3. Artun E. Characterizing reservoir connectivity and forecasting waterflood performance using data-driven and reduced-physics models // SPE Western Regional Meeting, Anchorage, Alaska, USA, 23–26 May 2016. Paper SPE-180488-MS. <https://doi.org/10.2118/180488-MS>
4. Васильев А.Н., Тархов Д.А., Шемякина Т.А. Нейросетевой подход к задачам математической физики. СПб.: Нестор-История, 2015. 260 с.
5. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного // Доклады АН СССР. 1957. Т. 114, № 5. С. 953–956.
6. Иваненко Б.П. Нейросетевое имитационное моделирование нефтяных месторождений и гидрогеологических объектов. Томск: Издательский Дом Томского государственного университета, 2014. 188 с.
7. Стрекалов А.В., Хусаинов А.Т. Математическое моделирование процессов нефтедобычи на основе нейронных сетей. Тюмень: Тюменский государственный нефтегазовый университет, 2013. 163 с.
8. Бриллиант Л.С., Завьялов А.С., Данько М.Ю. и др. Методика тестирования алгоритмов прокси-моделирования // Недропользование XXI век. 2020. № 4(87). С. 128–137.

9. *Ponomarev R.Yu., Vershinin V.E.* Long-term forecasting and optimization of non-stationary well operation modes through neural networks simulation // SPE Russian Petroleum Technology Conference, Virtual, 12–15 October 2021. Paper SPE-206529-MS. <https://doi.org/10.2118/206529-MS>
10. *Vershinin V.E., Ponomarev R.Yu., Strekalov A.V.* Neural network as a tool for predicting and controlling the technological regime of production wells // SPE Russian Petroleum Technology Conference, Virtual, 26–29 October 2020. Paper SPE-201937-MS <https://doi.org/10.2118/201937-MS>
11. *Васильев А.Н., Тархов Д.А., Шемякина Т.А.* Приближенные аналитические решения обыкновенных дифференциальных уравнений // Современные информационные технологии и ИТ-образование. 2016. Т. 12, № 3-2. С.188–195.
12. *Ручкин А.А., Степанов С.В., Князев А.В.* и др. Исследование особенностей оценки взаимовлияния скважин на примере модели CRM // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2018. Т. 4, № 4. С. 148–168. <https://doi.org/10.21684/2411-7978-2018-4-4-148-168>
13. *Степанов С.В., Соколов С.В., Ручкин А.А.* и др. Проблематика оценки взаимовлияния добывающих и нагнетательных скважин на основе математического моделирования // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2018. Т. 4, № 3. С. 146–164. <https://doi.org/10.21684/2411-7978-2018-4-3-146-164>

Информация об авторах

Роман Юрьевич Пономарев – менеджер, ООО «Тюменский нефтяной научный центр», Тюмень, Россия; SPIN-код: 8626-3037, <https://orcid.org/0000-0001-7241-573X>; e-mail: ruromarev@tncn.rosneft.ru

Рамиль Ришатович Зиязев – заместитель начальника управления, ООО «Тюменский нефтяной научный центр», Тюмень, Россия; SPIN-код: 8780-5249, <https://orcid.org/0009-0000-0289-5977>; e-mail: rrziyazev@tncn.rosneft.ru

Антон Александрович Лещенко – главный специалист, ООО «Тюменский нефтяной научный центр», Тюмень, Россия; <https://orcid.org/0009-0009-5780-6770>; e-mail: AA_Leshchenko2@tncn.rosneft.ru

Руслан Рамилевич Мигманов – главный специалист, ООО «Тюменский нефтяной научный центр», Тюмень, Россия; SPIN-код: 3268-4097, <https://orcid.org/0000-0003-4842-0592>; e-mail: rrmigmanov@tncn.rosneft.ru

Михаил Игоревич Ивлев – главный специалист, ООО «Тюменский нефтяной научный центр», Тюмень, Россия; SPIN-код: 2993-8883, <https://orcid.org/0009-0006-3533-3587>; e-mail: miiivlev@tncn.rosneft.ru.

Поступила в редакцию 14.10.2024

HYDROTHERMODYNAMIC AND GEOMECHANICAL MODELLING OF THE PROCESSES IN SATURATED GEOLOGICAL MEDIA

Original article

<https://doi.org/10.29222/ipng.2078-5712.2024-15-4.art3>

Flooding system optimization: Advantages of a hybrid approach to developing neural network filtration models

R.Yu. Ponomarev, R.R. Ziazev ✉, A.A. Leshchenko, R.R. Migmanov, M.I. Ivlev

Tyumen Petroleum Research Center LLC, Tyumen, Russia

Abstract. *Background.* Currently, neural networks are increasingly used for processing and forecasting the dynamics of well performance. However, there are a number of limitations in their application for flooding system optimization. *Objective.* To develop models that can correctly reproduce the impact of the reservoir pressure maintenance system on the operation of production wells. The article considers the problem of modeling the reaction of producing wells to the changes in water injection modes in injection wells using neural network modeling *methods.* *Results.* We propose the approaches to the creation and training of physics-informed neural networks for modeling responses in oil production to regime changes in the reservoir pressure maintenance system. The results of testing the training and predictive abilities of PINN (physics-informed neural network) models are presented, and a comparison is made with the results of forecasting on the classical LSTM neural network. *Conclusions.* With hybrid training of models based on actual data, PINN models make it possible to offset the limitations of classical neural networks.

Keywords: neural network modeling, field development, physics-informed neural network, optimization of injection well operation modes

Funding: the work received no funding.

For citation: Ponomarev R.Yu., Ziazev R.R., Leshchenko A.A., Migmanov R.R., Ivlev M.I. Flooding system optimization: Advantages of a hybrid approach to developing neural network filtration models. *Actual Problems of Oil and Gas*. 2024. Vol. 15, No. 4. P. 349–363. (In Russ.). <https://doi.org/10.29222/ipng.2078-5712.2024-15-4.art3>

✉ Ramil R. Ziazev, e-mail: rrziazev@tnnc.rosneft.ru

© Ponomarev R.Yu., Ziazev R.R., Lechenko A.A., Migmanov R.R., Ivlev M.I., 2024



The content is available under Creative Commons Attribution 4.0 License.

Conflict of interests

The authors declare no conflict of interests.

References

1. Potryasov A.A., Brilliant L.S., Pecherkin M.F., Komyagin A.I. Automating oil-field waterflood operations. *Subsoil Use XXI Century*. 2016. No. 6(63). P. 112–121. (In Russ.).
2. Brilliant L.S., Komyagin A.I., Blyashuk M.M. et al. Pat. RU 2614338 C1. Method of real-time control of reservoir flooding. No. 2015156293; App. 25.12.2015; Publ. 24.03.2017. *Inventions. Utility Models*. 2017. Bull. No. 9. 20 p. (In Russ.).
3. Artun E. Characterizing reservoir connectivity and forecasting waterflood performance using data-driven and reduced-physics models. In: *SPE Western Regional Meeting, Anchorage, Alaska, USA*, 23–26 May 2016. Paper SPE-180488-MS. <https://doi.org/10.2118/180488-MS>
4. Vasiliev A.N., Tarkhov D.A., Shemyakina T.A. *Neural Network Approach to Problems of Mathematical Physics*. St. Petersburg: Nestor-Istoriya, 2015. 260 p. (In Russ.).
5. Kolmogorov A.N. On the representation of continuous functions of many variables by superposition of continuous functions of one variable and addition. *Doklady AN SSSR*. 1957. Vol. 114, No. 5. P. 953–956. (In Russ.).
6. Ivanenko B.P. *Neural Network Simulation of Oil Fields and Hydrogeological Objects*. Tomsk: Publishing House of Tomsk State University, 2014. 188 p. (In Russ.).
7. Strekalov A.V., Khusainov A.T. *Mathematical Modeling of Oil Production Processes Based on Neural Networks*. Tyumen: Tyumen State Oil and Gas University, 2013. 163 p. (In Russ.).
8. Brilliant L.S., Zavyalov A.S., Danko M.Yu. et al. Procedure of proxy modelling algorithms testing. *Subsoil Use XXI Century*. 2020. No. 4(87). P. 128–137. (In Russ.).
9. Ponomarev R.Yu., Vershinin V.E. Long-term forecasting and optimization of non-stationary well operation modes through neural networks simulation. In: *SPE Russian Petroleum Technology Conference, Virtual*, 12–15 October 2021. Paper SPE-206529-MS. <https://doi.org/10.2118/206529-MS>
10. Vershinin V.E., Ponomarev R.Yu., Strekalov A.V. Neural network as a tool for predicting and controlling the technological regime of production wells. In: *SPE Russian Petroleum Technology Conference, Virtual*, 26–29 October 2020. Paper SPE-201937-MS <https://doi.org/10.2118/201937-MS>
11. Vasilyev A.N., Tarkhov D.A., Shemyakina T.A. Approximate analytical solutions of ordinary differential equations. *Modern Information Technologies and IT Education*. 2016. Vol. 12, No. 2-3. P. 188–195. (In Russ.).
12. Ruchkin A.A., Stepanov S.V., Knyazev A.V. et al. Applying CRM model to study well interference. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*. 2018. Vol. 4, No. 4. P. 148–168. (In Russ.). <https://doi.org/10.21684/2411-7978-2018-4-4-148-168>
13. Stepanov S.V., Sokolov S.V., Ruchkin A.A. et al. Considerations on mathematical modeling of producer-injector interference. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*. 2018. Vol. 4, No. 3. P. 146–164. (In Russ.). <https://doi.org/10.21684/2411-7978-2018-4-3-146-164>

Information about the authors

Roman Yu. Ponomarev – Manager, Tyumen Petroleum Research Center LLC, Tyumen, Russia; <https://orcid.org/0000-0001-7241-573X>; e-mail: ryonomarev@tnnc.rosneft.ru

Ramil R. Ziayev – Deputy Head of Department, Tyumen Petroleum Research Center LLC, Tyumen, Russia; <https://orcid.org/0009-0000-0289-5977>; e-mail: rrziayev@tnnc.rosneft.ru

Anton A. Leshchenko – Chief Specialist, Tyumen Petroleum Research Center LLC, Tyumen, Russia; <https://orcid.org/0009-0009-5780-6770>; e-mail: AA_Leshchenko2@tnnc.rosneft.ru

Ruslan R. Migmanov – Chief Specialist, Tyumen Petroleum Research Center LLC, Tyumen, Russia; <https://orcid.org/0000-0003-4842-0592>; e-mail: rmigmanov@tnnc.rosneft.ru

Mikhail I. Ivlev – Chief Specialist, Tyumen Petroleum Research Center LLC, Tyumen, Russia; <https://orcid.org/0009-0006-3533-3587>; e-mail: miivlev@tnnc.rosneft.ru

Received 14.10.2024