

Моделирование добычи жидкости и динамики обводненности при совместном использовании фильтрационной модели и нейронных сетей

Дмитрий Юрьевич Легостаев[✉], Виталий Петрович Косяков

Тюменский филиал Института теоретической и прикладной механики
им. С. А. Христиановича СО РАН, Тюмень, Россия
Контакт для переписки: legostaevdy@yandex.ru[✉]

Аннотация. В нефтяной отрасли заметна тенденция к использованию прокси-моделей разного уровня сложности для выполнения оперативных прогнозных расчетов, в частности методов машинного обучения, которые активно развиваются в контексте цифровизации и интеллектуализации производственных процессов. В настоящей работе на примере синтетической модели элемента разработки нефтяного пласта представлен подход к совместному использованию физически содержательной модели фильтрации и методов машинного обучения для решения задач адаптации и прогнозирования. Особенностью рассматриваемой синтетической модели является наличие выраженной зональной неоднородности поля проницаемости. В рамках предлагаемого подхода использована упрощенная, по сравнению с исходной постановкой, однофазная модель фильтрации, адаптация которой на историю проведена путем восстановления поля фильтрационных параметров пласта с помощью сети радиально-базисных функций. На основе восстановленного поля рассчитаны коэффициенты связи между скважинами, которые качественно и количественно соответствуют истинным связям. Следующим шагом выполнено обучение рекуррентной нейронной сети с целью прогнозирования обводненности добываемой жидкости. Использование рекуррентной нейронной сети позволило воспроизвести характерное немонотонное поведение обводненности добываемой жидкости, вызванное нестационарными режимами работы нагнетательных и добывающих скважин. Связка представленных моделей позволяет прогнозировать объем добываемой жидкости и ее фазовый состав. Для оценки прогностических свойств моделей набор фактических данных был разбит на обучающий и тестовый интервалы.

Ключевые слова: фильтрация, математическое моделирование пластовых систем, обратная задача, сопряженная задача, машинное обучение, радиальные базисные функции, рекуррентные нейронные сети

Благодарности: исследование выполнено при финансовой поддержке РФФИ и Тюменской области в рамках научного проекта № 20-41-720004.

Цитирование: Легостаев Д. Ю., Косяков В. П. 2023. Моделирование добычи жидкости и динамики обводненности при совместном использовании фильтрационной модели и нейронных сетей // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. Том 9. № 2 (34). С. 75–92. <https://doi.org/10.21684/2411-7978-2023-9-2-75-92>

Поступила 28.04.2023; одобрена 23.06.2023; принята 30.06.2023

Simulation of liquid production and water cut dynamics using fluid flow model and neural networks

Dmitry Yu. Legostaev[✉], Vitaly P. Kosyakov

Tyumen Branch of the Khristianovich Institute of Theoretical and Applied Mechanics of the Siberian Branch of the Russian Academy of Sciences, Tyumen, Russia
Corresponding author: legostaevdy@yandex.ru[✉]

Abstract. In the oil industry, there is a noticeable tendency to use proxy modeling of various levels of complexity to perform operational predictive calculations, in particular machine learning methods that are actively developing in the context of digitalization and intellectualization of production processes. In this paper, using the example of a synthetic oil reservoir model development element, we present an approach to the joint use of a physically meaningful fluid flow model and machine learning methods for solving adaptation and prediction problems. A feature of the considered synthetic model is the presence of a pronounced zonal inhomogeneity of the permeability field. Within the framework of the proposed approach, a single-phase filtration model, simplified in comparison with the original formulation was used, the history matching of which was carried out by restoring the field of reservoir filtration parameters using a network of radial basis functions. Based on the reconstructed field, the connection coefficients between the wells were calculated, which qualitatively and quantitatively correspond to the true well connections. The next step was to train a recurrent neural network in order to predict the water cut of the produced fluid. The use of a recurrent neural network made it possible to reproduce the characteristic non-monotonic behavior of the water cut of the produced fluid, caused by

non-stationary modes of operation of injection and production wells. A combination of the presented models makes it possible to predict the volume of the produced fluid and its phase composition. To assess the predictive properties of the models, the actual data set was divided into training and test intervals.

Keywords: flow through porous medium, reservoir mathematical simulation, inverse problem, adjoint problem, machine learning, radial basis functions, recurrent neural networks

Acknowledgements: The research was funded by RFBR and the Tyumen Region within the framework of the scientific project No. 20-41-720004.

Citation: Legostaev, D. Yu., & Kosyakov, V. P. (2023). Simulation of liquid production and water cut dynamics using fluid flow model and neural networks. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*, 9(2), 75–92. <https://doi.org/10.21684/2411-7978-2023-9-2-75-92>

Received April 28, 2023; Reviewed June 23, 2023; Accepted June 30, 2023

Введение

В настоящее время в нефтедобывающей отрасли широкое применение, наряду с традиционными гидродинамическими моделями, получили упрощенные прокси-модели. Их использование позволяет сократить вычислительные затраты, а также снизить требования к качеству и полноте исходных данных. Самыми ресурсоемкими задачами, как правило, являются обратные и оптимизационные задачи, поэтому развитие и применение прокси-моделирования для подобного рода задач является актуальным. Помимо физически содержательных моделей (материальный баланс [Musakaev и др., 2021], суперэлементы [Мазо, Поташев, 2020], CRM [Бекман и др., 2020], линии тока [Поташев и др., 2022] и т. д.), развиваются подходы, основанные на применении методов машинного обучения [Temirchev и др., 2020; Умановский, 2022; Illarionov и др., 2022]. Например, рекуррентные нейронные сети получили применение в области прогнозирования временных рядов и, в частности, режимов работы скважин [Гора и др., 2018; Alakeely, Horne, 2020; Bai, Tahmasebi, 2021]. С учетом растущей цифровизации промысла [Власов, Можиль, 2018] такие подходы являются весьма перспективными. Однако применение подходов, основанных только на методах машинного обучения, в качестве прогнозирующих моделей не может гарантировать получения верного с точки зрения физики процесса результата. Совместное использование физически содержательной модели и методов машинного обучения позволяет избегать проблем подобного рода [Косяков и др., 2021; Косяков, Легостаев, 2022].

Целью настоящей работы является развитие инструментов прокси-моделирования на основе теории фильтрации и элементов машинного обучения. Целевым показателем при разработке месторождений является добыча нефти, которая зависит от двух составляющих: дебита жидкости и доли нефти в добываемой продукции. В рамках настоящего подхода для предсказания дебита жидкости предлагается использовать модель однофазной фильтрации, а для предсказания долей воды и нефти в добываемой продукции —

рекуррентные нейронные сети (РНС). Настройка модели для прогнозирования дебита жидкости включает в себя решение задачи восстановления фильтрационных параметров пластовой системы в межскважинном пространстве при помощи сети радиально-базисных функций (РБФ). Задача решалась путем адаптации фильтрационной модели на известные значения пластового давления при заданных расходах жидкости на скважинах. Целью рекуррентной нейронной сети является установление ключевых зависимостей между режимами работы скважин и обводненностью добываемой продукции. Обучение РНС происходило на фактические значения обводненности добываемой жидкости. Для контроля прогностических свойств моделей проведено разбиение моделируемого периода разработки на обучающий и тестовый интервалы.

Методы

Синтетическая модель элемента разработки

Апробация предлагаемых подходов проведена на примере синтетической модели элемента разработки нефтяного пласта. Синтетическая гидродинамическая модель выступала в качестве источника исходных данных, которые были использованы для решения задач адаптации и прогнозирования. Набор данных получен путем прямого численного моделирования двухфазной фильтрации воды и нефти. Вода и нефть рассматриваются как слабосжимаемые несмешивающиеся жидкости, капиллярными и гравитационными силами пренебрегаем. Уравнения фильтрации в этом случае могут быть записаны в виде [Каневская, 2002; Азиз, Сеттари, 2004]:

$$S_w (C_w \varphi + C_r) \frac{\partial P}{\partial t} + \varphi \frac{\partial S_w}{\partial t} = \nabla \cdot \left[\frac{kk_{rw}}{\mu_w} \nabla P \right] + q_w,$$

$$S_o (C_o \varphi + C_r) \frac{\partial P}{\partial t} + \varphi \frac{\partial S_o}{\partial t} = \nabla \cdot \left[\frac{kk_{ro}}{\mu_o} \nabla P \right] + q_o,$$

$$S_w + S_o = 1,$$

где нижние индексы w и o относятся к воде и нефти соответственно; S_p — насыщенность фазой p ; C_p — коэффициент сжимаемости фазы; φ — пористость; C_r — коэффициент сжимаемости порового объема; P — поровое давление; k — абсолютная проницаемость; k_{rp} — относительная фазовая проницаемость; μ_p — вязкость фазы; q_p — источник/сток.

Синтетическая модель представляет собой элемент разработки месторождения размером $1\,000 \times 1\,000$ м, включающий в себя пять скважин: три добывающие (№ 1–3) и две нагнетательные (№ 4, 5). На рис. 1 приведена схема расстановки скважин и заданное зонально-неоднородное поле проницаемости. Проницаемость в основной части расчетной области составляла $0,1$ мкм². При этом в пласте присутствуют высокопроводящие включения с проницаемостью 1 мкм², которые соединяют пары скважин «добывающая — нагнетательная» (№ 1 — № 5 и № 2 — № 4). Добывающая скважина № 3 изолирована от остальных скважин барьером с проницаемостью $0,05$ мкм².

Период моделирования составлял 10 лет, на протяжении которых скважины работали с заданными режимами. Расчетный шаг составлял 1 месяц. Зависимости приемистости нагнетательных скважин от времени, приведенные на рис. 2, получены путем случайной генерации и имеют кусочно-постоянный вид. Так же с заданной периодичностью происходит отключение нагнетательных скважин. Период простоя составлял от 2 до 4 месяцев. На добывающих скважинах заданы изменяющиеся по гармоническому закону забойные давления, которые приведены на рис. 3. В начальный момент времени пласт полностью насыщен нефтью, начальное пластовое давление составляло 15 МПа. На границах элемента разработки задано условие непротекания.

Принятые для расчета параметры горной породы и насыщающих ее флюидов имели следующие значения: пористость 0,15 (значения абсолютной проницаемости представлены в виде карты на рис. 1), вязкость воды 1 мПа·с, вязкость нефти 5 мПа·с. Относительные фазовые проницаемости нефти и воды выбраны в виде модельных квадратичных функций $k_{rp} = S_p^2$. При рассмотрении двухфазной постановки на поле давления оказывают влияние не только фильтрационные свойства пластовой системы, но и сжимаемость насыщающих горную породу флюидов. Основное внимание в настоящем исследовании сконцентрировано на фильтрационных свойствах пластовой системы, поэтому влияние различной сжимаемости фаз исключено из рассмотрения $C_{w,o} = 1 \cdot 10^{-3}$ 1/МПа. Сжимаемостью порового пространства горной породы C_r пренебрегаем. Толщина пласта принята равной 1 м.

Рассмотрим влияние выбранного поля проницаемости в совокупности с нестационарными режимами работы скважин на процесс вытеснения нефти водой. На рис. 4 приведено поле водонасыщенности для различных моментов времени, полученное в результате прямого численного моделирования. Видно, что в первую очередь продвижение фронта водонасыщенности происходит по высокопроводящим каналам к добывающим скважинам № 1 и 2. Одновременно с этим протекает более медленный процесс равномерного вытеснения нефти из остальной части расчетной области. Для скважины № 3 характерен продолжительный безводный период добычи: фронт вытеснения доходит до нее в последнюю очередь (см. рис. 4г).

На рис. 5 приведена динамика обводнения, которая для скважин № 1 и 2 имеет немонотонный характер. Немонотонное поведение обводненности связано с перераспределением фильтрационных потоков в пласте, которое вызвано нестационарными режимами работы скважин. При этом наиболее сильные падения обводненности добываемой продукции связаны с отключениями нагнетательных скважин.

В результате прямого численного моделирования были получены: дебиты добывающих скважин, динамика обводненности добывающих скважин, динамика пластового давления для всех скважин. Полученный набор данных был использован для решения обратной задачи. При этом для оценки прогностических свойств модели данные были разделены на обучающую и тестовую выборки. Первые 7 лет истории разработки отнесены к обучающей выборке и использованы для адаптации модели. Период 7–10 лет включен в тестовую выборку, для которой проведены прогнозные расчеты. Тестовая и обучающая выборки обозначены на рис. 2, 3 и 5 зеленым и красным фоном соответственно.

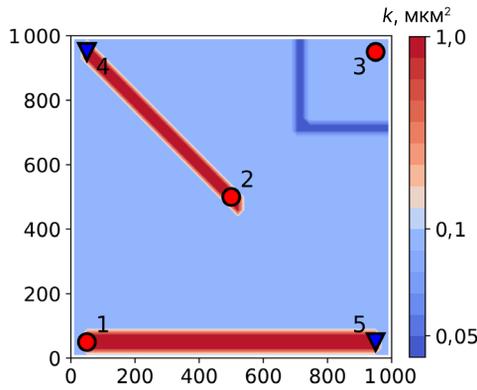


Рис. 1. Поле абсолютной проницаемости и схема расстановки скважин
Fig. 1. Absolute permeability field and well spacing pattern

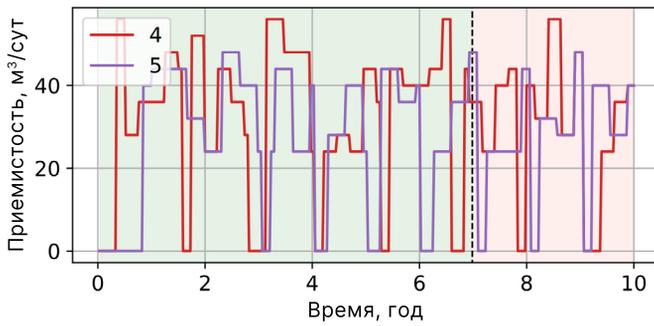


Рис. 2. Динамика приемистости нагнетательных скважин № 4 и 5
Fig. 2. Injectivity dynamics of injection wells No. 4 and 5

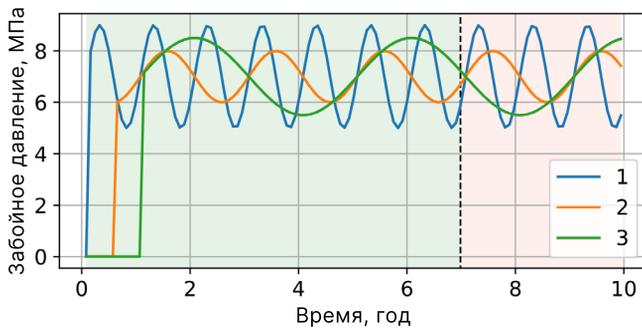


Рис. 3. Динамика забойного давления добывающих скважин № 1–3
Fig. 3. Dynamics of bottomhole pressure of production wells No. 1–3

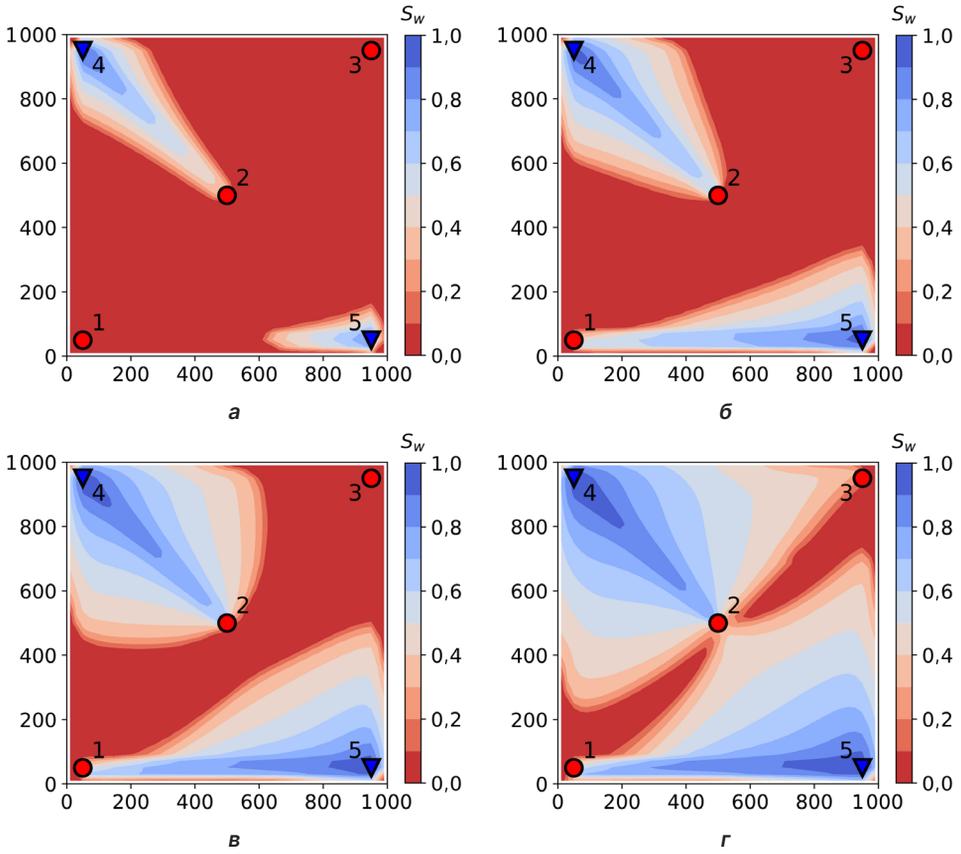


Рис. 4. Поле водонасыщенности для моментов времени: а — 1 год, б — 2 года, в — 4 года, г — 8 лет

Fig. 4. Water saturation field for time points: а — 1 year, б — 2 years, в — 4 years, г — 8 years

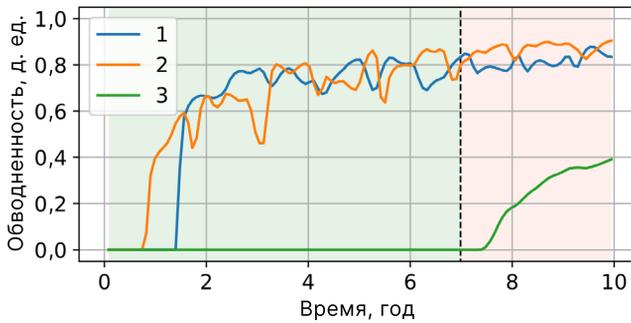


Рис. 5. Зависимость обводненности добываемой скважинами продукции от времени

Fig. 5. The dependence of the water cut produced by wells on time

Результаты

Адаптация однофазной фильтрационной модели

Для расчета объема добычи жидкости использована упрощенная, по сравнению с исходной постановкой, однофазная модель фильтрации. Данная модель связывает информацию об объемах добычи и закачки с информацией об энергетическом состоянии пласта, т. е. с замерами пластового давления.

Фильтрационные свойства пластовой системы в двухфазном случае характеризуются общей подвижностью:

$$\lambda = \frac{kk_{rw}}{\mu_w} + \frac{kk_{ro}}{\mu_o} = k \left(\frac{k_{rw}}{\mu_w} + \frac{k_{ro}}{\mu_o} \right),$$

которая включает в себя как абсолютную проницаемость горной породы k , так и зависящую от фазового состава жидкости в пласте флюидную составляющую k_{rp}/μ_p . Уравнение однофазной фильтрации с учетом общей подвижности может быть записано в виде:

$$\beta \frac{\partial P}{\partial t} = \nabla \cdot [\lambda \nabla P] + q,$$

где $\beta = C_r + \phi(S_w C_w + S_o C_o)$ — коэффициент упругости пласта; q — источник/сток.

Адаптация модели на историю происходит за счет настройки фильтрационных параметров пласта. Предлагаемый подход предполагает использование постоянного во времени поля общей подвижности, которое наилучшим образом позволит описать историю разработки. Однако при вытеснении нефти водой происходит постепенное изменение фазового состава жидкости в пласте, что приводит к изменению общей подвижности. Таким образом, решение обратной задачи сводится к определению некоторого эффективного поля общей подвижности, которое так же впоследствии используется для прогнозных расчетов.

Поле общей подвижности λ рассматривается в виде функциональной зависимости $\lambda(\mathbf{x})$ (где \mathbf{x} — вектор пространственных координат), в качестве которой использована сеть радиально базисных функций:

$$h_i(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\varepsilon_i^2}\right),$$

$$\lambda(\mathbf{x}) = w_i h_i + b,$$

где \mathbf{x} — координаты расчетных узлов; \mathbf{c}_i — положение базиса; ε_i — ширина базиса; w_i — вес базиса; b — свободный член. Параметры сети радиально базисных функций $c_i, \varepsilon_i, w_i, b$ настраиваются в процессе адаптации однофазной фильтрационной модели.

При решении обратной задачи в качестве режимов работы использованы дебиты добывающих скважин и приемистости нагнетательных скважин, полученные из прямого численного моделирования. Пористость, коэффициенты сжимаемости, толщина пласта, начальные и граничные условия соответствовали прямой задаче. Обратная задача решается в оптимизационной постановке, в которой минимизируется целевая функция:

$$J = \frac{w_\lambda}{N_\lambda} \sum_{i=1}^{N_\lambda} \Delta \lambda_i^2 + \frac{w_p}{N_p} \sum_{i=1}^{N_p} w_{p_i} \Delta P_i^2,$$

$$\Delta \lambda = \begin{cases} \lambda_i - \hat{\lambda}_i, & \text{при } \lambda_i \geq \hat{\lambda}_r, \\ 0, & \text{при } \hat{\lambda}_l < \lambda_i < \hat{\lambda}_r, \\ \hat{\lambda}_i - \lambda_i, & \text{при } \lambda_i \leq \hat{\lambda}_l, \end{cases}$$

где λ_i — истинное значение подвижности на скважине; $\hat{\lambda}_i$ — расчетное значение подвижности; $\hat{\lambda}_{l,r}$ — левое и правое ограничение на значение общей подвижности; N_λ — количество значений подвижности; $\Delta P = P_i - \hat{P}_i$; P_i — истинное значение пластового давления; \hat{P}_i — расчетное значение пластового давления; w_{p_i} — весовой коэффициент i -го замера давления; N_p — количество замеров пластового давления; w_λ и w_p — весовые коэффициенты, использующиеся для настройки баланса между составляющими целевой функции.

Первое слагаемое целевой функции отвечает за настройку поля подвижности на известные на скважинах фильтрационные свойства пласта. Причем рассчитанная подвижность может изменяться в диапазоне значений от $\hat{\lambda}_l$ до $\hat{\lambda}_r$, не приводя к росту целевой функции. Наличие допустимого интервала связано с изменением во времени фазового состава на скважинах, влияющего на подвижность в прискважинной зоне. Второе слагаемое описывает отклонение расчетных давлений от известных значений пластового давления. Весовые коэффициенты w_{p_i} отражают важность i -го замера давления. В настоящем исследовании значения весовых коэффициентов линейно увеличивались со временем. Таким образом, самыми важными считались значения давления, наиболее близкие к периоду прогноза. При решении обратной задачи в качестве фактических замеров пластового давления использовалось ограниченное количество давлений, полученных из решения прямой задачи. Случайным образом выбраны 10% от общего количества значений пластового давления, которые выступали в качестве истинных значений.

Обратная задача решалась с помощью градиентных методов, которые требуют расчета градиентов целевой функции по настраиваемым параметрам сети радиально базисных функций:

$$\frac{\partial J}{\partial c_i}, \frac{\partial J}{\partial \varepsilon_i}, \frac{\partial J}{\partial w_i}, \frac{\partial J}{\partial b}.$$

Градиенты вычисляются стандартным для области машинного обучения методом обратного распространения ошибки, который в данном случае предполагает решение сопряженной задачи для фильтрационной модели [Farrell и др., 2013; Косяков, Родионов, 2016]. В качестве инструмента для реализации представленного подхода была использована библиотека для машинного обучения Flux [Innes и др., 2018] языка программирования Julia.

Рассмотрим истинное поле общей подвижности, приведенное на рис. 6 в логарифмическом масштабе. Поле соответствует концу обучающей выборки ($t = 7$ лет). Видно, что поле общей подвижности качественно повторяет поле проницаемости (см. рис. 1). На рис. 6 кроме поля подвижности представлены связи между скважинами и их значения, которые были получены методом частичного исключения переменных из численной фильтрационной

модели [Андреев, 2013]. Наибольшие значения связей № 2 — № 4 и № 1 — № 5 соответствуют промытым водой высокопроводящим каналам, а малые значения связей относятся к изолированной добывающей скважине № 3. Коэффициенты связей имеют смысл проводимости между скважинами на единицу толщины пласта. Подобные коэффициенты связи могут быть получены при интерпретации попарного гидропрослушивания скважин.

На рис. 7 в логарифмическом масштабе приведено восстановленное поле общей подвижности и соответствующие ему связи между скважинами. Восстановленное поле качественно повторяет истинное поле: между парами скважин № 1 — № 5 и № 2 — № 4 восстановлены области с высокой подвижностью, скважина № 3 находится в области низкой подвижности.

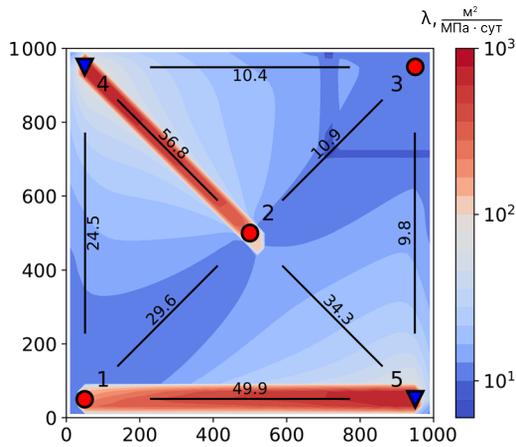


Рис. 6. Поле общей подвижности на конец обучающей выборки
Fig. 6. Total mobility field at the end of the training set

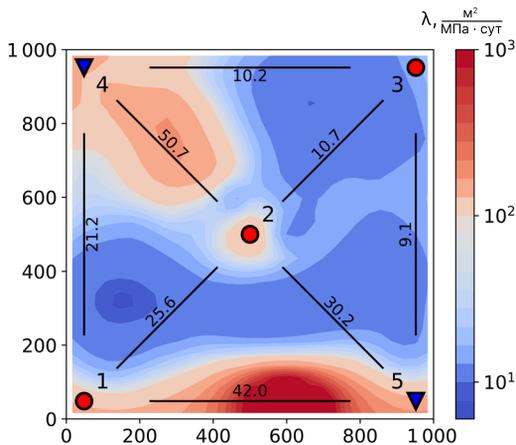


Рис. 7. Восстановленное поле общей подвижности
Fig. 7. Restored general total field

Таблица 1. Коэффициенты связей между скважинами

Table 1. The connection coefficients between wells

Связь (№ — №)	Истинное значение связи для момента времени $t = 7$ лет, $\text{м}^2/\text{МПа} \cdot \text{сут}$	Восстановленное значение связи, $\text{м}^2/\text{МПа} \cdot \text{сут}$	Относительная ошибка, д. ед.
2 — 4	56,75	50,74	0,106
1 — 5	49,87	41,97	0,158
2 — 5	34,26	30,17	0,119
1 — 2	29,57	25,56	0,136
1 — 4	24,47	21,15	0,136
2 — 3	10,87	10,71	0,014
3 — 4	10,36	10,19	0,016
3 — 5	9,84	9,15	0,071

Количественное сопоставление истинного и восстановленного поля общей подвижности проведено на основе рассчитанных для них величин связей между скважинами. Сравнение связей приведено в таблице 1, из которой видно, что ранжирование восстановленных связей полностью совпадает с ранжированием истинных. Кроме того, получено удовлетворительное количественное совпадение величин связей: в среднем относительная ошибка составляет 9%. Таким образом, восстановленное поле общей подвижности качественно и количественно воспроизводит ключевые особенности истинного поля.

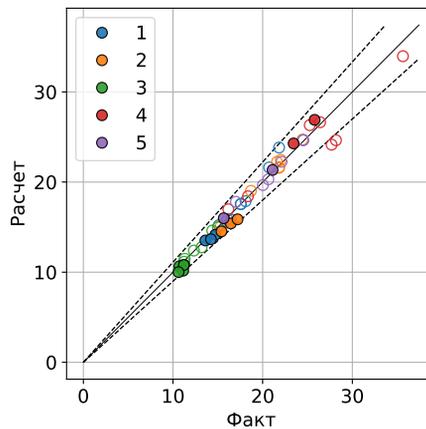


Рис. 8. Сопоставление фактических и расчетных значений пластового давления для добывающих и нагнетательных скважин. Полые маркеры соответствуют обучающей выборке, закрашенные — тестовой выборке. Пунктирная линия обозначает интервал отклонения в 10%

Fig. 8. The comparison of true and calculated reservoir pressure values for production and injection wells. Hollow markers correspond to the training set, filled markers correspond to the test set. The dotted line indicates the 10% deviation interval

Для реальных пластовых систем величины связей между скважинами, как правило, достоверно неизвестны. Ввиду этого одним из основных критериев для оценки качества адаптации модели выступают замеры пластового давления. На рис. 8 приведено сравнение значений фактических и расчетных пластовых давлений, полученных после восстановления поля общей подвижности. Видно, что получено удовлетворительное совпадение давлений на обучающей и тестовой выборке, значения средней относительной ошибки для которых составляет 2,6 и 4,1% соответственно. Модель демонстрирует удовлетворительную точность на тестовой выборке, что подтверждает ее прогнозные свойства.

Расчет обводненности с помощью рекуррентной нейронной сети

Рассмотренная выше однофазная модель фильтрации может быть использована для прогнозирования добычи жидкости и поведения пластового давления. Однако, как отмечалось выше, целевым показателем разработки является добыча нефти. Использование двухфазной модели фильтрации при решении обратной задачи существенно усложняет подходы к численному моделированию, требует больше вычислительного времени и дополнительной исходной информации для моделирования. В связи с этим разумным представляется использование подходов машинного обучения для учета добычи нефти совместно с адаптированной на историю однофазной моделью фильтрации. В настоящей работе для определения обводненности добываемой жидкости использована рекуррентная нейронная сеть.

Для описания динамики обводненности на скважинах была использована рекуррентная нейронная сеть, работающая по принципу «многие к одному», схема которой приведена на рис. 9. РНС последовательно обрабатывает информацию о режимах работы скважин на некотором временном интервале, включающем в себя k моментов времени $(x^{n-k+1}, x^{n-k+2}, \dots, x^{n-1}, x^n)$: текущий и предшествующие ему. Затем накопленная нейросетью информация используется для предсказания обводненности добываемой жидкости (\hat{y}^n) . В качестве входных данных выступают дебиты добывающих скважин q_{prod} , приемистости нагнетательных скважин q_{inj} , накопленная добыча жидкости Q_{prod} по скважинам, накопленный объем закачки Q_{inj} по скважинам и обводненность добываемой жидкости f_w . Все входные данные нормированы на единицу. Выходом нейросети является вектор, который содержит предсказанную для добывающих скважин обводненность \hat{f}_w . В общем случае вектора x^n и \hat{y}^n имеют следующий вид:

$$x^n = \left[q_{prod,1}^n, \dots, q_{prod,m}^n, q_{inj,1}^n, \dots, q_{inj,l}^n, \right. \\ \left. Q_{prod,1}^n, \dots, Q_{prod,m}^n, Q_{inj,1}^n, \dots, Q_{inj,l}^n, \right. \\ \left. f_{w,1}^{n-1}, \dots, f_{w,m}^{n-1} \right], \\ \hat{y}^n = \left[\hat{f}_{w,1}^n, \hat{f}_{w,2}^n, \dots, \hat{f}_{w,m}^n \right],$$

где нижними индексами m и l обозначены номера добывающих и нагнетательных скважин. На этапе обучения на вход сети подаются фактические значения обводненности $f_{w,m}^n$. При прогнозировании на входе сети вместо известных значений обводненности используются значения, рассчитанные на предыдущем шаге $\hat{f}_{w,m}^{n-1}$.

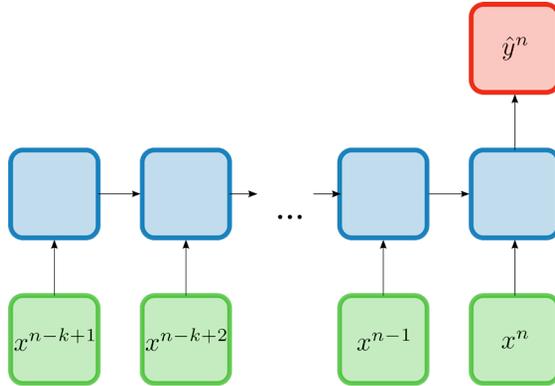


Рис. 9. Схема РНС «многие к одному». Зеленые блоки — входные данные, синие блоки — внутренний слой сети, красный блок — выход сети

Fig. 9. Sequence-to-one RNN scheme. Green blocks are the input data, blue blocks are the inner layer of the network, red block is the network output

В качестве целевой функции используется стандартная для регрессионных задач взвешенная среднеквадратическая ошибка:

$$J = \frac{1}{N_f} \sum_{i=1}^N w_i (f_{w,i} - \hat{f}_{w,i})^2,$$

где w_i — весовой коэффициент; $f_{w,i}$ — истинное значение обводненности; $\hat{f}_{w,i}$ — расчетное значение обводненности; N_f — количество значений обводненности. Веса w_i выбраны так, чтобы больше внимания уделять концу интервала обучения, для которого характерна обводненность будет наиболее близка к прогнозным значениям.

При обучении использована архитектура рекуррентной сети с долгой краткосрочной памятью LSTM [Hochreiter, Schmidhuber, 1997]; временной интервал, подаваемый на вход модели, составлял 10 месяцев. На рис. 10 приведены истинные и расчетные значения обводненности каждой скважины. Для скважин № 1 и 2 наблюдается хорошее совпадение расчетных значений с истинными данными (рис. 10а, б). Средняя относительная ошибка на тестовой выборке для скважин № 1 и 2 имела значение 2,2 и 1,2% соответственно. Кроме того, модель РНС позволяет воспроизвести характерное немонотонное поведение обводненности. Получена хорошая корреляция истинных и расчетных значений обводненности: коэффициент корреляции Пирсона для тестовой выборки имеет значения 0,68 и 0,93 для скважин № 1 и 2 соответственно. Таким образом, можно ожидать, что модель будет корректно описывать реакцию обводненности на изменения не только режимов работы самой добывающей скважины, но и ее окружения.

Обучающая выборка для скважины № 3 содержит информацию о безводном периоде ее работы; фронт вытеснения нефти водой доходит до скважины в момент времени, относящийся к тестовой выборке (рис. 10в). В данных условиях модель не способна воспроизвести рост обводненности на тестовой выборке, т. к. обучающая выборка не включала в себя соответствующих режимов работы скважины. На примере скважины № 3 продемонстрировано общее ограничение на применение подходов машинного обучения.

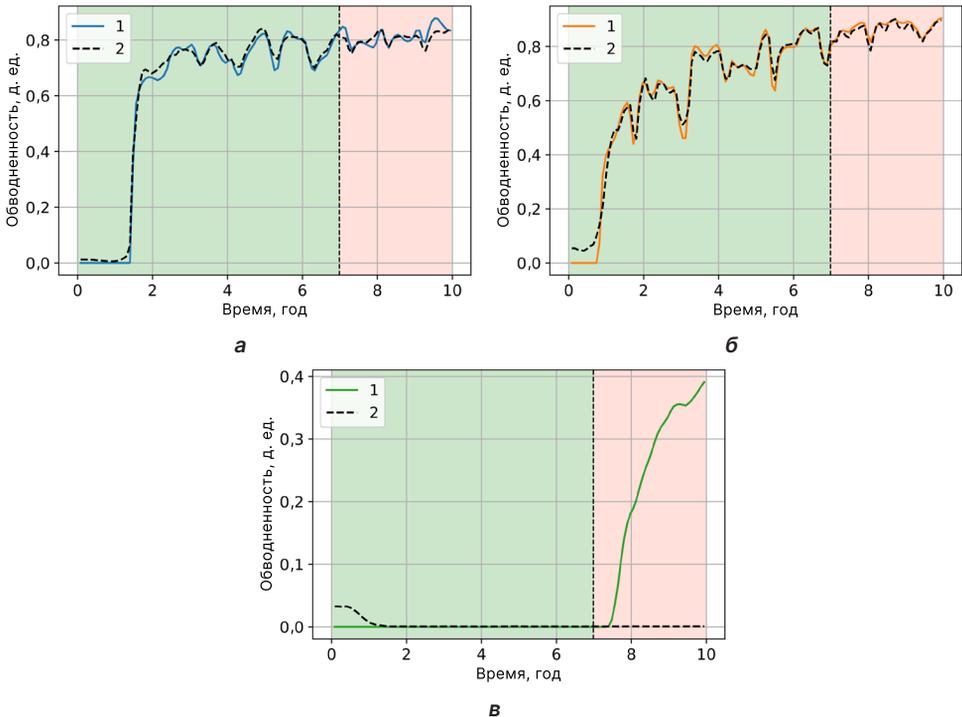


Рис. 10. Сопоставление истинных (линия 1) и рассчитанных с помощью РНС (линия 2) обводненностей для скважин: а — № 1, б — № 2, в — № 3

Fig. 10. Comparison of true (line 1) and calculated using RNN (line 2) water cuts for wells: а — No. 1, б — No. 2, в — No. 3

Заключение

Предложен подход к совместному применению теории фильтрации и машинного обучения для адаптации однофазной модели фильтрации на историю разработки и расчета обводненности добываемой жидкости. На примере синтетической модели элемента нефтяного месторождения с зонально-неоднородным полем проницаемости была продемонстрирована реализация предложенных подходов.

Адаптация однофазной модели фильтрации на историю проведена путем восстановления поля общей подвижности с помощью сети радиально-базисных функций. На основе

восстановленного поля рассчитаны коэффициенты связи между скважинами, которые качественно и количественно соответствуют истинным связям.

Обводненность добываемой жидкости получена с помощью РНС. Применение рекуррентных нейронных сетей позволило с достаточной точностью спрогнозировать динамику обводнения добывающих скважин. Воспроизведено немонотонное поведение обводненности, которое обусловлено изменением режимов работы скважин, в том числе отключением нагнетательных скважин.

Удовлетворительные прогнозные свойства связки моделей позволяют использовать разработанный подход для оптимизации режимов работы нагнетательных скважин с целью увеличения добычи нефти.

СПИСОК ИСТОЧНИКОВ

- Азиз Х., Сеттари Э. 2004. Математическое моделирование пластовых систем. М.; Ижевск: Институт компьютерных исследований. 416 с.
- Андреев В. Б. 2013. Численные методы: учеб. пос. М.: Изд. отд. фак. ВМиК МГУ им. М. В. Ломоносова; МАКС Пресс. 336 с.
- Бекман А. Д., Поспелова Т. А., Зеленин Д. В. 2020. Новый метод прогнозирования динамики обводненности скважин с использованием результатов CRMP-моделирования // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. Том 6. № 1 (21). С. 192–207. <https://doi.org/10.21684/2411-7978-2020-6-1-192-207>
- Власов А. И., Можилья А. Ф. 2018. Обзор технологии: от цифрового к интеллектуальному месторождению // PRНефть. Профессионально о нефти. № 3 (9). С. 68–74. <https://doi.org/10.24887/2587-7399-2018-3-68-74>
- Каневская Р. Д. 2002. Математическое моделирование гидродинамических процессов разработки месторождений углеводородов. М.; Ижевск: Институт компьютерных исследований. 140 с.
- Косяков В. П., Родионов С. П. 2016. Оптимальное управление системой скважин на основе уравнений двухфазной фильтрации // Труды МФТИ. Том 8. № 3 (31). С. 79–90.
- Косяков В. П., Легостаев Д. Ю., Мусакаев Э. Н. 2021. Задача совместного использования теории фильтрации и элементов машинного обучения для решения обратной задачи восстановления гидропроводности нефтяного месторождения // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. Том 7. № 2 (26). С. 113–129. <https://doi.org/10.21684/2411-7978-2021-7-2-113-129>
- Косяков В. П., Легостаев Д. Ю. 2022. Использование машинного обучения для восстановления поля проницаемости элемента разработки нефтяного пласта в двумерной постановке // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. Том 8. № 2 (30). С. 129–149. <https://doi.org/10.21684/2411-7978-2022-8-2-129-149>
- Мазо А. Б., Поташев К. А. 2020. Суперэлементы. Моделирование разработки нефтяных месторождений: монография. М.: ИНФРА-М. 220 с. <https://doi.org/10.12737/1043236>

- Поташев К. А., Ахунов Р. Р., Мазо А. Б. 2022. Вычисление перетоков флюида между скважинами в фильтрационной модели разработки нефтяного пласта с помощью линий тока // Георесурсы. Том 24. № 1. С. 27–35. <https://doi.org/10.18599/grs.2022.1.3>
- Умановский А. В. 2022. Графовые нейронные сети для прокси-моделирования гидродинамики пласта // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. Том 8. № 3 (31). С. 155–177. <https://doi.org/10.21684/2411-7978-2022-8-3-155-177>
- Alakeely A., Horne R. N. 2020. Simulating the behavior of reservoirs with convolutional and recurrent neural networks // SPE Reservoir Evaluation & Engineering. Vol. 23. No. 3. Pp. 992–1005. <https://doi.org/10.2118/201193-PA>
- Bai T., Tahmasebi P. 2021. Efficient and data-driven prediction of water breakthrough in subsurface systems using deep long short-term memory machine learning // Computational Geosciences. Vol. 25. No. 1. Pp. 285–297. <https://doi.org/10.1007/s10596-020-10005-2>
- Farrell P. E., Ham D. A., Funke S. F., Rognes M. E. 2013. Automated derivation of the adjoint of high-level transient finite element programs // SIAM Journal on Scientific Computing. Vol. 35. No. 4. Pp. C369–C393. <https://doi.org/10.48550/arXiv.1204.5577>
- Gopa K., Yamov S., Naugolnov M., Perets D., Simonov M. 2018. Cognitive analytical system based on data-driven approach for mature reservoir management // SPE Russian Petroleum Technology Conference (15–17 October 2018, Moscow, Russia). Paper SPE-191592-18RPTC-MS. <https://doi.org/10.2118/191592-18RPTC-MS>
- Hochreiter S., Schmidhuber J. 1997. Long short-term memory // Neural Computation. Vol. 9. No. 8. Pp. 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Illarionov E., Temirchev P., Voloskov D., Kostoev R., Simonov M., Pissarenko D., Orlov D., Koroteev D. 2022. End-to-end neural network approach to 3D reservoir simulation and adaptation // Journal of Petroleum Science and Engineering. Vol. 208. Article 109332. <https://doi.org/10.1016/j.petrol.2021.109332>
- Innes M., Saba E., Fischer K., Gandhi Dh., Rudilosso M. C., Joy N. M., Karmali T., Pal A., Shah V. 2018. Fashionable modelling with Flux // ArXiv. Article 1811.01457. <https://doi.org/10.48550/arXiv.1811.01457>
- Musakaev E. N., Rodionov S. P., Musakaev N. G. 2021. Hierarchical approach to identifying fluid flow models in a heterogeneous porous medium // Mathematics. Vol. 9. No. 24. Article 3289. <https://doi.org/10.3390/math9243289>
- Temirchev P., Simonov M., Kostoev R., Burnaev E., Oseledets I., Akhmetov A., Margarit A., Sitnikov A., Koroteev D. 2020. Deep neural networks predicting oil movement in a development unit // Journal of Petroleum Science and Engineering. Vol. 184. Article 106513. <https://doi.org/10.1016/j.petrol.2019.106513>

References

- Aziz, Kh., & Settari, A. (2004). *Petroleum reservoir simulation*. Izhevsk Institute of Computer Science. [In Russian]
- Andreev, V. B. (2013). *Numerical methods*. MAX Press. [In Russian]
- Bekman, A. D., Pospelova, T. A., & Zelenin, D. V. (2020). A new approach to water cut forecasting based on results of capacitance resistance modeling. *Tyumen State University Herald. Physical*

- and Mathematical Modeling. Oil, Gas, Energy*, 6(1), 192–207. <https://doi.org/10.21684/2411-7978-2020-6-1-192-207> [In Russian]
- Vlasov, A. I., & Mozhchil, A. F. (2018). Technology overview: From digital to intelligent field. *PROneft. Professionally about Oil*, (3), 68–74. <https://doi.org/10.24887/2587-7399-2018-3-68-74> [In Russian]
- Kanevskaya, R. D. (2002). *Mathematical simulation of hydrodynamic processes of hydrocarbon deposits development*. Izhevsk Institute of Computer Science. [In Russian]
- Kosyakov, V. P., & Rodionov, S. P. (2016). Optimal control of wells on the basis of two-phase filtration equations. *Proceedings of MIPT*, 8(3), 79–90. [In Russian]
- Kosyakov, V. P., Legostaev, D. Yu., & Musakaev, E. N. (2021). The problem of the combined use of filtration theory and machine learning elements for solving the inverse problem of restoring the hydraulic conductivity of an oil field. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*, 7(2), 113–129. <https://doi.org/10.21684/2411-7978-2021-7-2-113-129> [In Russian]
- Kosyakov, V. P., & Legostaev, D. Yu. (2022). Using elements of machine learning to solve the inverse problem of reconstructing the hydraulic conductivity field for a filtration problem. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*, 8(2), 129–149. <https://doi.org/10.21684/2411-7978-2022-8-2-129-149> [In Russian]
- Mazo, A. B., & Potashev, K. A. (2020). *The superelements. Modeling of oil fields development*. INFRA-M. <https://doi.org/10.12737/1043236> [In Russian]
- Potashev, K. A., Akhunov, R. R., & Mazo, A. B. (2022). Calculation of the flow rate between wells in the flow model of an oil reservoir using streamlines. *Georesources*, 24(1), 27–35. <https://doi.org/10.18599/grs.2022.1.3> [In Russian]
- Umanovskiy, A. W. (2022). Proxy modeling of reservoir hydrodynamics with graph neural networks. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy*, 8(3), 155–177. <https://doi.org/10.21684/2411-7978-2022-8-3-155-177> [In Russian]
- Alakeely, A., & Horne, R. N. (2020). Simulating the behavior of reservoirs with convolutional and recurrent neural networks. *SPE Reservoir Evaluation & Engineering*, 23(3), 992–1005. <https://doi.org/10.2118/201193-PA>
- Bai, T., & Tahmasebi, P. (2021). Efficient and data-driven prediction of water breakthrough in subsurface systems using deep long short-term memory machine learning. *Computational Geosciences*, 25(1), 285–297. <https://doi.org/10.1007/s10596-020-10005-2>
- Farrell, P. E., Ham, D. A., Funke, S. F., & Rognes, M. E. (2013). Automated derivation of the adjoint of high-level transient finite element programs. *SIAM Journal on Scientific Computing*, 35(4), C369–C393. <https://doi.org/10.48550/arXiv.1204.5577>
- Gopa, K., Yamov, S., Naugolnov, M., Perets, D., & Simonov, M. (2018, October 15–17). *Cognitive analytical system based on data-driven approach for mature reservoir management* [Conference paper SPE-191592-18RPTC-MS]. SPE Russian Petroleum Technology Conference, Moscow, Russia. <https://doi.org/10.2118/191592-18RPTC-MS>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Illarionov, E., Temirchev, P., Voloskov, D., Kostoev, R., Simonov, M., Pissarenko, D., Orlov, D., & Koroteev, D. (2022). End-to-end neural network approach to 3D reservoir simulation

- and adaptation. *Journal of Petroleum Science and Engineering*, 208, Article 109332. <https://doi.org/10.1016/j.petrol.2021.109332>
- Innes, M., Saba, E., Fischer, K., Gandhi, Dh., Rudilosso, M. C., Joy, N. M., Karmali, T., Pal, A., & Shah, V. (2018). Fashionable modelling with Flux. *ArXiv*, Article 1811.01457. <https://doi.org/10.48550/arXiv.1811.01457>
- Musakaev, E. N., Rodionov, S. P., & Musakaev, N. G. (2021). Hierarchical approach to identifying fluid flow models in a heterogeneous porous medium. *Mathematics*, 9(24), Article 3289. <https://doi.org/10.3390/math9243289>
- Temirchev, P., Simonov, M., Kostoev, R., Burnaev, E., Oseledets, I., Akhmetov, A., Margarit, A., Sitnikov, A., & Koroteev, D. (2020). Deep neural networks predicting oil movement in a development unit. *Journal of Petroleum Science and Engineering*, 184, Article 106513. <https://doi.org/10.1016/j.petrol.2019.106513>

Информация об авторах

Дмитрий Юрьевич Легостаев, младший научный сотрудник, Тюменский филиал Института теоретической и прикладной механики им. С. А. Христиановича СО РАН, Тюмень, Россия

legostaevdy@yandex.ru, <https://orcid.org/0000-0001-6371-7031>

Виталий Петрович Косяков, кандидат физико-математических наук, старший научный сотрудник, Тюменский филиал Института теоретической и прикладной механики им. С. А. Христиановича СО РАН, Тюмень, Россия

lik.24@yandex.ru, <https://orcid.org/0000-0002-2297-408X>

Information about the authors

Dmitry Yu. Legostaev, Junior Researcher, Tyumen Branch of the Khristianovich Institute of Theoretical and Applied Mechanics of the Siberian Branch of the Russian Academy of Sciences, Tyumen, Russia

legostaevdy@yandex.ru, <https://orcid.org/0000-0001-6371-7031>

Vitaly P. Kosyakov, Cand. Sci. (Phys.-Math.), Senior Researcher, Tyumen Branch of the Khristianovich Institute of Theoretical and Applied Mechanics of the Siberian Branch of the Russian Academy of Sciences, Tyumen, Russia

lik.24@yandex.ru, <https://orcid.org/0000-0002-2297-408X>